

RICARDO JANES

PROPOSIÇÃO DE UM ALGORITMO PARA IDENTIFICAÇÃO BIOMÉTRICA
DE PESSOAS BASEADO NOS PADRÕES DE VEIAS DAS MÃOS

São Paulo
2016

RICARDO JANES

PROPOSIÇÃO DE UM ALGORITMO PARA IDENTIFICAÇÃO BIOMÉTRICA
DE PESSOAS BASEADO NOS PADRÕES DE VEIAS DAS MÃOS

Tese apresentada à Escola Politécnica da Uni-
versidade de São Paulo para obtenção do título
de doutor em Ciências

São Paulo
2016

RICARDO JANES

PROPOSIÇÃO DE UM ALGORITMO PARA IDENTIFICAÇÃO BIOMÉTRICA
DE PESSOAS BASEADO NOS PADRÕES DE VEIAS DAS MÃOS

Tese apresentada à Escola Politécnica da Uni-
versidade de São Paulo para obtenção do título
de doutor em Ciências

Área de concentração:
Engenharia Elétrica

Orientador:
Prof. Dr. Augusto Ferreira Brandão Jr.

São Paulo
2016

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, _____ de _____ de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Janes, Ricardo

Proposição de um algoritmo para identificação biométrica de pessoas baseado nos padrões de veias das mãos / R. Janes – versão corr. -- São Paulo, 2016.

155 p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas.

1.Biometria 2.Processamento de Imagens 3.Inteligência Artificial
4.Mineração de dados 5.Redes Neurais I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Energia e Automação Elétricas II.t.

DEDICATÓRIA

Às minhas queridas filhas Sophia e Giovanna,
meus pequenos anjos enviados por Deus, pelo
auxílio na elaboração desta tese em forma de
beijos, abraços e atos de amor intermináveis
que me inspiraram a continuar batalhando,
mesmo nos momentos mais difíceis.

AGRADECIMENTOS

Ao Prof. Dr. Augusto Ferreira Brandão Júnior, pelas diretrizes seguras, orientação, supervisão, confiança, paciência e oportunidade que concedeu-me para o desenvolvimento desta pesquisa e por todo o apoio prestado durante estes anos.

Ao Prof. Dr. Cícero Couto de Moraes e ao Prof. Dr. Sérgio Luiz Pereira, pelas importantes contribuições durante o exame de qualificação deste trabalho.

À minha querida esposa Dinah, que com muito amor e paciência, fez com que a execução deste trabalho se tornasse mais fácil.

À Escola Politécnica da Universidade de São Paulo, pela oportunidade de realização deste trabalho.

Ao Dr. Caio Cesar Fattori, pelas importantes contribuições na editoração e diagramação deste trabalho com o uso do sistema Latex.

Ao amigo Prof. Ms. Daniel Otávio Tambasco Bruno, por todo o auxílio com os programas envolvidos.

Ao Prof. Dr. Mauro Sérgio Juarez Cáceres, pela confiança, incentivo e apoio.

Aos professores do curso de pós-graduação da Escola Politécnica da Universidade de São Paulo, principalmente aos professores do PEA, pelo apoio, colaboração, sugestões e discussões levantadas ao longo do período de pesquisa, fundamentais na elaboração e consolidação do trabalho.

À minha família e meus amigos, pela paciência, ajuda, apoio e carinho.

A todos que direta ou indiretamente contribuíram para a elaboração deste trabalho.

RESUMO

Esta tese tem por finalidade apresentar o desenvolvimento de um sistema biométrico de baixo custo, capaz de identificar pessoas pela análise dos padrões de veias das mãos com obtenção de imagens no espectro infravermelho próximo. O sistema foi montado fisicamente através da construção de um protótipo e então foram adquiridas e armazenadas 520 imagens da parte dorsal da mão direita de 52 diferentes usuários, após isto foi realizada a extração de uma região de interesse definida pela maior porção quadrada da parte dorsal da mão. Em seguida foram aplicados três diferentes métodos de equalização e suavização da imagem na fase de pré-processamento, para posterior extração das características das veias com a utilização da transformada de Curvelet na função “wrapping” e aplicação do algoritmo Padrão Binário Local (LBP) para a digitalização do conteúdo extraído. No próximo passo, uma análise de identificação foi realizada usando cinco diferentes métodos de classificação. Em primeiro lugar, foi utilizado um classificador probabilístico Naive Bayes, em seguida um classificador baseado em aprendizagem por regressão linear Kernel Nearest Neighbor (K-NN), ainda foram aplicados dois algoritmos baseados em árvores de decisão C4.5 e Random Forest e finalmente um algoritmo baseado em redes neurais artificiais Multilayer Perceptron. Os classificadores foram testados utilizando o método de validação cruzada, e as informações foram separadas por 10 folds sendo que 10% dos dados foram utilizados para treino e 90% dos dados foram utilizados para teste. Com os mesmos dados resultantes da fase de pré-processamento, dois algoritmos foram aplicados para seleção de características, sendo o primeiro baseado na correlação da função de seleção de recursos e o segundo na seleção de atributos pelo conceito da entropia dos dados. Os resultados provam que o método de equalização de histograma adaptativa por limite de contraste na fase de pré-processamento apresentou os melhores resultados. Quanto aos classificadores, os melhores resultados foram obtidos com o uso da rede neural artificial proposta e as taxas de falsa aceitação (FAR) e falsa rejeição (FRR) obtidas após o processamento foram estimadas em 0,038 e 0,003 respectivamente. Foram realizados ainda testes com a quantidade mínima de imagens necessárias para identificação de pessoas e chegou-se ao valor de cinco imagens por usuário. Finalmente a avaliação da permanência do sistema biométrico foi realizada através da análise de imagens capturadas após um ano da primeira análise e os resultados mostram que o sistema é robusto, apesar das imagens conterem pequenas alterações, proporcionais às variações do índice de massa corporal dos usuários.

Palavras-chave: Biometria. Processamento de Imagens. Inteligência Artificial. Mineração de dados. Redes Neurais.

ABSTRACT

The system has been assembled as a prototype then were acquired and stored 520 images from the dorsal side of the right hand of 52 different users, and then is accomplished an extracting of a region of interest defined by the largest square portion of the dorsal hand. Then a pre-processing of image has been applied using three different methods of image equalization and smoothing for later extraction of the veins characteristics using the Curvelet Transform in "wrapping" function and application of the Local Binary Pattern algorithm (LBP) for scanning the extracted content. On the next step, an identification analysis has been performed using five different classification methods. First, a probabilistic Naive Bayes classifier was used, second a classifier based on linear regression called Kernel Nearest Neighbor (K-NN) was applied, third and fourth two algorithms based on decision trees, C4.5 and Random Forest were tested, and finally an algorithm based on artificial neural networks Multilayer Perceptron was performed. The classifiers have been tested using the cross-validation method, and the information was separated by 10 folds wherein 10% of the data were used for training and 90% of the data were used for testing. From the same data resulted of the pre-processing step, two algorithms have been applied for selection features, the first based on the correlation based feature selection and the second in selecting attributes based to the concept of entropy data. The results proof that the equalization method by contrast limited adaptive histogram equalization, in the pre-processing stage, shown the best results. From the application of classifiers, the best result was achieved by using the artificial neural network proposal and the false acceptance rate (FAR) and false rejection rate (FRR) found through the processing were estimated in 0.038 and 0.003 respectively. Tests were also performed to assess the minimum amount of images needed to identify people and as result five images per user were found as the ideal number. Finally, the assessment of the biometric system permanence was performed using acquired images after a year of the first analysis and the results shown that the system is robust, even that the pictures contain minor changes proportional to index variations of body mass of users.

Keywords: Biometry. Image Processing. Artificial Intelligence. Data Mining. Neural Networks

LISTA DE ILUSTRAÇÕES

| | | |
|------------|---|-----|
| Figura 1 | Fotografia do Edifício <i>Citi Center / Citibank</i> | 16 |
| Figura 2 | Curva de análise da qualidade de um sistema biométrico | 27 |
| Gráfico 1 | Quantidade de trabalhos publicados por ano de publicação | 56 |
| Gráfico 2 | Métodos de extração utilizados | 57 |
| Gráfico 3 | Algoritmos utilizados na extração de características das imagens | 58 |
| Gráfico 4 | Algoritmos classificadores utilizados | 59 |
| Gráfico 5 | Padrões de veias analisados | 60 |
| Figura 3 | Imagem de uma mão obtida com filtro IR de $850nm$ | 62 |
| Figura 4 | Conjunto de LEDs na base do protótipo | 65 |
| Figura 5 | Base com pinos para posicionamento da mão | 66 |
| Figura 6 | Resultados do método de invólucro | 76 |
| Figura 7 | Conjunto de vizinhança do algoritmo LBP | 77 |
| Figura 8 | Fluxograma do algoritmo para extração de características | 79 |
| Figura 9 | Funcionamento do algoritmo CFS | 81 |
| Figura 10 | Fluxograma do processo de classificação dos dados | 93 |
| Figura 11 | Amostra de imagem adquirida com nome atribuído | 95 |
| Figura 12 | Extração da região de interesse ROI | 96 |
| Figura 13 | Equalização global do histograma da imagem | 97 |
| Figura 14 | Mapeamento e ajuste de intensidade de cinza | 98 |
| Figura 15 | Equalização de histograma adaptativa por limite de contraste | 99 |
| Figura 16 | Resultados dos processos de melhoramento do contraste | 100 |
| Gráfico 6 | Resultados com o uso do classificador <i>Naive Bayes</i> | 106 |
| Gráfico 7 | Resultados com o uso do classificador K-NN | 107 |
| Gráfico 8 | Resultados com o uso do classificador C4.5/J48 | 107 |
| Gráfico 9 | Resultados com o uso do classificador <i>Random Forest</i> | 108 |
| Gráfico 10 | Resultados com classificador <i>Naive Bayes</i> utilizando SUAE | 111 |
| Gráfico 11 | Resultados com classificador K-NN utilizando SUAE | 111 |
| Gráfico 12 | Resultados com classificador C4.5/J48 utilizando SUAE | 112 |
| Gráfico 13 | Resultados com classificador <i>Random Forest</i> utilizando SUAE | 112 |
| Gráfico 14 | Resultados com classificador <i>Naive Bayes</i> utilizando CFS | 116 |
| Gráfico 15 | Resultados com classificador K-NN utilizando CFS | 116 |
| Gráfico 16 | Resultados com classificador C4.5/J48 utilizando CFS | 117 |

| | | |
|------------|--|-----|
| Gráfico 17 | Resultados com classificador <i>Random Forest</i> utilizando CFS | 117 |
| Figura 17 | Rede neural artificial criada no <i>software</i> WEKA | 119 |
| Gráfico 18 | Resultados obtidos na classificação por RNA | 120 |
| Gráfico 19 | Uso do classificador <i>Naive Bayes</i> com variação da quantidade de imagens | 123 |
| Gráfico 20 | Uso do classificador K-NN com variação da quantidade de imagens . . | 123 |
| Gráfico 21 | Uso do classificador C4.5/J48 com variação da quantidade de imagens | 124 |
| Gráfico 22 | Uso do classificador <i>Random Forest</i> com variação da quantidade de imagens | 124 |
| Figura 18 | Classificação por RNA com variação na quantidade de imagens | 125 |
| Gráfico 23 | Relação de variação do IMC com variação das imagens em um ano . . | 128 |
| Figura 19 | Comparação dos resultados obtidos | 130 |

LISTA DE TABELAS

| | | |
|-----------|--|-----|
| Tabela 1 | Resultados da análise comparativa entre <i>Wavelet</i> , <i>Curvelet</i> e <i>Ridgelet</i> . | 72 |
| Tabela 2 | Quantidade de características extraídas por imagem | 100 |
| Tabela 3 | Tempos envolvidos na binarização das subimagens com LBP | 101 |
| Tabela 4 | Quantidade de características extraídas com algoritmo CFS | 101 |
| Tabela 5 | Quantidade de características extraídas com algoritmo SUAE | 102 |
| Tabela 6 | Resultados obtidos com o uso do classificador <i>Naive Bayes</i> | 104 |
| Tabela 7 | Resultados obtidos com o uso do classificador K-NN | 104 |
| Tabela 8 | Resultados obtidos com o uso do classificador C4.5/J48 | 105 |
| Tabela 9 | Resultados obtidos com o uso do classificador <i>Random Forest</i> | 105 |
| Tabela 10 | Resultados com o classificador <i>Naive Bayes</i> e algoritmo SUAE | 109 |
| Tabela 11 | Resultados com o classificador K-NN e algoritmo SUAE | 109 |
| Tabela 12 | Resultados com o classificador C4.5/J48 e algoritmo SUAE | 110 |
| Tabela 13 | Resultados com o classificador <i>Random Forest</i> e algoritmo SUAE | 110 |
| Tabela 14 | Resultados com o classificador <i>Naive Bayes</i> e algoritmo CFS | 113 |
| Tabela 15 | Resultados com o classificador K-NN e algoritmo CFS | 114 |
| Tabela 16 | Resultados com o classificador C4.5/J48 e algoritmo CFS | 114 |
| Tabela 17 | Resultados com o classificador <i>Random Forest</i> e algoritmo CFS | 115 |
| Tabela 18 | Quantidade de neurônios artificiais criados na classificação por RNA | 118 |
| Tabela 19 | Resultados com o classificador RNA e algoritmo CFS | 120 |
| Tabela 20 | Classificador <i>Naive Bayes</i> com variação da quantidade de imagens | 121 |
| Tabela 21 | Classificador K-NN com variação da quantidade de imagens | 121 |
| Tabela 22 | Classificador C4.5/J48 com variação da quantidade de imagens | 122 |
| Tabela 23 | Classificador <i>Random Forest</i> com variação da quantidade de imagens | 122 |
| Tabela 24 | Classificador MLP com variação da quantidade de imagens | 125 |
| Tabela 25 | Dados dos usuários avaliados | 126 |
| Tabela 26 | Variações das imagens no período de um ano | 127 |
| Tabela 27 | Resultados obtidos com acréscimo de 17 imagens | 128 |
| Tabela 28 | Testes dos algoritmos de suavização de imagens | 129 |
| Tabela 29 | Análise comparativa dos resultados de outros autores | 129 |
| Tabela 30 | Análise comparativa dos resultados de outros sistemas biométricos | 131 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|---------|--|
| ABS | Acrilonitrila butadieno estireno |
| ASF | <i>Alternating Sequential Filter</i> |
| BACnet | <i>Building Automation and Control Networks</i> |
| BPV | <i>Border Pixel Vector</i> |
| BTG | <i>British Technology Group</i> |
| CASIA | <i>Chinese Academy of Sciences Institute of Automation</i> |
| CCD | <i>Charge-coupled device</i> |
| CFC | Clorofluorcarbono |
| CFS | <i>Correlation-based Feature Selection</i> |
| CFTV | Circuitos Fechados de Televisão |
| CLAHE | <i>Contrast Limited Adaptive Histogram Equalization</i> |
| CNN | <i>Cellular Neural Networks</i> |
| CPDA | <i>Chord to point distance accumulation</i> |
| CRC | <i>Collaborative Representation-Based Classification</i> |
| DAT | <i>Digital Audio Tape</i> |
| DC | <i>Direct Current</i> |
| DNA | <i>Deoxyribonucleic Acid</i> |
| DoG | <i>Difference of Gaussians</i> |
| EEPROM | <i>Electrical-Erasable Programmable Read-Only Memory</i> |
| EER | <i>Equal Error Rate</i> |
| ELGBPHS | <i>Enhanced Local Gabor Binary Patterns Histogram Sequence</i> |
| EPROM | <i>Erasable Programmable Read-Only Memory</i> |
| FAR | <i>False Acceptance Rate</i> |
| FDCT | <i>Fast Discret Curvelet Transform</i> |
| FFT | <i>Fast Fourier Transform</i> |
| FIR | <i>Far Infrared</i> |
| FPGA | <i>Field Programmable Gate Array</i> |
| FPVP | <i>Feature points of the vein patterns</i> |
| FRR | <i>False Rejection Rate</i> |
| FSO | <i>Free Space Optics</i> |
| HC | Hidrocarbono |
| HD | <i>Hard Disk</i> |
| HFC | Hidroclorofluorcarbono |

| | |
|----------|--|
| HFO | Tetrafluoropropano |
| HVAC | <i>Heating, ventilation and air conditioning</i> |
| IBI | <i>Intelligent Buildings Institute</i> |
| ICA | <i>Independent Component Analysis</i> |
| IFFT | <i>Inverse Fast Fourier Transform</i> |
| IMC | Índice de Massa Corpórea |
| IP | <i>Internet Protocol</i> |
| IR | <i>Infrared</i> |
| JPEG | <i>Joint Photographics Experts Group</i> |
| KNN | <i>Kernel Nearest Neighbor</i> |
| LBP | <i>Local Binary Pattern</i> |
| LDA | <i>Linear Discriminant Analysis</i> |
| LDP | <i>Local Derivative Pattern</i> |
| LDR | <i>Light Dependent Resistor</i> |
| LED | <i>Light Emitting Diode</i> |
| LEM | <i>Line Edge Map</i> |
| LONworks | <i>Local Operating Network</i> |
| LRT | <i>Localized Radon Transform</i> |
| M-LBP | <i>Modified Local Binary Pattern</i> |
| MDF | <i>Medium Density Fiberboard</i> |
| MHD | <i>Modified Hausdorff Distance</i> |
| MIAS | <i>Mammographic Image Analysis Society</i> |
| MLP | <i>Multi Layer Perceptron</i> |
| MRF | <i>Multiresolution filter</i> |
| NCUT | <i>North China University of Technology</i> |
| NIR | <i>Near Infrared</i> |
| NMF | <i>Non-negative Matrix Factorization</i> |
| PCA | <i>Principal Component Analysis</i> |
| PIN | <i>Personal Identification Number</i> |
| PLBP | <i>Partition Local Binary Pattern</i> |
| POC | <i>Phase Only Correlation</i> |
| PVC | <i>Polyvinyl chloride</i> |
| RFID | <i>Radio Frequency Identification</i> |
| RGB | <i>Red Green Blue</i> |
| RJ45 | <i>Registered Jack 45</i> |
| ROC | <i>Receiver Operating Characteristic</i> |

| | |
|-------|---|
| ROI | <i>Region of Interest</i> |
| SCM | <i>Single Chip Micryo co</i> |
| SIFT | <i>Scale-Invariant Feature Transform</i> |
| SNR | <i>Signal-to-noise ratio</i> |
| SSD | <i>Solid-State Drive</i> |
| SUAE | <i>Symmetrical Uncert Attribute Eval</i> |
| TIFF | <i>Tagged Image File Format</i> |
| TSE | <i>Tribunal Superior Eleitoral</i> |
| TV | <i>Total Variation</i> |
| USFFT | <i>Unequally Spaced Fast Fourier Transform</i> |
| UTP | <i>Unshielded Twisted Pair</i> |
| VDU | <i>Visual Display Unit</i> |
| VHS | <i>Video Home System</i> |
| WEKA | <i>Waikato Environment for Knowledge Analysis</i> |

SUMÁRIO

| | |
|---|----|
| 1 INTRODUÇÃO | 16 |
| 1.1 OBJETIVOS | 18 |
| 1.2 JUSTIFICATIVA E HIPÓTESE | 18 |
| 1.3 METODOLOGIA DA PESQUISA | 18 |
| 1.4 ESTRUTURA DO TRABALHO | 19 |
| 2 AUTOMAÇÃO PREDIAL E SISTEMAS DE SEGURANÇA | 20 |
| 2.1 CONTROLE DE ILUMINAÇÃO | 20 |
| 2.2 CONTROLE DE TEMPERATURA - AR CONDICIONADO | 21 |
| 2.3 SISTEMAS DE DE DETECÇÃO E ALARMES A INCÊNDIOS | 21 |
| 2.4 SISTEMAS DE SEGURANÇA PERIMETRAL E INTERNA | 22 |
| 2.5 CIRCUITOS FECHADOS DE TELEVISÃO - CFTV | 23 |
| 2.5.1 Sistemas analógicos | 23 |
| 2.5.2 Sistemas digitais | 23 |
| 2.6 REDES PARA AUTOMAÇÃO DE PRÉDIOS INTELIGENTES | 24 |
| 2.7 CONTROLE DE ACESSO EM EDIFÍCIOS INTELIGENTES | 24 |
| 2.7.1 Cartões inteligentes | 25 |
| 2.7.2 Biometria | 26 |
| 2.7.2.1 <i>Reconhecimento da impressão digital</i> | 28 |
| 2.7.2.2 <i>Reconhecimento da íris</i> | 29 |
| 2.7.2.3 <i>Reconhecimento da face</i> | 30 |
| 2.7.2.4 <i>Geometria das mãos</i> | 31 |
| 2.7.2.5 <i>Reconhecimento da voz</i> | 32 |
| 2.7.2.6 <i>Reconhecimento da assinatura</i> | 33 |
| 2.7.2.7 <i>Considerações sobre os principais algoritmos</i> | 33 |
| 3 RECONHECIMENTO DE PADRÕES DE VEIAS DAS MÃOS | 35 |
| 3.1 INTRODUÇÃO | 35 |
| 3.2 REVISÃO DA LITERATURA | 36 |
| 3.3 CONCLUSÕES FINAIS SOBRE A REVISÃO BIBLIOGRÁFICA | 55 |
| 4 MATERIAIS E MÉTODOS | 61 |
| 4.1 PROTÓTIPO PARA AQUISIÇÃO DAS IMAGENS | 61 |
| 4.1.1 Sistema de iluminação | 63 |
| 4.1.2 Posicionadores das mãos | 66 |

| | | |
|----------|--|-----------|
| 4.1.3 | Equalização global do histograma | 67 |
| 4.1.4 | Mapeamento e ajuste de intensidade de cinza | 68 |
| 4.1.5 | Equalização de histograma adaptativa por limite de contraste | 69 |
| 4.2 | EXTRAÇÃO DAS CARACTERÍSTICAS BIOMÉTRICAS | 70 |
| 4.2.1 | Transformada <i>Curvelet</i> | 73 |
| 4.2.2 | Transformada <i>Curvelet</i> digital | 73 |
| 4.2.3 | Transformada Digital <i>Curvelet</i> via “invólucro” | 74 |
| 4.3 | PROCESSO DE MONTAGEM DO VETOR DE CARACTERÍSTICAS | 76 |
| 4.3.1 | Operador LBP - “Padrões binários locais” | 76 |
| 4.4 | SELEÇÃO DE ATRIBUTOS | 80 |
| 4.4.1 | Algoritmo CFS | 80 |
| 4.4.2 | Algoritmo SUAE | 82 |
| 4.5 | CLASSIFICADORES PARA AVALIAÇÃO DOS ALGORITMOS PROPOSTOS | 83 |
| 4.5.1 | Métodos <i>Bayesianos</i> | 83 |
| 4.5.2 | Métodos de aprendizado “preguiçoso” | 85 |
| 4.5.3 | Métodos por árvores de decisão | 87 |
| 4.5.3.1 | <i>Algoritmo Random Forest</i> | 87 |
| 4.5.3.2 | <i>Algoritmo C4.5/J48</i> | 88 |
| 4.5.4 | Métodos baseados em Redes Neurais Artificiais | 89 |
| 4.5.4.1 | <i>Redes Neurais artificiais MLP</i> | 89 |
| 4.5.5 | Método de validação cruzada | 91 |
| 5 | RESULTADOS E DISCUSSÕES | 94 |
| 5.1 | AQUISIÇÃO DE IMAGENS | 94 |
| 5.2 | PRÉ-PROCESSAMENTO DAS IMAGENS | 95 |
| 5.3 | RESULTADOS OBTIDOS PARA SUAUIZAÇÃO DE IMAGENS | 96 |
| 5.3.1 | Equalização global do histograma | 96 |
| 5.3.2 | Mapeamento e ajuste de intensidade de cinza | 97 |
| 5.3.3 | Equalização adaptativa por limite de contraste | 97 |
| 5.4 | EXTRAÇÃO DE CARACTERÍSTICAS | 98 |
| 5.5 | PROCESSO DE DIGITALIZAÇÃO DAS IMAGENS. | 100 |
| 5.6 | SELEÇÃO DE ATRIBUTOS | 101 |
| 5.7 | RESULTADOS OBTIDOS COM OS CLASSIFICADORES | 102 |
| 5.7.1 | Classificação de dados sem uso de técnicas de seleção | 103 |
| 5.7.2 | Classificação de dados após algoritmo SUAE | 108 |
| 5.7.3 | Classificação de dados após algoritmo CFS | 113 |

| | | |
|----------|--|------------|
| 5.8 | ANÁLISE DE CLASSIFICAÇÃO COM REDE NEURAL ARTIFICIAL | 115 |
| 5.9 | ANÁLISE DA QUANTIDADE DE IMAGENS UTILIZADAS | 119 |
| 5.10 | ANÁLISE DE PERMANÊNCIA DOS DADOS | 125 |
| 5.11 | ANÁLISE DOS MÉTODOS DE SUAVIZAÇÃO DAS IMAGENS | 128 |
| 5.12 | ANÁLISE COMPARATIVA COM RESULTADOS DE OUTROS AUTORES | 129 |
| 5.13 | ANÁLISE COMPARATIVA COM OUTRAS TÉCNICAS BIOMÉTRICAS | 130 |
| 6 | CONCLUSÕES | 132 |
| | APÊNDICE A – Trabalho publicado | 135 |
| | REFERÊNCIAS | 141 |

1 INTRODUÇÃO

A automação predial iniciou-se na década de 70 com a implantação de sistemas automáticos de controle do ar condicionado, conhecidos como sistemas de *Heating, ventilation and air conditioning* (HVAC), em seguida, na década de 80 o conceito de prédio inteligente surgiu devido à crise energética americana e então começam a aparecer sistemas de controle de segurança e de iluminação, visando a eficiência energética. Em 1986, o Brasil adota o conceito de prédio inteligente com o lançamento do *CitiCorp Center/Citibank* na avenida Paulista, em São Paulo, projetado pelo arquiteto Gian Carlo Gasperini, sendo o primeiro edifício a adotar sistemas de automação. (PRUDENTE, 2011)

Abaixo, na Figura 1 pode-se visualizar uma fotografia do edifício *Citi Center*.

Figura 1 - Fotografia do Edifício *Citi Center / Citibank*



Fonte: (BUILDINGS, 2014)

De acordo com o *Intelligent Buildings Institute* (IBI), define-se como edifício inteligente os que apresentam ambiente produtivo e econômico, enfatizando ao menos os quatro elementos básicos: (IBI, 1987)

- a) Estrutura: elementos da arquitetura, acabamentos de interiores e exteriores, mobiliários e componentes estruturais;
- b) Sistemas: controle de temperatura, de ventilação, de iluminação, de segurança e energia elétrica;
- c) Serviços: comunicação de dados, voz e imagem;
- d) Gerenciamento: ferramentas para controlar o edifício, bem como das inter-relações entre eles.

Ao item de sistemas, atualmente os prédios inteligentes já são projetados com a ideia de redução de consumo dos recursos naturais. As fachadas são geralmente compostas por vidros que permitem a entrada de luz natural, inclusive com a implantação de vidros inteligentes,

que reduzem ou aumentam sua luminância eletronicamente, fazendo com que a quantidade de luz em um determinado ambiente seja constante. Lâmpadas de *Light Emitting Diode* (LED) são instaladas em substituição às lâmpadas incandescentes pois apresentam consumo reduzido e tempo de vida útil elevado quando comparadas às lâmpadas fluorescentes, além de não conter em sua estrutura o mercúrio, visto pelos ambientalistas como componente totalmente proibitivo. Ainda existe o fato de que este tipo de lâmpada gera menos calor, economizando indiretamente o consumo de energia elétrica em sistemas de ar condicionado. (TECHMUNDO, 2012)

Existem ainda os reatores dimerizáveis para lâmpadas fluorescentes, ou seja, pode-se controlar a quantidade de luz emitida pela lâmpada, e estes tem em sua construção física sensores de luz que fazem com que o controle de iluminação seja automático pois o mesmo trabalha em malha fechada, verificando a quantidade de luz proveniente do exterior e ajustando a luminância pré-determinada. O tema da iluminação já foi muito difundido nos meios acadêmico e industrial, inclusive gerando diversas dissertações de mestrado, teses de doutorado e artigos técnicos apresentados em congressos. (CARDOSO, 2008)

Sobre os sistemas de controle de temperatura, até os anos 80 distinguiam-se sistemas com ventilação, ar condicionado e aquecedores, estes eram equipamentos independentes. Atualmente todos estes sistemas foram integrados ao equipamento de ar condicionado, que incorporou o aquecimento do ar à sua característica. Sistemas automatizados são utilizados visando tanto o conforto quanto a redução do consumo de energia elétrica e a base de toda a automação está no uso dos aparelhos de ar condicionado, que possuem diversos recursos como por exemplo o controle de suas características feito remotamente pela *internet* ou até mesmo por aparelhos celulares. (MILLER; MILLER, 2014)

Na área de segurança, os principais sistemas adotados em edifícios inteligentes são os Circuitos Fechados de Televisão (CFTV), que no passado eram analógicos, com pouca resolução e com gravações em fitas *Video Home System* (VHS), e hoje são sistemas inteligentes digitais, controlados por *softwares*; os sistemas de controle perimetral, com sensores de infravermelho, ultrassom, de quebra de vidro, cercas eletrificadas e diversos outros dispositivos que visam evitar a invasão do edifício; os sistemas de controle e combate a incêndios, que praticamente se resumem aos sensores de calor e detectores de fumaça interligados a uma central de controle microprocessada e ainda os sistemas de controle de acesso, que podem ser implementados desde a leitura de cartões com códigos de barras para liberação física de catracas a até os sistemas mais avançados de leitura biométrica, que tiveram início com a leitura de impressões digitais, foram substituídos pelos sistemas de leitura de geometria das mãos, geometria das faces, padrão de íris e que hoje se encontra concentrado no estudo do padrão de veias das mãos, dedos e pulso. Todos estes sistemas devem ser interligados em um sistema inteligente, e

diversos protocolos de comunicação foram implementados para que isto seja realizado. (BÓ, 1995; BOLZANI, 2004)

A eficiência energética também é um tema de grande significância em edifícios inteligentes, e o controle efetivo de todos os equipamentos elétricos é realizado por dispositivos controladores de carga, entre outros. Um sistema ideal deve integrar os dispositivos em uma unidade de controle para o devido gerenciamento de consumo de energia em um edifício inteligente. (PINTO; MORAES; BRANDÃO JR, 2000)

Os estudos sobre biometria focam principalmente a segurança no controle de acesso em substituição aos crachás com códigos de barras, no entanto, os dispositivos existentes utilizam algoritmos patenteados, e sua estrutura só é comentada em forma de fluxogramas, fazendo com que a reprodução dos processos seja impedida. De acordo com estas informações, sistemas biométricos são largamente estudados pelas universidades no intuito de tornar os sistemas mais eficientes ou mais rápidos quando a aplicação é feita em bases de informações com alto número de usuários. (DIAS, 2009)

1.1 OBJETIVOS

Desenvolver um algoritmo biométrico de identificação de pessoas baseado nos padrões de veias das mãos para aplicação no controle de acesso físico de pessoas em edifícios inteligentes.

1.2 JUSTIFICATIVA E HIPÓTESE

Os sistemas biométricos utilizam algoritmos matemáticos patenteados e suas estruturas não são expostas. Sistemas deste tipo apresentam alto custo e a proposta é de se desenvolver um algoritmo que possa identificar pessoas no controle de acesso em edifícios inteligentes.

1.3 METODOLOGIA DA PESQUISA

Todas as informações contidas nesta tese são provenientes de diversas fontes, descritas abaixo:

- a) Trabalhos de conclusão de curso, monografias, dissertações e teses da área de engenharia;
- b) Artigos científicos publicados em congressos nacionais e internacionais;
- c) Pesquisas na *internet*;
- d) Consulta a manuais de equipamentos já existentes;
- e) Consulta à normas e artigos de órgãos reguladores;
- f) Livros e revistas especializadas.

1.4 ESTRUTURA DO TRABALHO

O capítulo 1 apresenta a introdução do tema e o objetivo deste trabalho, com sua devida justificativa e estrutura.

O capítulo 2 apresenta como é constituída uma automação predial, com detalhes sobre sistemas de iluminação, controle de temperatura, sistemas de segurança (detecção e combate a incêndios, segurança interna e perimetral, circuitos fechados de televisão, e redes de comunicação para interligar os diversos dispositivos), e ainda o controle de acesso, detalhando os sistemas de identificação por cartões, enfocando no fim do capítulo a análise dos sistemas biométricos.

O capítulo 3 apresenta o tema escolhido para estudo e sua devida revisão bibliográfica que consiste no desenvolvimento de um sistema biométrico para controle de acesso de pessoas em edifícios inteligentes utilizando os padrões de veias das mãos.

O capítulo 4 apresenta o desenvolvimento do trabalho (materiais e métodos) que é a criação de um novo dispositivo biométrico capaz de realizar a captura de imagens infravermelhas das mãos para obter imagens das veias e a análise matemática destes dados para a devida identificação de pessoas. Ainda são apresentados os algoritmos para equalização de contraste das imagens, para classificação dos dados e para validação dos resultados utilizando técnicas de predição.

O capítulo 5 apresenta os resultados e discussões sobre cada técnica aplicada ao estudo desta tese.

O capítulo 6 conclui o estudo realizado, apresentando as principais características do projeto proposto nesta tese, com os resultados finais e as conclusões.

2 AUTOMAÇÃO PREDIAL E SISTEMAS DE SEGURANÇA

A automação predial constitui-se de diversos elementos como o efetivo controle de iluminação, controle do ar ambiente (visando tanto conforto quanto eficiência energética), sistemas de segurança que incluem detecção e combate a incêndios, segurança interna e perimetral, sistemas de vigilância por câmeras, controle de acesso físico através do uso de leitores de cartões instalados em catracas e torniquetes ou leitores biométricos e a integração de todos estes sistemas através de redes de comunicação com seu devido controle de acesso lógico. (IPOG, 2013)

Todos estes tópicos são comentados abaixo:

2.1 CONTROLE DE ILUMINAÇÃO

O controle de iluminação em edifícios inteligentes pode se caracterizar por três fatores fundamentais: Segurança, redução dos recursos naturais utilizados (eficiência energética) e conforto. Quanto à segurança, o controle efetivo da iluminação em corredores, salas, e locais onde as pessoas possam circular livremente pode prevenir acidentes, e em áreas externas, pode prevenir assaltos ou outros quaisquer tipos de atos de violência. Quanto à eficiência energética, a economia de energia é realizada através do uso de lâmpadas que consomem menos energia, como por exemplo os LEDs ou até o uso de lâmpadas inteligentes do tipo HUE (do inglês “matiz”) que podem ser controladas remotamente utilizando aparelhos celulares ou qualquer outro equipamento de comunicação, atendendo assim além da diminuição do consumo de energia, o conforto do usuário. (PHILIPS, 2014; PINTO; MORAES; BRANDÃO JR, 2000)

O controle da iluminação externa com enfoque na estética predial (iluminação de jardins, paredes ou outras estruturas) normalmente é realizada utilizando sistemas baseados em LEDs, e a fonte principal de energia é obtida através da captação de luz solar por placas específicas. Nestes sistemas, as placas solares, conhecidas tecnicamente por painéis fotovoltaicos, convertem a luz em energia elétrica, e esta é armazenada em baterias. Durante a noite, sensores de luz (normalmente compostos por *Light Dependent Resistor* (LDR) devido ao seu baixo custo) fazem com que controladores liguem automaticamente os conjuntos de iluminação. Apesar da finalidade destes sistemas ser puramente estética, o efetivo controle dos mesmos e a utilização de sistemas que aproveitam a luz solar ou outro qualquer tipo de grandeza que possa ser convertida em energia elétrica caracteriza um sistema de eficiência energética. Os circuitos responsáveis por captação da energia proveniente das placas solares e devido armazenamento nas baterias podem ser simples controladores de corrente ou circuitos mais complexos como por exemplo placas com lógica *fuzzy* para aproveitamento máximo da luz

solar em qualquer condição de luminosidade ou até por redes neurais artificiais no controle de sistemas de iluminação híbridos. (CARDOSO; AO, 2008; WANG; WU, 2011)

2.2 CONTROLE DE TEMPERATURA - AR CONDICIONADO

Os equipamentos basicamente são compostos de uma unidade evaporadora e uma unidade condensadora, responsável pela circulação do gás refrigerante. A unidade condensadora contém o compressor que faz com que o gás refrigerante circule pelo sistema. Ao passar por estrangulamento antes da unidade evaporadora, o gás aumenta sua velocidade e causa resfriamento de uma serpentina de cobre, em seguida um ventilador força a passagem de ar por esta serpentina, resfriando-o e lançando-o no ambiente a ser controlado. Ao fazer isto, o fluido refrigerante se aquece, e é resfriado na unidade condensadora. Para que este mesmo equipamento aqueça um ambiente, é feita a inversão do fluxo de gás, fazendo com que o mesmo chegue aquecido à unidade evaporadora. O princípio de funcionamento praticamente não mudou nos últimos dez anos, apenas o gás refrigerante foi modificado, pois desde 1932 utilizava-se o gás 22 Clorofluorcarbono (CFC) mais conhecido como *Freon*, e devido a sua propriedade de destruir a camada de ozônio, o mesmo deixou de ser utilizado nos anos 90. A partir de 1996, o protocolo de Montreal obrigou o uso do gás R134A Hidroclorofluorcarbono (HFC) e o 600A Hidrocarbono (HC) em sistemas de ar condicionado domésticos e de pequeno porte, e o mesmo agora começa a ser trocado pelo gás 1234YF Tetrafluorpropano (HFO), pois este é dissipado na atmosfera em apenas 11 dias, enquanto que os outros demoram a se dissipar aumentando dessa forma o efeito estufa e prejudicando o meio ambiente. O critério de automação mais importante nesta área é a introdução do controle de velocidade dos motores acoplados ao compressor dos equipamentos de ar condicionado. Nos sistemas convencionais, a partida do motor é direta, causando forte ruído e altíssimo consumo de energia elétrica, enquanto que nos modelos atuais disponíveis existem os modelos *inverter*, que utilizam inversores de frequência para o controle de partida e rotação destes motores, diminuindo assim o ruído gerado e o consumo de energia. (SILVA; SILVA, 2008)

2.3 SISTEMAS DE DETECÇÃO E ALARMES A INCÊNDIOS

Uma das normas a serem obedecidas em instalações prediais é a NBR17240 que diz respeito ao sistema de detecção e combate ao incêndio. Segundo a norma, trata-se de um conjunto de equipamentos capazes de detectar princípios de incêndio, seja por verificação de calor ou por presença de fumaça, indicar às pessoas a existência da situação de risco através do acionamento de indicações sonoras e visuais, e ainda controlar os sistemas automáticos para

o devido combate do incêndio. (PINHEIRO, 2010)

O conjunto de equipamentos normalmente utiliza um controlador dedicado que pode ser microcontrolado e os diversos sensores são instalados em forma de laço (topologia em anel) que devem ter número máximo de vinte dispositivos por laço segundo a norma, retornando sinais provenientes do campo em que estão instalados, e estes devem ser capazes de:

- a) Gerar sinais de alerta tanto para os usuários do local quanto das corporações públicas responsáveis pelo combate do incêndio;
- b) Orientar adequadamente os usuários sobre as possíveis rotas de fuga disponíveis;
- c) Controlar os níveis de água dos sistemas de armazenamento próprio para combate de incêndios, assim como controlar a pressão mínima do sistema;
- d) Desligar os sistemas elétricos evitando assim que curto-circuitos possam aumentar ainda mais os incêndios;
- e) Os elevadores devem ser posicionados no andar diretamente abaixo do incêndio para evitar que o fogo suba pelo poço, ou ainda posicionar o elevador no primeiro andar evitando assim que os usuários possam utilizá-lo ficando presos após desenergização do local;
- f) Ligar nas escadas sistemas de insuflamento de ar para que os usuários possam respirar nestes locais de fuga;
- h) Ligar e controlar bombas que deverão pressurizar a linha de água para combate ao incêndio. (JÚNIOR, 2013)

Diversos dispositivos podem ser utilizados para a devida detecção de incêndio. Os principais sensores utilizados são: detectores de temperatura, detectores velocimétricos, detectores lineares, detectores de fumaça, detectores por aspiração e detectores *Multisensor*.

2.4 SISTEMAS DE SEGURANÇA PERIMETRAL E INTERNA

Os sistemas de segurança perimetral e interna visam a proteção dos locais através da detecção de possíveis invasões, distinguindo fatores de risco de outros fatores como a presença de animais ou movimentação de plantas e árvores. Estes devem ter pequenas dimensões de modo que sua presença não seja notada ou, se expostos, devem possuir características que impeçam seu desligamento indevido ou ainda sua obstrução para que o ato criminoso não seja detectado, e devem ser robustos o suficiente para instalação externa sob condições de intempérie.

Existem diversos sensores para esta finalidade, e os principais são: volumétricos, piezoe-létricos, de movimento em vídeo, magnéticos, piroelétricos, detectores de quebra de vidro, infravermelho ativo, micro-ondas e por análise de aproximação utilizando campo magnético.

2.5 CIRCUITOS FECHADOS DE TELEVISÃO - CFTV

Os sistemas de de captura de imagens conhecidos por CFTV, são compostos por câmeras digitais ou analógicas instaladas no local onde se deseja aumentar o nível de segurança. Podem possuir cabos ou podem emitir suas imagens via radiofrequência, sem a necessidade de passagem de cabos. Os principais tipos de instalação destes equipamentos se baseiam na instalação física utilizando cabo coaxial em sistemas com câmeras analógicas, e o armazenamento destes dados é feito por equipamentos analógicos, como videocassetes gravando imagens em fitas de vídeo VHS, enquanto que seletores e multiplexadores fazem a divisão das imagens das câmeras; em equipamentos modernos os sistemas são digitais e as câmeras *wireless* ou ainda câmeras *Internet Protocol* (IP) que utilizam cabo par trançado *Unshielded Twisted Pair* (UTP) e conectores *Registered Jack 45* (RJ45) para instalação (padrão *Ethernet*) são largamente utilizadas, e neste caso, podem fazer parte de uma rede de dados corporativa, considerando as câmeras como *hosts* do sistema, por possuírem protocolo IP e permitirem endereçamento individual para cada câmera. (GUIA DO CFTV, 2012)

2.5.1 Sistemas analógicos

Os principais acessórios que compõem estes sistemas são o *quads* que permitem a visualização de quatro imagens simultaneamente, permitindo a geração destas em um monitor para que uma pessoa possa monitorar o ambiente a ser controlado. Além deste, existe o *Time Lapse* que é um vídeo cassete dedicado a sistemas CFTV, capazes de armazenar até 960 horas de imagem em uma única fita VHS, e os multiplexadores que são *quads* mais poderosos, permitindo até dezesseis câmeras ligadas simultaneamente e sendo monitoradas em tempo real numa única imagem. O equipamento *sequential* permite que as imagens sejam trocadas câmera a câmera em um tempo pré-determinado. (GUIA DO CFTV, 2012)

2.5.2 Sistemas digitais

A principal diferença nestes sistemas é a captação das imagens e seu devido armazenamento. Câmeras digitais podem enviar suas imagens diretamente a um computador e este irá armazenar a informação em *Hard Disk* (HD). As câmeras digitais possuem uma resolução muito superior quando comparadas com as câmeras analógicas e o armazenamento das informações não é prejudicado, pois apesar de se tratar de informações muito maiores por estarem em um computador, passam por técnicas de compressão de dados antes de seu devido armazenamento. Existem sistemas digitais de grande porte que armazenam os dados em fitas *Digital*

Audio Tape (DAT), e em sistemas mais atuais, em HDs do tipo *Solid-State Drive* (SSD). As principais vantagens dos sistemas digitais são a alta qualidade das imagens capturadas, possibilidade de monitoramento remoto utilizando a *internet* como meio físico e acessando as imagens por meio de computadores ou *smartphones*; busca de imagens com maior facilidade em um banco de imagens pois esta é realizada por eventos; geração de relatórios; utilização de *softwares* que detectam movimento; proteção dos sistemas por senha e integração com outros sistemas de segurança. (GUIA DO CFTV, 2012)

2.6 REDES PARA AUTOMAÇÃO DE PRÉDIOS INTELIGENTES

Diversos protocolos de comunicação são utilizados para comunicação de dispositivos de automação predial no intuito de integrar todos os equipamentos e disponibilizar informações aos usuários, e estas informações podem ser de segurança ou de conforto. Dentre vários protocolos utilizados, os mais comuns são o *Building Automation and Control Networks* (BACnet) e o *Local Operating Network* (LONworks). Os meios físicos mais utilizados são o cabeamento elétrico de cobre, fibra ótica e o próprio ar em sistemas *wireless* utilizando os protocolos *Zigbee*, protocolos baseados nas normas IEEE 802.11 e *Zigwave*. (MONTEBELLER, 2006)

Em sistemas modernos conhecidos como *Free Space Optics* (FSO), a transmissão dos dados pode ser realizada pelo ar com o carregamento das informações em feixes de luz ou *laser*, no mesmo princípio de funcionamento da fibra ótica sem a existência da própria fibra, sendo um recurso a ser usado em locais onde a passagem de cabeamento é impossível ou difícil de ser implementada. (CARDOSO; BRANDÃO JR, 2007)

2.7 CONTROLE DE ACESSO EM EDIFÍCIOS INTELIGENTES

Em edifícios inteligentes automatizados, os principais sistemas de controle podem ser divididos em duas categorias distintas, a seguir:

a) Acesso físico: são os sistemas de catracas, torniquetes e outros dispositivos utilizados para o controle de acesso das pessoas. Nestes ambientes, o controle do acesso físico pode ser realizado pela abordagem de um agente de segurança que visa identificar corretamente a pessoa e verificar se esta tem permissão para entrar no local;

b) Acesso lógico – diversos sistemas informatizados utilizam redes sem fio e o acesso a estes deve ser controlado através da digitação de senhas ou de identificação de pessoas por sistemas biométricos (normalmente realizados por equipamentos portáteis).

Em ambos os casos, o controle utiliza diversos tipos de recursos e os mais utilizados são os sistemas com cartões inteligentes e biometria para identificação ou autenticação da pessoa.

Neste trabalho, serão apresentados os dois sistemas com enfoque na biometria, pois trata-se da proposta principal de desenvolvimento da tese.

2.7.1 Cartões inteligentes

Em sistemas de controle de acesso, ainda são usados cartões com código de barras e cartões com tarjas magnéticas, no entanto, estes apresentam alta vulnerabilidade, pois os códigos de barras podem ser gerados facilmente em *sites* da *internet* com o conhecimento do número registrado no crachá, que em muitos casos trata-se do número de registro do colaborador da empresa, número este que pode estar estampado no próprio crachá facilitando o acesso a esta informação, e a tarja magnética perde seus dados quando em contato com equipamentos que possam gerar algum tipo de campo magnético, como por exemplo o telefone celular. Para resolver estes problemas, o Dr. Kunitaka Arimura patenteou o primeiro cartão inteligente em 1970 no Japão, e este consistia basicamente de um plástico no formato de um cartão de crédito ou cartão para acesso de contas bancárias, e em seu interior, um microprocessador e memória para armazenamento e devido processamento dos dados do usuário, e estes ainda podiam possuir contatos elétricos para acesso às informações com vida útil média de 10000 acessos ou ainda realizarem o acesso via redes de comunicação sem fio. (MAMMASS, 2011)

Os dois principais materiais utilizados para a construção destes cartões são o *Polyvinyl chloride* (PVC) (não são recicláveis mas podem ser moldados) e o *Acrilonitrila butadieno estireno* (ABS) (podem ser reciclados mas não são moldáveis), e em seus interiores estes são divididos entre duas categorias, sendo os primeiros que utilizam apenas memória para armazenamento de dados de identificação do usuário (normalmente *Electrical-Erasable Programmable Read-Only Memory* (EEPROM) ou *Flash Erasable Programmable Read-Only Memory* (EPROM)) e os cartões que utilizam além de memória, microprocessadores e microcontroladores capazes de realizar operações. Estes são chamados de *Smartcards memory* e *Smartcards processor*, respectivamente. A área de contato elétrico do cartão *smartcard* é definida pelo norma ISO/IEC 7816. (AENDENROOMER; HUANG, 2007)

Quanto aos cartões sem contato elétrico, a identificação dos dados é feita através de rádio frequência conhecido pelo seu termo em inglês *Radio Frequency Identification* (RFID) sobre proximidade de um equipamento leitor em até 10 centímetros, e são normalizados pela ISO/IEC 14443. São muito utilizados no transporte público e no controle de acesso por catracas que possuem leitores para este tipo de cartão. Ainda existem cartões que conseguem enviar sinais aos equipamentos leitores em distâncias de até um metro, normalizados pela ISO/IEC 15693. (THOMASSON; BALDI, 1997)

2.7.2 Biometria

Biometria é uma palavra proveniente do grego que significa “medida da vida” e consiste basicamente em medições de características humanas, que podem ser tanto físicas quanto comportamentais e são utilizadas para identificação de pessoas. Através de sistemas biométricos é possível efetuar a devida identificação de uma pessoa, utilizando para isto a impressão digital, geometria da face, geometria da mão, textura da íris, textura da retina, padrão de voz, padrão de assinatura, tanto dinâmica quanto estática, padrão de veias das mãos e pulsos, código genético *Deoxyribonucleic Acid* (DNA), entre outros. (BROMME, 2003)

Os diversos equipamentos existentes baseiam-se em sensores capacitivos, indutivos ou óticos, e câmeras de baixo custo, todos utilizados para a aquisição de algum tipo de imagem ou característica comportamental ou física do indivíduo, e são largamente utilizados em sistemas de segurança para o devido controle de acesso, que pode ser físico ou lógico. (PINHEIRO, 2008)

Os seguintes critérios devem ser atendidos para que uma característica comportamental ou física seja considerada uma técnica biométrica válida para uso em sistemas de identificação:

- a) Universalidade – todos os seres humanos devem possuir a característica em análise;
- b) Distinção – a característica em questão deve ser diferente de pessoa para pessoa;
- c) Permanência – durante a vida do indivíduo, esta característica não deve ter mudanças, ou se existirem, devem ser mínimas;
- d) Coletabilidade – deve haver algum tipo de processo ou equipamento que consiga realizar a leitura e armazenamento desta característica.

Quanto à qualidade do sistema adotado, existem ainda outros parâmetros a serem considerados, como:

- a) Desempenho – a aquisição da característica e seu devido processamento devem ter tempos razoáveis para uso comercial;
- b) Aceitabilidade – o método de aquisição destas características deve ser aceito pelo usuário do sistema (menos invasível possível);
- c) Segurança – o sistema deve ser robusto o suficiente para evitar possíveis fraudes. (MATYAS V.; RIHA, 2003)

Em sistemas biométricos, é comum a utilização dos termos Autenticação e Identificação. Estes dois métodos distintos são explicados a seguir:

- Autenticação Biométrica – Modo 1:1

O sistema primeiramente identifica o usuário através do uso de um crachá com código de barras, por um cartão magnético, crachá com *tag* do tipo RFID ou qualquer outro dispositivo

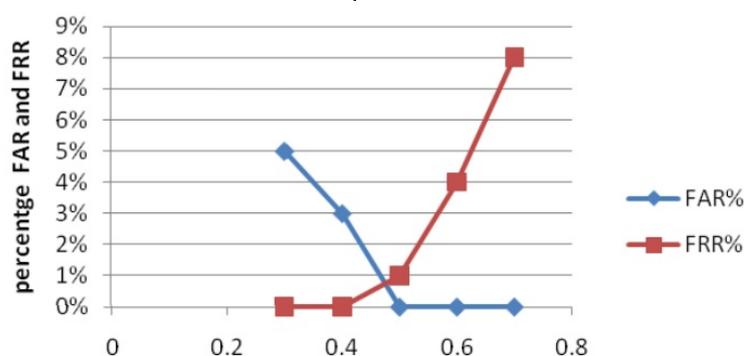
de propriedade do usuário, (este dado contido no dispositivo é comumente conhecido como *Personal Identification Number (PIN)*) e a partir desta identificação, é feita a aquisição da característica biométrica do indivíduo para efetuar a comprovação de que se trata da mesma pessoa. Nestes sistemas, a biometria não é utilizada para identificação, e sim apenas para validação de que o processo de identificação é consistente. A velocidade deste tipo de sistema é muito alta, pois é apenas realizada uma validação cruzada entre dois dados (um dado armazenado anteriormente e o dado momentâneo usado na autenticação), e não em um banco de dados completo.

- Identificação Biométrica – Modo 1:N

O sistema biométrico extrai a característica da pessoa sem identificação prévia, e procura em um banco de dados a similaridade mais próxima desta característica na tentativa de validar a identificação. Nestes sistemas os algoritmos trabalham com taxas de coincidência e o programador do sistema escolhe a probabilidade estatística de validação, ou seja, a partir de qual porcentagem de acerto pode ser definida a aceitação do indivíduo. Se este valor for muito baixo, o sistema passa a validar identificações mesmo de pessoas não cadastradas e se este valor for muito alto, o sistema passa a rejeitar a identificação mesmo de pessoas cadastradas. Estes índices em biometria são conhecidos como falsas taxas de aceitação (*False Acceptance Rate (FAR)*) e falsas taxas de rejeição (*False Rejection Rate (FRR)*), e em todos os sistemas biométricos, o que se busca como sistema ideal é o ponto limiar entre estes dois índices, também chamado de ponto de *threshold*. A taxa de erro igual (*Equal Error Rate (EER)*) é exatamente o ponto de *threshold* ideal onde a FAR é igual a FRR, e define a qualidade do sistema biométrico em estudo, ou seja, quanto menor a taxa EER, melhor é o sistema. (JAIN et al., 2004)

A Figura 2 abaixo apresenta um exemplo de curva onde são apresentados estes índices:

Figura 2 - Curva de análise da qualidade de um sistema biométrico



Fonte: (INSANKEOVILAY; PRASARN; CHOOMCHUAY, 2011)

Os sistemas biométricos são selecionados pelo critério da segurança a ser adotada no local, tempo de resposta do sistema, aceitabilidade por parte dos usuários (métodos invasivos e não

invasivos), custos do sistema, facilidade de instalação e manutenção do sistema, e confiabilidade. (JANES et al., 2008)

2.7.2.1 Reconhecimento da impressão digital

A impressão digital é uma das técnicas de identificação biométrica mais utilizadas no mundo desde o fim do século XIX, inclusive em análises forenses. Os equipamentos utilizados capturam imagens dos dedos, normalmente indicador (o polegar é pouco utilizado) e a partir desta imagem, analisa as suas características, conhecidas como minúcias (relatada em diversos trabalhos como “*minutiae*”). Estas minúcias são reconhecidas e então algoritmos são aplicados para transformar estas posições em informações digitais. Como a imagem a ser adquirida é de baixa dimensão, os equipamentos costumam ter baixo custo e são relativamente pequenos, inclusive passíveis de serem instalados em *laptops*, aparelhos celulares e outros equipamentos eletrônicos onde é necessária a identificação do usuário para o devido controle do acesso lógico. Algumas fechaduras eletrônicas também dispõem de um leitor de impressões digitais para abertura das portas, e estes sistemas são usados tanto para a automação residencial quanto para uso comercial, como a abertura de salas de servidor de informática. (JANES, 2009; ZHAO et al., 2013)

Os principais algoritmos são baseados na esqueletonização da imagem, ou seja, após a captura da imagem, a mesma passa pela etapa de normalização que consiste em aplicação de filtros para melhoramento de contraste, transformação de imagem colorida em imagem apenas com tons de cinza, extração de região de interesse com correção indevida de rotação, aplicação de técnicas de *threshold* e em seguida extração das linhas que formam a impressão digital. A partir destas linhas, o algoritmo as digitaliza, considerando sua espessura unitária, e então verifica a presença das terminações, núcleo, bifurcações e deltas, e cria informações digitais que serão utilizadas para identificação da pessoa. (BALTI; SAYADI; FNAIECH, 2012)

As principais vantagens destes sistemas são o baixo custo, como já comentado, a facilidade de utilização por parte dos usuários e a alta divulgação do sistema, fazendo com que as pessoas tenham alta aceitabilidade, no entanto, alguns fatores podem afetar o desempenho da tecnologia, como pequenos ferimentos nos dedos, ressecamento ou sujeira que podem causar falsas rejeições. Ainda existem os problemas de contaminação, pois o equipamento necessita do toque do usuário para a coleta da imagem, e em diversos países asiáticos existe alta rejeição por sistemas deste tipo devido ao alto risco de contaminação, como por exemplo a gripe aviária, vírus H1N1, vírus H7N9, conjuntivite, entre outros. (CAPPELLI et al., 2006)

Recentemente no Brasil, foram adotados sistemas de coleta de impressão digital e seu uso na identificação de pessoas para o controle de votação eleitoral pelo *Tribunal Superior Eleitoral*

(TSE), mas os sistemas ainda não abrangem todas as cidades, estão em fase de testes em algumas regiões do país, e de acordo com informações do próprio TSE, o sistema está sendo considerado extremamente eficiente no que diz respeito à correta identificação das pessoas. (TSE, 2014)

Ainda no Brasil, sistemas semelhantes foram implantados para o controle de treinamento prático por pessoas que pretendem adquirir carta de habilitação, e diversos relatos de fraude utilizando dedos falsos feitos com silicone pré-moldado foram relatados pela imprensa. (JANES; BRANDÃO JR; DIAS, 2010; FORUM BIOMETRIA, 2014)

2.7.2.2 Reconhecimento da íris

A ideia inicial sobre o uso da textura da íris como característica biométrica importante na identificação de pessoas partiu de Frank Burch em 1936, e a partir desta ideia, James Daggarts documentou a teoria em 1949. No entanto, o uso da textura da íris como padrão biométrico só foi realmente patenteado em 1987 pelos oftalmologistas Aran Safir e Leonard Flom. (NAROTE et al., 2006)

O uso desta técnica como ferramenta para identificação de pessoas foi implementado pela primeira vez pelo pesquisador da Universidade de *Cambridge*, John Daugman, que criou um algoritmo baseado na transformada de *Wavelet* e o uso do filtro de *Gabor* em 1993 para a extração das características da íris, chamado pelo autor de *íris code*, que tratava-se de uma sequência de 256 *bytes* para a representação da íris. As imagens das íris capturadas por Daugman eram expostas à luz infravermelha de espectro próximo, pois segundo o mesmo, este tipo de iluminação revela mais características de textura do que quando vista a olho nu. (DAUGMAN, 2001)

A partir desta data, diversos outros autores elaboraram trabalhos semelhantes para o uso da íris como característica biométrica, como a criação de equipamentos para automação do processo de identificação, mas praticamente todos os trabalhos posteriores tem como base a proposta de Daugman. (LI; SAVVIDES, 2013)

A íris é um tecido que faz parte do olho humano, com pigmentação específica para cada pessoa (com exceção de albinos) e trata-se de uma rede de filamentos cruzados formados por volta do oitavo mês de gestação, e estabelece-se em cor aproximadamente um ano após o nascimento. Considerando a estrutura do olho, a íris fica localizada entre o cristalino e a córnea, portanto, é uma região protegida de agentes externos pela presença da córnea sobre a mesma. No centro da íris, localiza-se a pupila, e esta por apresentar dilatação de acordo com a quantidade de luz sobre o qual o olho é exposto, acaba fazendo com que as dimensões visíveis da íris variem. Na estrutura da íris localizam-se os músculos responsáveis por realizar

esta movimentação da pupila, fazendo com que a quantidade de luz que entra no olho humano e atinge a retina seja controlada. A íris possui cores e texturas diferentes mesmo entre olhos direito e esquerdo da mesma pessoa, e em sua composição é possível verificar diferenças entre glândula, sardas, filamentos, coroas, estrias e sulcos radiais, fazendo com que a mesma seja praticamente única quando comparadas as íris de diversas pessoas, portanto, a mesma possui alto potencial de aplicação em sistemas biométricos por ter a probabilidade de se encontrar duas íris iguais de 10^{78} . (DAUGMAN, 2002)

Os equipamentos que realizam a leitura da íris são capazes de identificar uma pessoa mesmo com o uso de lentes de contato, mas é indicada a retirada de óculos escuros, principalmente os que possuem lentes polarizadas no momento da aquisição da imagem, pois estes podem modificar a imagem a ser analisada. O algoritmo criado por Daugman (2007) analisa cerca de 600 pontos de características da íris, enquanto que em outros sistemas biométricos, como por exemplo a impressão digital, esta quantidade de minúcias é da ordem de 50 pontos, mostrando assim que se trata de uma tecnologia cerca de 12 vezes mais precisa que a análise da impressão digital. O processo de identificação de uma pessoa através do uso da íris consiste em:

- a) Detectar a presença do olho na imagem, usando como referência as pálpebras superior e inferior;
- b) Definir os limites da íris, usando sua borda externa e a pupila como referência;
- c) Excluir pálpebras, cílios e outros componentes que não fazem parte da íris;
- d) Extrair as características da íris e armazenar estas informações em um banco de dados.

A partir do armazenamento das características no banco de dados, é feita a comparação do padrão armazenado com o padrão da pessoa a ser identificada, e o algoritmo usado por Daugman é a distância de *Hamming*. (DAUGMAN, 2007)

2.7.2.3 Reconhecimento da face

A tecnologia de reconhecimento da face tem alta aceitação pelas pessoas devido o método não ser intrusivo, pois para captura são utilizadas câmeras convencionais, que podem ser fotográficas ou filmadoras e representam uma aplicação de baixo custo. Por parte dos órgãos de defesa e justiça, também é um sistema interessante pois pode-se verificar a identidade de uma pessoa sem que ela saiba que está sendo analisada, como por exemplo na tentativa de identificação de terroristas em aeroportos ou no controle de travessia de pessoas em fronteiras. Diferenças na face devido à idade, presença de barba, óculos e outros objetos, assim como a variação da fisionomia da pessoa podem afetar o nível de segurança na identificação (o mesmo rosto cadastrado com fisionomia normal pode gerar futuramente imagens da pessoa sorrindo, triste, chorando, nervosa, enfim, diversas outras possibilidades que levam ao sistema geração

de falsa rejeição).

A técnica consiste em identificar pontos específicos no rosto definidos no *software* de análise como os cantos da boca, cantos dos olhos, nariz e suas bordas, sobrancelhas, medidas da largura e altura do rosto (entre orelhas e entre queixo e cabelo, respectivamente), espessura dos lábios, orelhas, e todas as relações entre estas áreas. Após a captura da imagem, são extraídos os coeficientes necessários à identificação de uma pessoa e estes dados são armazenados em um banco de dados para futura comparação. As análises biométricas podem ser realizadas por um único algoritmo ou por aplicação de múltiplos algoritmos, tanto em duas dimensões da imagem quanto em três dimensões, sendo que o primeiro método é menos eficaz e mais sujeito a fraudes, pois uma fotografia da pessoa pode ser utilizada na identificação, gerando uma falsa aceitação pelo dispositivo, enquanto que no método de análise tridimensional, o sistema tem muito mais robustez mas necessita de equipamento específico, aumentando assim seu custo, e aumentando também o nível de intrusão (necessita de conhecimento por parte do usuário para geração correta da imagem). (ACHERMANN; BUNKE, 1996)

Como qualquer dispositivo eletrônico construído com uma câmera pode efetuar capturas de imagens, existe a possibilidade de se utilizar um equipamento que contenha uma câmera e ter sua imagem capturada para futura análise sem o consentimento do usuário, caracterizando assim uma possibilidade de ato criminoso. Atualmente, existem diversos relatos da criação de um banco de dados de faces capturadas pela empresa *Facebook* (projeto *Deep Face*) através do uso das imagens colocadas no perfil do usuário do sistema, e ainda da captura de imagens de *softwares* gratuitos de reconhecimento facial para celulares, tanto para plataforma *iOS* quanto *Android*, e segundo especialistas, são analisadas cerca de 300 milhões de faces por dia sem o conhecimento do proprietário da imagem. (NETWORKWORLD, 2012)

2.7.2.4 Geometria das mãos

A proposta destes sistemas biométricos é de se utilizar a geometria das mãos como característica individual para reconhecimento de pessoas, baseando-se na hipótese de que ao menos em pequenas populações não existem mãos idênticas e que estas características não sofrem grandes mudanças ao passar dos anos. Apesar da proposta ser válida, sabe-se atualmente que diversos fatores modificam esta estrutura tornando o sistema vulnerável a fraudes e gerando falsas rejeições, como por exemplo a mudança de peso corporal, artrite, sujeiras, cortes e objetos como anéis e pulseiras. Como existem diversos fatores que tornam o sistema fraco, normalmente o mesmo é utilizado para autenticação, e a identificação é realizada através do uso de crachás ou outro documento que comprove a identificação pessoal. (SANCHEZ-REILLO, 2000)

O processo de captura das imagens consiste basicamente em um equipamento composto por câmera e conjunto de lentes e espelhos para que sejam capturadas imagens das mãos de forma tridimensional para posterior análise da largura das mãos, comprimento dos dedos, posições das juntas dos dedos, angularidades no eixo de cada dedo, área total e diversos outros pontos de análise. Estes pontos extraídos por um algoritmo específico são armazenados para verificação biométrica e normalmente ocupam pouco espaço para armazenamento, portanto se torna ideal em locais de grande acesso, como estádios e universidades, inclusive o sistema foi testado em grande escala pela primeira vez nos jogos olímpicos de 1996 para o controle de acesso à vila olímpica. (UFRJ - BIOMETRIA DA MÃO, 2009)

A principal desvantagem neste método é o posicionamento da mão no dispositivo e para resolver este problema, a maioria dos equipamentos contém pinos de alinhamento evitando assim que a pessoa consiga rotacionar as mãos no momento da aquisição da imagem.

2.7.2.5 Reconhecimento da voz

O reconhecimento da voz humana pode ser usado como característica biométrica pois o som da voz humana é gerado a partir da ressonância das cordais vocais, e o mesmo sofre influência das cavidades nasais e do formato da boca, portanto, gera uma característica única para cada indivíduo. No momento da aquisição da amostra, é importante que a pessoa não esteja com nenhum tipo de problema de saúde como por exemplo amigdalites, faringites, obstrução nasal, ou tenha feito algum tipo de tratamento odontológico recentemente, pois todos estes fatores irão influenciar no som gerado pelas cordas vocais no momento do armazenamento do padrão, e no futuro, quando o usuário for realizar a tentativa de identificação, serão geradas falsas rejeições. Outros fatores como nervosismo ou cansaço podem alterar o padrão de voz. (RASHID et al., 2008)

São usadas técnicas que dependem de pronúncia de textos específicos e outras que testam aleatoriamente o padrão da voz humana. Os sistemas dependentes de texto normalmente são usados em equipamentos comerciais para se obter acesso lógico a *softwares* e estes geram mensagens que devem ser lidas pelo usuário para análise da voz, e os sistemas independentes são usados para controle de acesso físico onde o usuário pode escolher falar uma frase específica pré-cadastrada. Em sistemas de automação residencial, este método é muito usado para acionamento de iluminação, controle de ar condicionado e acionamento de dispositivos de som através de comandos de voz, e não necessariamente para a identificação de pessoas, mas os algoritmos utilizados são os mesmos. (ALSHU'EILI; GUPTA; MUKHOPADHYAY, 2011)

O reconhecimento da fala é feito através da análise por série de *Fourier*, que extrai frequências específicas de cada pessoa, e a seguir estas informações são armazenadas em um banco

de dados para futura comparação. Como o cadastro de cada usuário consiste basicamente de um equipamento gravador com um microfone, estes sistemas são relativamente baratos, mas a confiabilidade é muito baixa, e as falsas rejeições são altas pois qualquer som do próprio ambiente pode alterar os resultados. Outra limitação do uso desta técnica está no fato de que a voz muda ao longo dos anos, normalmente se tornando mais grave devido ao relaxamento e enfraquecimento natural das cordas vocais, alterando assim o resultado da identificação, e o fato de que a voz de uma pessoa pode ser gravada previamente em um equipamento portátil e usada para identificação e posterior fraude no sistema. (CUI; XUE, 2009)

2.7.2.6 Reconhecimento da assinatura

Existem duas formas de se identificar uma pessoa através da assinatura, a análise da imagem estática após a assinatura ter sido realizada (método menos eficiente), e a análise dinâmica da assinatura. Nesta segunda proposta, equipamentos baseados em *scanners* de mesa compostos de diversos sensores que reconhecem o ângulo, direção e pressão da escrita (parecidos com *mouse pads*) realizam a medição do ato de escrever, que incluem pressão sobre o equipamento pela caneta, velocidade da escrita, ritmo, momentos em que a caneta não pressiona o leitor, como o usuário adiciona pontos e traços, momentos de pausa entre duas palavras e outros padrões específicos para cada pessoa. Estes dados são armazenados em um banco de dados e são utilizados para comparação no intuito de identificar o indivíduo. A maior utilização deste método está na verificação de assinatura de cheques por instituições financeiras. A maior desvantagem desta técnica é que a assinatura varia ao longo do tempo, poucas pessoas são consistentes com seu padrão ao longo dos anos, dessa forma, o sistema necessita de rearmazenamento do padrão periodicamente. (PLAMONDON; PARIZEAU, 1988; VIGLIAZZI, 2006)

2.7.2.7 Considerações sobre os principais algoritmos

Em todos os sistemas biométricos analisados nas seções anteriores que utilizam imagens como padrão biométrico, a abordagem espectral é realizada e baseia-se principalmente na aplicação da série de *Fourier* sobre a imagem capturada para a descrição de padrões em duas dimensões que podem ser periódicas ou não periódicas, analisando os padrões globais de textura da imagem tratada que apresentam alta energia no espectro resultante e as principais características usadas para montagem do padrão são picos no espectro responsáveis por fornecer a direção dos padrões da textura. A posição destes picos no espectro fornecem o período espacial e a eliminação de componentes no espectro que representam ruídos são feitos por

filtros sintonizados nestas regiões. Para a efetiva análise da imagem, são necessárias informações de diferentes locais da imagem, mas a série de *Fourier* analisa apenas o espectro global da frequência, dessa forma, foram criadas técnicas adaptadas de *Fourier* para o tratamento específico deste tema. As técnicas mais utilizadas são a transformada de *Wavelet*, *Ridgelet*, *Curvelet* e *Contourlet*. (GONZALEZ; WOODS, 2001)

3 RECONHECIMENTO DE PADRÕES DE VEIAS DAS MÃOS

O reconhecimento do padrão de veias é utilizado baseando-se no princípio da unicidade, ou seja, de que não existem duas pessoas com o mesmo padrão de veias (formato, posição e dimensão). Para que as imagens sejam capturadas, utiliza-se luz infravermelha com comprimento de onda entre $700nm$ e $1000nm$, que é capaz de atravessar a pele humana, mas é absorvida pela hemoglobina, tornando assim as veias facilmente identificáveis em uma imagem capturada por uma câmera infravermelha, pois as mesmas ficam escuras na imagem. (WANG; LEEDHAM, 2006)

Outro método de captura das imagens é a utilização de câmeras infravermelhas capazes de realizar a leitura de comprimentos de onda da ordem de $3\mu m$ a $14\mu m$ (espectro que o corpo humano irradia) para identificação das veias, no entanto, este processo é mais influenciado pelas condições do ambiente. (WANG; LEEDHAM, 2006)

3.1 INTRODUÇÃO

Como já comentado anteriormente, sistemas biométricos normalmente são patenteados e suas características não são divulgadas. O material divulgado normalmente é comercial, com ênfase no *marketing* do produto. A consulta sobre o tema então foi direcionada às instituições de ensino e congressos nacionais e internacionais, no intuito de analisar o que já foi escrito sobre o tema, para que não fosse realizado o desenvolvimento de um sistema já existente.

As principais bases nacionais informadas pela biblioteca da Escola Politécnica da Universidade de São Paulo foram consultadas e nenhuma monografia, dissertação ou tese foi encontrada com o tema específico de análise de padrão de veias das mãos. Alguns trabalhos tem outro enfoque e somente comentam este sistema biométrico como um pequeno tópico dentro da estrutura do trabalho.

Ao consultar então as bases científicas na busca de artigos publicados sobre o tema, foram encontrados a princípio 330 trabalhos. Não houve eliminação de artigos sobre o critério cronológico, todos foram consultados independente do ano de publicação. Após análise de seus *abstracts*, evidenciou-se que apenas 141 trabalhos tratavam o tema em questão, todos os outros 191 trabalhos eram resultados da área médica. Os 141 trabalhos foram lidos e avaliados na busca do estado da arte deste tema. As bases consultadas foram *IEEE Xplore*, *Elsevier Scopus* e *Springer*. As palavras-chave utilizadas na busca de material são descritas abaixo, e foram utilizadas em pesquisas avançadas, realizando o cruzamento das palavras, pois quando foram realizadas pesquisas simples, cada palavra-chave analisada de forma independente gerava mais de um milhão de resultados, dos quais a maioria não era pertinente ao tema específico:

- *Veins Pattern*;
- *Biometry*;
- *Biometric System*;
- *Access Control*;
- *Smart buildings*.

3.2 REVISÃO DA LITERATURA

A pesquisa sobre a identificação biométrica utilizando os padrões de veias das mãos teve início com o trabalho de Rice (1994) que apresentou uma breve explanação sobre o que é biometria, e em seguida detalhou sobre seu equipamento criado em 1990, mas comenta sobre ter registrado a patente em nome da *British Technology Group* (BTG). A proposta do autor é de iluminar a parte dorsal da mão com LEDs infravermelhos, e capturar imagens desta mão utilizando diodos fotossensíveis. A meta de sua pesquisa é que o equipamento consiga reconhecer e identificar adequadamente uma pessoa em até um segundo. O procedimento de registro é efetuado adquirindo duas imagens da mesma mão, e após isto, passam-se as duas imagens por uma lógica booleana ou-exclusivo, na tentativa de gerar uma terceira imagem só com as diferenças entre as duas primeiras. Após isto, é feita a binarização da imagem por um algoritmo matemático (não citado) e os dados são armazenados em um banco de dados, onde cada figura tem incorporado um cabeçalho com informações do indivíduo. O autor ainda cita que ao adquirir as imagens, utilizou um filtro chamado de *pepper and salt algorithm* na tentativa de melhorar a qualidade da imagem adquirida, e após pesquisa breve sobre este filtro, trata-se de um método utilizado para processamento de imagens com a finalidade de diminuir ruídos, mas que na verdade é utilizado normalmente para gerar ruídos suavizando a imagem. O método de binarização utilizado consiste em adotar *bits* lógicos "zero" para *pixels* da imagem com iluminação abaixo de cinquenta por cento e adotar *bits* lógicos "um" para *pixels* com iluminação acima de cinquenta por cento. Os resultados obtidos foram enviados para estatísticos independentes, para que pudessem levantar as características de falsa rejeição e falsa aceitação, e o autor comenta que os resultados foram encorajadores. O trabalho não referencia nenhuma fonte de informação, e não comenta sobre resultados numéricos ou processos algorítmicos utilizados neste levantamento. Após análise deste artigo, foram investigados trabalhos do mesmo autor e encontrada a patente registrada em 1984 mas publicada apenas em 1987 em nome do autor, comprovando assim a autoria do primeiro projeto envolvendo leitura de veias para aplicação em sistemas biométricos. (RICE, 1987)

Os autores MacGregor e Welford (1991) também apresentaram resultados da pesquisa sobre este tema. Os autores propuseram um sistema de identificação biométrica utilizando imagens da parte dorsal da mão, que diferentemente do autor Rice (1987), propuseram a iluminação usando um fio de tungstênio incandescente como fonte de luz infravermelha. O intuito da pesquisa era provar que as pessoas tem padrões de veias diferentes umas das outras, e para isto, construíram um sistema capaz de adquirir imagens, processar automaticamente estas imagens adquiridas e identificar a pessoa, e ainda estabelecer qual era a falsa taxa de aceitação FAR e a falsa taxa de rejeição FRR de seu equipamento. O trabalho dos autores utiliza um algoritmo que elimina todas as informações da imagem adquirida com exceção das veias, armazena estas informações e em seguida identifica a pessoa. Nenhuma destas técnicas é comentada, apenas cita-se a eficácia do equipamento mas sem finalidade comercial devido à complexidade de construção, pois as imagens adquiridas eram apresentadas em um *Visual Display Unit* (VDU) e plotadas manualmente em um acetato, e a iluminação era realizada com incidência de luz proveniente de um filamento de tungstênio, portanto, de acordo com a proposta inicial de se criar um sistema automático, o proposto pelos autores era realizado manualmente. Os mesmos autores MacGregor e Welford (1992) mostraram métodos mais eficientes de se plotar as imagens em acetato, mas ainda não tornou o equipamento comercial, no entanto, apresentaram resultados da comparação entre vinte imagens de diferentes mãos, provando que a similaridade entre elas era de apenas 0,45%.

Novos resultados de pesquisa foram apresentados por Hawkes e Clayden (1993) e sua proposta foi de utilizar as mesmas técnicas já citadas mas representando cada veia por um vetor em que sua posição e ângulo são armazenadas para representar as características do indivíduo. Apresentaram ainda um sistema de melhoramento do contraste da imagem para que a binarização pudesse ser realizada com mais eficiência, então propõem pela primeira vez o método de binarização de imagens. A segmentação e esqueletonização das imagens foram realizadas utilizando um algoritmo criado em linguagem "C" para simplificar a imagem e preservar apenas o formato essencial das veias, eliminando irrelevâncias. Vale comentar que binarização é o termo definido pelos autores como processo de transformação da imagem em *bits* que podem ser "zeros" ou "uns" através de técnica conhecida como *threshold* (limiar entre o que é um *pixel* preto e o que é um *pixel* branco), segmentação foi o termo utilizado para excluir tudo que não é de interesse na pesquisa sobre veias, como imagem do fundo e os ruídos, e esqueletonização é o termo usado para simplificar a espessura das veias em uma única linha média sobre o eixo das veias.

Mehnert, Cross e Smith (1992) comentaram em seu trabalho que perante a luz visível, a estrutura das veias não é facilmente discernível, e que esta estrutura varia significativamente dependendo de diversos fatores como idade, nível de gordura sob a pele, temperatura e umidade

do ambiente, atividade física durante a aquisição da imagem e posicionamento inadequado da mão no dispositivo leitor. Além disso, existem os fatores de contraste diferente entre estruturas da mão como músculos, sangue, nervos, ossos e ainda detalhes de pele como cicatrizes, pigmentação e presença de pêlos. A proposta do trabalho dos autores consiste em provar que as imagens adquiridas no espectro do infravermelho elimina praticamente todas estas variáveis, concentrando o contraste entre o que é veia e o que não é veia.

Dessa forma, após três anos os mesmos autores Cross e Smith (1995) propuseram um algoritmo capaz de segmentar a imagem automaticamente no momento da aquisição, obtendo uma representação média do eixo da mão, corrigindo assim o mal posicionamento. Após isto, a binarização da imagem é realizada e armazenada em uma matriz, que será utilizada como o padrão único de identificação da pessoa. Os mesmos sugerem nove passos para que o processamento seja realizado:

1. Atenuar ruídos e melhorar contraste da imagem;
2. Determinar o domínio da mão, eliminando fundo ou qualquer outro objeto;
3. Reduzir este domínio para um domínio de trabalho, utilizando técnica de erosão;
4. Remover pêlos, poros da pele e qualquer outro ruído, utilizando elementos de estruturação linear;
5. Normalizar a imagem, pois a mão apresenta curvatura e a iluminação sobre a mesma não se apresenta de forma uniforme;
6. Separar veias do restante da imagem;
7. Remover ruídos e preencher falhas, utilizando filtro sequencial alternativo *Alternating Sequential Filter* (ASF);
8. Criar uma linha fina média das veias, ignorando sua espessura (esqueletonizar a veia);
9. Podar segmentos indesejados, usando um algoritmo de poda automática para que os segmentos espúrios induzidos por sombras e grandes concentrações de pelos sejam eliminados, enquanto a veia dominante é aproveitada.

Todo o processamento é realizado em 120 segundos, fazendo com que o sistema seja inviabilizado para sistemas de controle com grande volume de usuários. Para corrigir a rotação da mão no momento da aquisição das imagens, os autores usaram um algoritmo que localiza uma veia horizontal ao lado direito da imagem e uma veia vertical abaixo da imagem para usá-las como vetores de referência e conseguir realizar a correção da rotação das mãos. Foram usadas

100 imagens de 20 usuários para realização dos testes, mas não foram concluídas informações sobre FAR e FRR. O enfoque principal deste trabalho está no alinhamento da imagem, mas o algoritmo utilizado não é descrito. Pode-se então afirmar que este foi o primeiro trabalho apresentado neste tema que realmente identificava de forma automática uma pessoa pelo padrão de veias das mãos. A ideia inicial de Rice (1987) só foi implementada de forma automática em 1995.

Após 5 anos sem evoluções sobre o assunto, os autores Im et al. (2000) publicaram os resultados de seu trabalho que propõe um algoritmo de extração do padrão de veias melhorado, que compensa a perda de padrões de veia na área de borda, e apresenta melhor desempenho em relação ao algoritmo existente, mas não cita qual é este algoritmo existente, nem o referencia a outro trabalho. Além disso, o trabalho propõe que o problema decorrente da natureza iterativa de filtragem de pré-processamento no algoritmo existente é solucionado com o projeto de um filtro que é processado apenas uma vez, fazendo com que a velocidade de reconhecimento seja aumentada (100ms para reconhecimento de uma pessoa) e redução da complexidade de *hardware* seja obtida. O algoritmo proposto é implementado com um dispositivo *Field Programmable Gate Array* (FPGA) e o FAR obtido é cinco vezes melhor do que o algoritmo existente (não se sabe a referência de comparação, do ponto de vista que os trabalhos publicados até então não comentaram estes valores para que este autor afirme sendo melhor) e fica evidente que a qualidade deste trabalho está no tempo de processamento, de apenas 100ms para os 120 segundos do trabalho citado anteriormente.

Os autores Lin e Fan (2004) propuseram um sistema com uma câmera infravermelha para capturar as imagens térmicas da parte dorsal da mão, coletando em seu trabalho 960 imagens provenientes de 32 voluntários, sendo 29 homens e 3 mulheres, utilizando para isto uma câmera *Infrared* (IR) com sensibilidade de 300nm a 500nm, do fabricante *Inframetrics Corporation*. Representações de imagens com multirresolução *Feature points of the vein patterns* (FPVP) são obtidas utilizando filtros *Multiresolution filter* (MRF) que extraem os pontos dominantes filtrando recursos diversos para cada FPVP. O filtro proposto nada mais é que uma melhoria do filtro *watersheed*, que impõe pontos sobre as regiões mais escuras de uma imagem. Os resultados apresentaram uma FAR de 2,3% e uma FRR de 2,3%.

Ainda no mesmo ano, os autores Tanaka e Kubo (2004) propuseram um sistema composto por câmera *Charge-coupled device* (CCD) modelo CV-15H para captura das imagens do padrão de veias das mãos, um conjunto de LEDs IR modelo SANYO SLR931A para iluminação da mão em questão e uma placa de vídeo para conexão da câmera a um microcomputador. O primeiro passo dos autores foi transformar as imagens adquiridas em padrões de cinza, no intuito de eliminar qualquer espectro de luz visível que possa ter passado pelo filtro. Em seguida, melhoram o contraste utilizando técnicas de normalização de histograma (não comentam o

algoritmo utilizado) e salvam a imagem em um padrão de 640x480 *pixels*. O trabalho se baseia essencialmente na criação de um algoritmo capaz de extrair informações da imagem, e os autores o chamam de correlação somente de fase, conhecido por seu termo em inglês *Phase Only Correlation* (POC) que trata-se de um processo contínuo similar à transformada *Fast Fourier Transform* (FFT). A pesquisa foi aplicada sobre imagens adquiridas de 25 pessoas, mas não existe a informação de quantas imagens foram obtidas por pessoa, durante a leitura do texto existe a impressão de que foi adquirida uma única imagem de cada pessoa, totalizando assim 25 imagens. Os resultados obtidos foram e FRR igual a 4% e FAR igual a 5,0191%. Se comparados os resultados do autor anterior aqui citado, a FAR e a FRR foram quase duas vezes pior. A contribuição deste trabalho está na indicação de uma câmera e do conjunto de LEDs propostos para a avaliação e possível utilização no protótipo utilizado nesta tese.

De acordo com Wang et al. (2006)^b o comprimento de onda da luz infravermelha que é absorvida pelo sangue humano está na ordem de 720nm a 1100nm, portanto, a proposta feita pelos autores foi de utilizar uma câmera CCD convencional para capturar as imagens e uma fonte luminosa com comprimento de onda de 850nm para iluminar as mãos em questão. A escala de cinzas gerada nas imagens captadas variam de acordo com o tempo de aquisição, intensidade da luz aplicada e tamanho da mão, portanto, as imagens devem inicialmente passar por um processo de normalização de escala de cinzas. O próximo passo foi extrair as informações baseando-se em um algoritmo de segmentação dinâmico que calcula a média e a variância dos pontos para em seguida realizar a binarização da imagem. A proposta do trabalho é baseada em um processo de extração multimodal, utilizando um classificador Euclidiano, um classificador baseado em distância (utilizado para tratar imagens comprimidas) e um classificador baseado em momentos invariáveis. Os resultados apresentados com este processo mostram que o sistema funciona, mas não apresentam as taxas de falso aceite e falsa rejeição pois foram utilizadas quinhentas imagens de mãos obtidas de 250 pessoas apenas como forma de provar a eficácia do algoritmo, sem que o processo tenha sido testado efetivamente. Outra característica importante que deveria ter sido exposta é o tempo de resposta do sistema, pois em processos multimodais, o tempo total de identificação pode ser alto a ponto de tornar a tecnologia inviável do ponto de vista de aceitabilidade pelo usuário.

O trabalho dos autores Watanabe, Tanaka e Iwata (2006) apresenta detalhes sobre a utilização da biometria por verificação do padrão de veias das mãos utilizando POC como sendo um método algorítmico capaz de extrair informações precisas das imagens obtidas mesmo quando existem irregularidades de iluminação, mas o ponto fraco desta tecnologia está no fato de não haver correções quando existe rotação da imagem. A proposta realizada pelos autores baseia-se na aplicação das transformadas de *Hough*, de *Fourier* e conversão logarítmica sobre as imagens obtidas, antes de realizar a binarização das mesmas. Após aplicação prática, con-

cluíram que para tornar o sistema robusto, basta utilizar a POC e a transformada de *Hough*, pois as transformadas de *Fourier* e a conversão logarítmica aplicadas no intuito de corrigir as rotações não apresentaram resultados que justificassem sua aplicação. Vale lembrar que o primeiro trabalho utilizando POC foi realizado pelos autores Tanaka e Kubo (2004) e que a proposta aqui foi de melhorar este algoritmo, mas isto os autores não comentaram como fizeram. A transformada de *Hough* foi utilizada por *Daugman* para a identificação da íris por se tratar de um componente circular, e este é o motivo da transformada ter o nome de circular de *Hough*, mas os autores não citam as características de se utilizar um algoritmo específico para círculos em imagens de mãos.

Os autores Wang e Leedham (2006) apresentaram resultados inéditos quanto ao processo de reconhecimento do padrão de veias das mãos. Os mesmos propuseram um algoritmo chamado de bacia hidrográfica (*watershed algorithm*) como sendo extremamente eficiente na fase de esqueletonização da imagem das veias, eliminando a etapa de segmentação e binarização proposto em outros métodos pois, segundo eles, a segmentação e binarização da imagem introduzem erros no processo, fazendo com que o algoritmo de reconhecimento indique falsas aceitações e rejeições. O processo de aquisição da imagem é similar aos outros propostos e comentados neste capítulo. Após armazenar a imagem em um banco de dados, os autores realizaram testes similares à de outros autores, segmentando a imagem na primeira etapa por métodos de limiaridade (utilizaram o algoritmo chamado de *local adaptive thresholding*) e em uma segunda etapa aplicaram dois métodos de esqueletonização da imagem obtendo resultados bastante parecidos (usaram os algoritmos *fast fully parallel thinning* e *fast parallel algorithm* propostos por Guo e Hall (1992) e Suen e Zhang (1984) respectivamente) e em seguida apresentaram o método proposto, mostrando que seu algoritmo é muito mais eficiente por eliminar a etapa de segmentação. O método proposto consiste em visualizar a imagem em três dimensões: duas coordenadas espaciais e níveis de cinza da imagem. Os resultados, apesar de satisfatórios, apresentam problemas citados pelos autores, pois quando duas veias se encontram muito próximas, o algoritmo as une transformando em uma única veia, e quando a imagem da veia não é discernível, o algoritmo simplesmente a elimina.

Segundo os autores Crisan, Tarnovan e Crisan (2007) um dispositivo de baixo custo para a aquisição das imagens pode ser construído a partir do uso de 18 LEDs infravermelhos modelo ELD-740-524 com pico de radiação em $740nm$ para iluminação da mão, instalados em três círculos concêntricos no mesmo local de instalação da câmera CCD. Percebe-se que os autores colocam a incidência direta de luz sobre a mão sendo que outros autores já citaram sobre a deficiência deste método, e não seguem a recomendação de se utilizar luz em uma posição adequada para a passagem por dentro da mão. O trabalho comenta que todos os algoritmos utilizados fazem parte do módulo *Vision*, que é parte integrante do software *Labview*[®] ver-

são 7, da empresa *National Instruments*, mas nenhum comentário adicional é realizado sobre qual algoritmo foi utilizado na fase de aquisição, melhoramento da imagem, segmentação, binarização, esqueletonização, armazenamento e reconhecimento, e não são apresentadas informações sobre resultados experimentais. A contribuição deste trabalho está na indicação do LED comercialmente utilizado para aplicação neste tipo de sistema biométrico.

Os autores Wang et al. (2007) realizaram um projeto multimodal utilizando duas câmeras, sendo que a primeira é responsável por adquirir uma imagem da palma das mãos, e a segunda câmera realiza a captura do padrão de veias da mesma mão. A primeira câmera é convencional, colorida de modelo JAI CV-M50IR e a segunda câmera é relatada pelos autores como sendo um equipamento específico para captura de imagens no espectro do infravermelho próximo. A proposta dos mesmos é fazer a identificação biométrica analisando a impressão digital da palma da mão e analisando ainda o padrão de veias das mãos. Não é citado no trabalho o processo de aquisição das imagens, pois deve ser realizada duas capturas ao mesmo tempo, e também não é analisada a possibilidade de rotação da mão no momento da aquisição. O reconhecimento do padrão é feito cruzando-se as duas imagens no intuito de ter uma única imagem proveniente dos pontos de intersecção entre as minúcias da impressão digital e das posições das veias, e o processo de melhoramento de contraste das características desta imagem é realizada utilizando transformada de *Wavelet* após a imagem ser tratada por filtro *Gaussian smoothing* (responsável por retirar ruídos da imagem). O algoritmo utilizado para extração das características da imagem é o *Principal Component Analysis* (PCA) e o *Linear Discriminant Analysis* (LDA) mas nenhum comentário adicional é feito sobre a funcionalidade e aplicação destes algoritmos, somente que todo o projeto foi realizado utilizando o *software Matlab*[®]. Em tratamento de imagens, estes dois algoritmos são comumente utilizados para analisar a variância de dados, e não para extrair características de imagens. Como se trata de um sistema multimodal, não existem parâmetros de comparação quanto aos resultados alcançados com relação aos estudos sobre biometria utilizando somente o padrão de veias das mãos, e os próprios autores colocam como dificuldade o tempo de processamento pois qualquer sistema unimodal se torna mais rápido.

O trabalho de Zhao, Wang e Wang (2007) diz respeito essencialmente à qualidade da imagem do padrão de veias das mãos e seu respectivo contraste com relação ao tipo de luz aplicada à mão e sua direção. Os autores relatam que o fato da hemoglobina absorver a luz no espectro infravermelho não é suficientemente razoável para definir um bom contraste em uma imagem, e que o efeito de espalhamento da luz infravermelha é muito mais significativa pois as diversas estruturas da mão apresentam diferentes índices de refração. Os resultados da tese de XiaoXia (2004) mostraram que os índices de refração são realmente muito maiores que os índices de absorção de luz, sendo que a $1064nm$, o infravermelho apresenta índice de absorção

de 9,77 nos músculos e 2,00 na hemoglobina, enquanto que na mesma frequência, os índices de refração são de 508,60 nos músculos e de 215,00 na hemoglobina. Ainda comentando sobre os autores citados no início do parágrafo, os mesmos fizeram testes quanto à qualidade de imagem quando a luz é penetrante na mão, quando é exposta diretamente sobre a mão e em ambos os casos, chamando este terceiro método de modo misto, e obtiveram como melhor resultado de contraste o modo penetrante, no entanto, este é o método que apresenta maior variação no histograma da imagem, necessitando correções por *software* para devida análise e como parte de seu trabalho, propõem um novo algoritmo redutor de ruídos. Comparam ainda os resultados de seu algoritmo com o filtro Gaussiano passa baixa (*Gaussian low-pass filter*) e provam através de seus resultados que sua proposta é mais eficiente. Como a luz utilizada é penetrante, aparecem nas imagens regiões mais claras e outras mais escuras, formando blocos totalmente disformes, e para a segmentação, escolhem utilizar um método já reconhecido, proposto em 2006 por Wang et al. (2006)^b e como método de reconhecimento de padrões, os autores citam sobre dois métodos muito utilizados em outros trabalhos, como os métodos de padrão local e padrão global, e adotam o padrão local modificado, conhecido como *Local Binary Pattern* (LBP). Os resultados apresentados foram basicamente obtidos pela proposta de análise da imagem com enfoque no espalhamento da luz, e não na absorção, pois as fases de filtragem, segmentação e reconhecimento utilizaram algoritmos já propostos por outros autores.

Ainda no mesmo ano, os autores Wang, Leedham e Cho (2007) apresentaram seus resultados de testes realizados sobre qual o tipo de luz mais adequada à aquisição de imagens de veias. Propuseram um sistema para captura de imagens no espectro de $8\mu m$ a $14\mu m$ sendo que este sistema consiste em utilizar técnicas de termografia, capturando as diferentes estruturas do objeto em questão, e é chamado de *Far Infrared* (FIR) e ainda um sistema para captura de imagens no espectro de $700nm$ a $900nm$ chamado de *Near Infrared* (NIR). Ainda apresentaram análises de qual seria a região mais interessante a ser utilizada em sistemas de identificação biométrica, e propuseram analisar dessa forma imagens da palma da mão, da parte dorsal da mão, do punho e dos dedos. Chegaram à conclusão de que a luz NIR é mais imune ao ambiente e que qualquer parte da mão pode ser utilizada.

No ano seguinte os autores Zhao e Wang (2008) apresentam inovações com relação aos trabalhos já publicados. A proposta é de se utilizar um equipamento com dois conjuntos de iluminação, sendo um para aplicação da luz diretamente sobre a mão, e outro do lado oposto da câmera, de modo que a luz atravessasse a mão. Para a extração de ruídos e melhoramento no contraste da imagem, os autores propõem o uso de um algoritmo adaptado da transformada de *Wavelet* conhecido como *Besov norm regularization*. A comparação feita com os filtros *Gaussian* e *Smoothing* mostram que a proposta feita aqui realmente melhora a qualidade das

imagens. No que diz respeito à segmentação da imagem, os autores propõem também um novo algoritmo adotado do trabalho de Wang et al. (2006)^b chamado de método de *threshold* dinâmico local. Os mesmos modificaram o algoritmo citado pois foi utilizado por Wang et al. (2006)^a em imagens adquiridas com iluminação sobre a mão, e no caso da aplicação de luz que penetra a mão, as imagens apresentam variações muito mais abruptas formadas por regiões claras e escuras. Para o reconhecimento dos padrões, foram propostos dois algoritmos que descrevem as veias como níveis. O primeiro algoritmo descreve a distribuição espacial do padrão de veias em uma imagem e calcula a porcentagem de veias na região analisada, e o segundo algoritmo é chamado de *Modified Local Binary Pattern* (M-LBP), e trata-se de extração de características da imagem levando em consideração a textura e a forma. O algoritmo também é inédito, pois foi utilizado o algoritmo LBP proposto por Zhao et al. (2005) e modificado pelos autores pois o mesmo era utilizado originalmente na extração de características de imagens da face. A finalidade do uso dos dois algoritmos propostos é criar um histograma em quatro níveis da imagem e utilizá-lo como padrão para reconhecimento da pessoa em questão, através do uso da medição estatística de similaridade *Chi square*, proposto por Ahonen et al. (2004). O trabalho apresenta três novos algoritmos para uso em sistemas biométricos de identificação de padrões de veias das mãos, e mostra-se como importante referência, sendo classificado pela IEEE como o trabalho já publicado de maior relevância sobre o tema.

O trabalho dos autores Kumar e Prathyusha (2009) propõe um sistema de extração das características das veias do dorso da mão utilizando o mesmo método até então proposto por outros autores, aplicando equalização de histograma na imagem adquirida, e utilizando o operador Laplaciano para extrair as características das veias. O método com o qual realizam a extração utilizando este algoritmo não é comentado, mas o detalhe de maior interesse neste trabalho está na proposta dos autores de se utilizar as juntas dos dedos como pontos de referência para poder corrigir rotações ocasionais no momento da aquisição das imagens e recortar a região de interesse após realizada a correção. A extração das características é realizada utilizando o algoritmo *Delaunay* de triangularização proposto por Bebis, Deaconu e Georgiopoulos (1999) e que trata-se de um sistema utilizado em identificação por impressões digitais. Os resultados apresentados comparam as taxas de falsa aceitação obtida em 1,14% e falsa rejeição obtida em 1,14% com autores já citados, e mostram que a técnica proposta apresenta praticamente a mesma eficácia, com o detalhe de ambas as taxas terem o mesmo resultado numérico, representando assim a taxa de erro igual citado por outros autores.

O trabalho dos autores Hong et al. (2009) apresenta uma revisão bibliográfica interessante, pois compara os métodos até então propostos. Todos os algoritmos já propostos são divididos em grupos, sendo que o primeiro é representado por métodos *line tracking* (segmento da linha)

e que todos os resultados já apresentados mostram que esta técnica é afetada pela variação da largura das veias ao longo do tempo, o segundo algoritmo mais estudado até o momento é baseado em *local threshold* mas estes apresentam problemas quanto às diferentes intensidades de valor adquiridas devido às diferentes localizações de região de interesse nas mãos, e o terceiro algoritmo mais utilizado baseia-se em métodos que utilizam transformadas baseadas na série de *Fourier*, mas estes gastam muito tempo no processamento das imagens e necessitam de muito recurso computacional. Com base nestas informações, é proposto um novo método de extração de características das veias chamado de *Position-Gray-Scale*, que consiste em adotar uma escala de cinzas representada em oito *bits*, sendo que a imagem totalmente preta tem como representação o número zero e a imagem totalmente branca tem como representação o número 255. Através desta definição, a imagem da mão é mapeada de forma gráfica, gerando uma linha curva que representa as regiões das veias sobre a estrutura completa da mão, e esta linha na prática é composta por regiões de "vale" onde aparecem as veias. Estas linhas são armazenadas como sendo o padrão de cada indivíduo, e para o reconhecimento, os autores utilizam a distância de *Hausdorff*. A proposta utilizou 378 imagens provenientes de 63 pessoas e os autores comentam que durante seus testes, não houveram falsas rejeições ou falsas aceitações, propondo que o sistema é o mais preciso até o momento, mas não relatam quantos testes foram realizados, nem por quanto tempo o sistema ficou em teste.

A proposta dos autores Kumar, Hanmandlu e Gupta (2009) é de utilizar imagens térmicas das mãos para se extrair informações das veias. Para a aquisição das imagens foi utilizada a câmera de modelo *SP Thermoview 8300 Infrared*. Os próprios autores lembram sobre a falha deste tipo de aquisição por ser diretamente dependente da temperatura e umidade do ambiente, então propõem utilizar uma sala fechada com temperatura e umidade controladas. O primeiro passo foi utilizar o filtro de *Gabor* para melhorar o contraste da imagem e em seguida utilizar a distância Euclidiana para localizar os pontos de mínimo e máximo contraste como forma de excluir a imagem de fundo, selecionando assim uma imagem única da mão. O método da distância Euclidiana também foi usado para localizar a profundidade dos dedos, adotar estes pontos como referência e rotacionar a imagem em um padrão sempre perpendicular à base da imagem obtida, corrigindo assim posicionamentos incorretos da mão no dispositivo leitor. A extração das características é realizada utilizando *Wavelets* de *Gabor*. Os resultados apresentados relatam falsa taxa de aceitação igual a 1,5% e falsa taxa de rejeição menor que 0,1%. A consideração a ser feita sobre estes resultados é que os autores realizaram um total de 90000 testes em 300 imagens adquiridas de 100 pessoas, e até o momento, outros autores propuseram taxas próximas a zero, mas com quantidades mínimas de testes.

A proposta dos autores Hegde et al. (2009) é de modularizar a imagem obtida com a finalidade de diminuir falsas rejeições e falsas aceitações devido à problemas de posicionamento

das mãos no momento da aquisição das imagens e por ferimentos causados nas mãos após o cadastramento do usuário. Trata-se de um sistema de autenticação, e não de identificação. As imagens obtidas são salvas com o número de registro do usuário na empresa onde o mesmo trabalha, e no momento da autenticação, caso o algoritmo proposto identifique corretamente, o usuário é liberado, mas caso haja rejeição, o sistema entra no modo de modularização para tentar corrigir uma possível falha. Inicialmente a segmentação da imagem é feita através de um algoritmo que detecta o gradiente da imagem, buscando os pontos de máximo e mínimo contraste conhecido como filtro Gaussiano. Após esta etapa, são realizadas duas aplicações de *threshold* na imagem, sendo uma para detectar bordas fortes (alto contraste) e outra para detectar bordas fracas (borradas). Ainda na mesma imagem, é aplicado o mesmo método de esqueletonização proposto em outros trabalhos. Para a extração de características, foi utilizada a transformada de *Hough*, que utiliza coordenadas polares para extrair vetores que contém as informações sobre as veias. O número de pontos que se cruzam e pontos que indicam o fim das veias são determinados pela técnica *Chord to point distance accumulation* (CPDA). Enfim, a modularização proposta pelos autores consiste em dividir a imagem em 16 módulos de igual tamanho, após isto a imagem é recortada usando as coordenadas espaciais obtidas para gerar um retângulo de determinada largura e altura. O módulo de saída pode variar por um ou dois *pixels* do tamanho especificado devido o módulo de saída incluir todos os *pixels* da entrada que são total ou parcialmente fechados pelo retângulo. Analisando a figura proposta no trabalho, evidenciase que a imagem foi dividida por 4 linhas e 4 colunas gerando uma matriz de pequenas imagens (chamadas por outros autores de subimagens), e a técnica de extração de dados antes aplicada na imagem total, agora é aplicada sobre cada pequena célula no intuito de melhorar a precisão do sistema. Todo o sistema proposto pelos autores foi realizado com o uso do *software Matlab*® versão 7.5 e os resultados obtidos mostram que o sistema melhora a identificação em relação ao método tradicional. As taxas de FAR e FRR eram de 2,3% em sistemas que utilizam exatamente o mesmo projeto proposto mas sem a técnica de modulação, e caíram para FAR igual a 2,1% e FRR igual a 1,274% após aplicação da técnica proposta.

Os autores Malki e Spaanenburg (2010) propuseram a implementação de um sistema de identificação biométrica baseado em FPGA. Os autores definem o sistema como sendo essencialmente composto por três etapas: binarização responsável por transformar a imagem proveniente de uma padrão de cinzas para um padrão de apenas preto e branco; esqueletonização como sendo o processo de reduzir a largura das veias em linhas de apenas um *pixel* e remoção de *pixels* isolados, como sendo um método de redução de ruídos. Para isto, propõem o uso do algoritmo *Cellular Neural Networks* (CNN) na implementação de um sistema que detecte terminações das veias, cruzamentos (bifurcações) e pontos isolados na extração de

características das imagens. Trata-se de uma proposta de melhoria na qualidade da imagem, mas os autores não relatam como a imagem foi adquirida, nem quais são os resultados da proposta do trabalho, apenas comentam que como o sistema é embarcado em FPGA, o tempo total de processamento é da ordem de $1\mu s$ enquanto que em outros sistemas este tempo é em média de $15ms$.

Os autores Zhang e Hu (2010) publicaram seus resultados de um trabalho de identificação biométrica completo. Para a captura das imagens, utilizaram a câmera JAI AD-080 CL 1/3" que tem pico de resposta em $800nm$, um conjunto de LEDs infravermelhos modelo *Single Chip Micyoco* (SCM) com conexão direta à porta serial do microcomputador e a proposta é de que a iluminação seja controlada via *software* no momento da aquisição da imagem, variando a luminância de acordo com o contraste obtido, mas os autores não comentaram a realização deste processo. Em seguida extraem a região de interesse (*Region of Interest* (ROI)) e aplicam o método de agrupamento de *Otsu* para obter o melhor valor de *threshold* a ser aplicado na imagem na fase de binarização. Analisando as equações do trabalho, nota-se que este método foi utilizado para melhorar o contraste da imagem, o que tinha sido proposto inicialmente como sendo uma fase desnecessária pelo uso de controle automático da iluminação, e na verdade, a binarização foi feita utilizando o algoritmo de *NiBlack*, já comentado aqui neste capítulo. Os autores não citam qual método utilizaram para a extração das características da imagem, e em seus resultados, comentam que foram coletadas 180 imagens provenientes das palmas das mãos de 30 pessoas, sendo 6 imagens capturadas por cada pessoa, e os resultados sobre falhas é apresentado utilizando a curva *Receiver Operating Characteristic* (ROC) (esta curva ilustra a falsa taxa de aceitação FAR e a falsa taxa de rejeição FRR no mesmo gráfico, e a área onde os dois índices se cruzam, é chamado de EER, que representa a taxa de erro entre a FAR e a FRR), sendo que a taxa EER é de 1,82%.

Segundo Yuan (2010) um dos problemas de identificação biométrica está no posicionamento incorreto da mão no momento da captura da imagem. Para solucionar este problema, propõem um dispositivo de captura que utiliza um *grip-type hand* (suporte parecido com uma maçaneta de porta convencional) para que o usuário o segure durante a aquisição da imagem. Como o usuário é obrigado a segurar este dispositivo, dificilmente conseguirá rotacionar a mão causando problemas na identificação das características. Ainda para a correção de possíveis desvios, utilizam o algoritmo *Border Pixel Vector* (BPV) para localizar as bordas da imagem da mão, e a distância *Euclidiana* para encontrar os pontos de máximo e mínimo ao rotacionar a imagem no sentido horário. Isto faz com que os pontos de profundidade dos dedos seja localizada, e a partir destes pontos, a região de interesse é selecionada, corrigindo qualquer possível rotação da mão. A base do trabalho está nesta correção, a extração de características é baseada na análise de minúcias assim como é feito em sistemas biométricos que utilizam o padrão de

impressão digital dos dedos e os resultados apresentados mostram a FAR em 1% e FRR em 0,67%, após análise de 600 imagens obtidas de 30 usuários.

Os autores Yüksel, Akarun e Sankur (2010) apresentaram um trabalho que demonstra ser importante pelos resultados e pela técnica adotada. Para captura das imagens, utilizaram uma câmera monocromática especial que captura imagens no espectro do infravermelho próximo, de modelo WAT-902H2 ULTIMATE (CCIR), e criaram uma base de 1200 imagens provenientes de 100 usuários, sendo 41 mulheres e 59 homens. A captura das imagens foram feitas em condições especiais. Utilizaram uma sala escura para a aquisição das imagens impedindo assim que qualquer luz no ambiente interferisse no processo, e adotaram quatro critérios diferentes: a primeira imagem é coletada em condições reais, sem orientação do usuário quanto ao correto posicionamento da mão no dispositivo; a segunda imagem é coletada após o usuário carregar uma bolsa com três quilos durante um minuto; a terceira imagem é coletada após o usuário ficar apertando uma pequena bola de borracha por um minuto e a quarta imagem é coletada após o usuário colocar uma bolsa de gelo sobre a mão (o tempo não é relatado neste caso). Para cada situação, foram realizadas três capturas de imagem, gerando um banco de dados de 1200 imagens. Para a extração das características, utilizaram uma fusão de três algoritmos diferentes. O primeiro algoritmo utilizado é conhecido como *Independent Component Analysis* (ICA) e baseia-se em extrair estatisticamente variáveis independentes de uma imagem. O segundo algoritmo utilizado é conhecido como *Non-negative Matrix Factorization* (NMF) que tem como principal objetivo forçar com que as matrizes extraídas pelo algoritmo ICA não sejam negativas e o terceiro algoritmo utilizado é o *Line Edge Map* (LEM) que realiza a extração de linhas de uma imagem. No próximo estágio, citam que a binarização da imagem pode ser feita com adoção de um *threshold* global ou local, e adotam diversos métodos na busca de um melhor algoritmo (os métodos testados foram de *Yasuda*, *Bernsen*, *NiBlack*, *Wang* e *Otsu*). Utilizando o algoritmo *Modified Hausdorff Distance* (MHD) para a comparação entre os métodos, escolheram o algoritmo de *Yasuda* como o mais eficiente na binarização da imagem. Chegaram à conclusão de que em condições normais, o algoritmo ICA é o melhor a ser aplicado, mas em condições especiais (após carregar peso, exposição ao gelo e pressão sobre a bola elástica) o melhor algoritmo a ser adotado não foi definido pois reconheceram que cerca de 25% dos pontos extraídos não tem relação com as condições de *stress* adotadas. Propõem assim em um projeto futuro a implementação de um algoritmo que possa extrair em condições especiais as principais características das imagens para tornar o sistema biométrico mais robusto.

O trabalho dos autores Yang, Liu e Liu (2010) apresentou um processo inédito na esqueleto-nização da imagem de padrão de veias das mãos. A proposta é de se dividir o processamento da imagem em várias etapas. A primeira etapa consiste em normalizar a imagem padroni-

zando o tamanho e a escala de cinzas de cada imagem adquirida, pois segundo os autores, as mãos de diferentes pessoas apresentam diferentes tamanhos e deve ser definido um tamanho padrão para o sistema biométrico, e a modificação dos níveis de gordura nas mãos ou diferenças na iluminação também variam e devem ser normalizadas. Para a normalização, foi proposto um algoritmo que extrai a média e a variância de cada imagem, e aplicam-se estes valores para normalização do padrão de cinzas. O tamanho é definido experimentalmente para ser 256x256 *pixels*, mas o algoritmo que realiza isto automaticamente não é comentado. O próximo passo proposto é a segmentação, e então os autores utilizam o algoritmo de *NiBlack* (*threshold* dinâmico local) mas relatam que esta aplicação gera protuberâncias nas veias e a forma de se resolver isto é passando a imagem por um filtro Gaussiano passa baixa 5x5 2D. Os autores relataram que os melhores resultados foram obtidos ao se passar este filtro por seis vezes na mesma imagem, no entanto os resultados melhoram mas são gerados ruídos. A próxima etapa consiste em retirar estes ruídos, através da aplicação de filtros de suavização de imagem e o filtro adotado nada mais é que um filtro passa faixa focado em frequências médias (estas frequências não são expostas no trabalho). Nem todas as protuberâncias são extraídas, então os autores propõem o uso do algoritmo de Wang et al. (2006)a, que usa um modelo para remover oito tipos diferentes de pontos com *pixels* vizinhos de padrão diferentes, e os resultados visuais são muito bons. Ainda assim, existem protuberâncias e a proposta para retirá-los é de aplicar um algoritmo de “poda” que consiste em analisar a imagem linha a linha tentando encontrar *pixels* pretos que não coincidem com *pixels* de mesmo tom ao seu redor, e eliminá-los. Os testes de identificação foram feitos usando o algoritmo SVM, e os resultados apresentados mostram taxa de reconhecimento de 95,5%. Visualmente, as imagens obtidas após todas as etapas propostas são muito boas, resumidas em linhas de um único *pixel* sem nenhuma protuberância, e o artigo apresenta passo a passo como os resultados podem ser reproduzidos.

Segundo Zhou e Kumar (2010) uma forma eficiente de se extrair as características dos padrões de veias das mãos é de se aplicar múltiplos algoritmos, criando um sistema multimodal. Vários autores relataram sistemas multimodais unindo características biométricas diferentes, e este trabalho utiliza a mesma biometria mas a extração das características é realizada por quatro diferentes algoritmos. Os algoritmos de fase Heussiana (*Heussian phase*) e de *Ordinal Code* representam um tipo de características de fase, ou seja, quantifica valores de acordo com algum *threshold* ou relação entre *pixels*); o algoritmo *Laplaciampalm* pertence à classe de algoritmos que representam a aparência da imagem baseado nas características subespaiais e o algoritmo *Localized Radon Transform* (LRT) codifica as características de orientação angular da imagem. Todos os quatro algoritmos já foram comentados aqui como sendo aplicados em trabalhos de outros autores. Neste trabalho, os autores testam individualmente todos os

algoritmos sobre o banco de dados de imagem da CASIA (2010).

Chinese Academy of Sciences Institute of Automation (CASIA) é um grupo criado com a finalidade de gerar imagens de diversas partes do corpo para criar bancos de dados usados em sistemas biométricos. Os resultados obtidos usando apenas uma imagem (os autores propõem uma técnica de treino, que a princípio parece relatar um sistema de inteligência artificial, mas na verdade trata-se de tirar a média entre várias imagens e utilizar esta média como sendo a figura de referência) relatam os seguintes índices (taxa de reconhecimento):

- *Hessian Phase*: mão direita = 95% e mão esquerda = 91%;
- LRT: mão direita = 96,67% e mão esquerda = 91,33%;
- *Ordinal Code*: mão direita = 97,67% e mão esquerda = 91%;
- *Laplacianpalm*: mão direita = 77,67% e mão esquerda = 75%;
- Combinação entre os quatro algoritmos: mão direita = 98% e mão esquerda = 96,67%.

Os resultados obtidos usando três imagens (relatado como sistema treinado, na verdade apresenta a média de três diferentes imagens obtidas do mesmo usuário) relatam os seguintes índices (taxa de reconhecimento):

- *Hessian Phase*: mão direita = 97,67% e mão esquerda = 97,33%;
- LRT: mão direita = 99% e mão esquerda = 98,33%;
- *Ordinal Code*: mão direita = 99% e mão esquerda = 98,67%;
- *Laplacianpalm*: mão direita = 91,67% e mão esquerda = 87%;
- Combinação entre os quatro algoritmos: mão direita = 100% e mão esquerda = 99,67%.

O que chamou a atenção neste trabalho foi o fato de que os décimos apresentados nas taxas de reconhecimento são sempre os mesmos para cada algoritmo, em uma análise de 600 imagens, sendo que na segunda proposta, foi utilizada a composição de 3 imagens de cada usuário, resultando em 1800 imagens. Estes décimos mostram 1/3 ou 2/3 do inteiro para cada análise (0,33% ou 0,67%).

O próximo trabalho avaliado é de autoria de Wang, Li e Cui (2010) e propõe um sistema biométrico baseado no padrão de veias da parte dorsal da mão. O tema principal do trabalho está no método de extração das características da imagem. Os autores dividem o trabalho em várias etapas, e a primeira etapa consiste em adquirir a imagem, usando uma câmera CCD de baixo custo (não relatado o modelo e fabricante), e dois conjuntos de LEDs infravermelhos

dispostos aos lados esquerdo e direito da câmera. Após a captura da imagem, são usados três filtros diferentes, sendo: *Matched filter*, *Wiener filter* e *Smoothing filter*. Os autores relatam que devido às imagens serem naturais, não é fácil calcular a taxa de sinal ruído (*Signal-to-noise ratio* (SNR)), então usaram a variação total (*Total Variation* (TV)) para avaliar o nível de ruído. Com o uso desta técnica, comprovaram a eficácia do uso dos três filtros. A correção da rotação da imagem é feita utilizando o algoritmo *Circle Partition LBP* (não comentado como foi realizado) e a região de interesse foi extraída usando a mesma técnica proposta por Kumar e Prathyusha (2009) já comentada, a normalização da imagem é feita calculando-se a média de tons de cinza sobre a imagem total e adotando este parâmetro para regulação, e finalmente, a proposta original do trabalho está na aplicação do algoritmo LBP particionado, chamado pelos autores de *Partition Local Binary Pattern* (PLBP). A proposta é de se dividir a imagem em pequenas células e aplicar o algoritmo LBP nestas células, pois segundo eles, os vetores extraídos identificam com maior precisão a pessoa, em relação à aplicação do algoritmo aplicado à imagem inteira. Vale comentar que originalmente o algoritmo LBP foi proposto pelos autores Zhao et al. (2005) e melhorado pelos autores Zhao, Wang e Wang (2007). O interessante nesta proposta é que o algoritmo utilizado extrai vetores referentes às texturas da imagem, e com isso, não é necessário realizar *threshold*, esqueletonização e binarização da imagem, aumentando a velocidade de processamento e diminuindo erros inseridos por uso destas três técnicas citadas. Os resultados apresentados são provenientes da análise de 2040 imagens de 102 pessoas, sendo 52 homens e 50 mulheres, e a taxa de reconhecimento ficou em 95,1961%, indicando que o trabalho é válido. O autor compara seus resultados com autores que utilizaram outras técnicas de extração, mas se comparado aos trabalhos originais que usam algoritmo LBP, os resultados seriam piores.

Os autores Sanchit et al. (2011) iniciam o ano de 2011 com uma proposta de sistema biométrico multimodal. A proposta é de se utilizar a imagem da mão e o padrão de veias da mão em um único sistema de identificação. O trabalho só apresenta o estudo sobre a identificação utilizando o padrão de veias. Um protótipo montado com uma câmera modelo JAI AD-080GE foi montado para a aquisição das duas imagens ao mesmo tempo, pois segundo os autores, esta câmera possui dois sensores do tipo CCD, sendo um para imagens no espectro de luz visível e o outro com pico de captura de imagens em $800nm$. Um banco de dados com 1400 imagens provenientes de 70 pessoas (10 imagens da palma da mão e 10 imagens da parte dorsal da mão de cada pessoa) foi montado e cada imagem foi salva no padrão *Tagged Image File Format* (TIFF) com resolução de 1024×768 pixels e oito bits por pixel. Na fase de pré-processamento, é proposto um sistema de extração da região de interesse ROI baseando-se em quatro pontos da mão mas o algoritmo utilizado e a região destes pontos não é citada. Após determinação desta região, a imagem é recortada e redimensionada para 128×128 pixels.

Para a redução de ruídos, utilizaram o filtro médio como primeira etapa, em seguida usaram o filtro *Wiener 2D* para suprimir o efeito dos ruídos de alta frequência e para o melhoramento do contraste usaram equalização adaptativa do histograma. Na fase de extração das características foi usado o algoritmo *Circular 2D Gabor*, que consiste em extrair matrizes provenientes das frequências e desvios de padrão da imagem, muito utilizado em outros processamentos biométricos tais como identificação por íris e retina. A distância de *Hamming* foi usada para validar a identificação das pessoas (chamado pelos autores de algoritmo métrico). A fusão entre os dados extraídos do padrão de veias e da impressão digital da mão foi feita usando a técnica de *score level*, proposto inicialmente por Toh et al. (2005) que consiste em criar texturas a partir da soma de duas ou mais imagens. Os resultados apresentados mostram índices de EER igual a zero, enquanto que o EER do processamento de apenas a palma das mãos foi de 1,39 e do dorso das mãos foi de 1,43. O tempo de processamento em sistemas multimodais já foi comentado várias vezes como sendo o critério restritivo, e os autores apresentaram o tempo total de 0,975 segundos, enquanto que o tempo para processamento da palma da mão era de 0,3458 segundos e do dorso da mão de 0,3631 segundos, mostrando assim que neste caso o tempo total não foi a soma dos dois processamentos, e sim um valor triplicado dos tempos individuais. Em sistemas com alto volume de usuários, o tempo aproximado de um segundo por pessoa para o processamento pode ser considerado como fator proibitivo da aplicação do sistema proposto.

O trabalho dos autores Wang e Chen (2011) apresenta um sistema biométrico de identificação de pessoas através do padrão de veias da parte dorsal das mãos, e a imagem é capturada com a mão fechada. Para isto, utilizaram a câmera modelo SONY SSC-E473 que possui picos de captura de $750nm$ a $1400nm$ para a aquisição de 10 imagens da mão direita e 10 imagens da mão esquerda de cada usuário, sendo 20 homens e 5 mulheres, totalizando 500 imagens analisadas. Para melhoria da imagem, utilizaram o filtro *High Booster* que tem a característica de melhorar os componentes de alta frequência preservando os de baixa frequência, em seguida usaram um algoritmo detector de borda (não comentado) para extrair a imagem da mão através da exclusão do fundo, usaram o operador Laplaciano para a fase de *threshold* e o operador morfológico para extração de características. Os autores apresentaram seus resultados em precisão de 94,8% quando usada a mão direita, 91,9% quando usada a mão esquerda e 93,35% quando usadas as duas mãos (na verdade esse valor é uma média simples entre as precisões das mãos) mas não apresentaram qual técnica utilizaram para a verificação da identidade das pessoas nem detalhes de como os algoritmos funcionam.

Os autores Mirmohamadsadeghi e Drygajlo (2011) apresentaram um trabalho original sobre o melhor método de extração de características de imagens de padrão de veias das mãos. A proposta é de se testar o algoritmo LBP já comentado pelo uso por diversos outros autores

(neste trabalho utilizaram o algoritmo LBP multi-escala) e o algoritmo *Local Derivative Pattern* (LDP) como ferramentas para extração de características das imagens do banco de dados CASIA (2010), portanto, a proposta é de se testar apenas os algoritmos, não realizaram a aquisição das imagens. Após aplicação do algoritmo LBP, o melhor desempenho do sistema foi apresentado quando a imagem é decomposta em 16 subimagens, e os 16 histogramas referentes são concatenados em um descritor de tamanho igual a 3840, que representa toda a imagem. O algoritmo LDP é muito utilizado em reconhecimento de padrões da face, e se comporta como um algoritmo de segunda ordem por extrair a informação de variação derivativa da direção de cada *pixel*, enquanto que o LBP pode ser caracterizado como de primeira ordem. O mesmo foi aplicado sobre as mesmas 16 subimagens decompostas anteriormente, com ângulos definidos em 0, 45, 90 e 135 graus. Os quatro histogramas obtidos foram concatenados e resultaram em um descritor de tamanho igual a 16384. O método de identificação utilizado foi o algoritmo de intersecção do histograma, proposto originalmente em 1991 por Swain e Ballard (SWAIN; BALLARD, 1991) e os resultados apresentados mostram a taxa EER para o algoritmo LBP igual a 0,0009 e EER para o algoritmo LDP igual a 0,004, provando assim que o algoritmo LBP é a melhor ferramenta a ser aplicada em imagens de padrão de veias das mãos.

O ano de 2012 se inicia com a publicação do trabalho de Fischer, Rybnicek e Tjoa (2012) e este apresenta um método eficiente para se extrair as características das veias das palmas da mão chamado de algoritmo *Enhanced Local Gabor Binary Patterns Histogram Sequence* (ELGBPHS). Este algoritmo é muito utilizado em sistemas biométricos que identificam os padrões faciais, e trata-se de uma combinação de filtro 2D de *Gabor*, algoritmo LBP e algoritmo de intersecção de histograma. A proposta dos autores é aplicar este algoritmo em padrões de veias para verificar a possibilidade de uso do mesmo. Para isto, utilizam o banco de dados de imagens CASIA (2010), pois a única finalidade do trabalho é o teste do algoritmo. Segundo os autores, a fase de pré-processamento consiste basicamente em segmentar o contorno da mão na imagem, encontrar os dedos e fixar pontos nas extremidades dos dedos, determinar a região de interesse a partir destes pontos, extrair a região de interesse, rotacionar a imagem para uma posição ideal e redimensionar. A fase de melhoramento do contraste e diminuição de ruídos não é necessária pois o algoritmo ELGBPHS é usado para diversas condições de iluminação no reconhecimento facial. Para a segmentação da mão, usaram o algoritmo *Suzuki 85 Border Tracing Algorithm*, que identifica as bordas da mão pelo fato do fundo da imagem ser totalmente escura. Para a identificação dos dedos e fixação de pontos nas extremidades dos dedos, usaram o algoritmo de distância Euclidiana. A localização da região de interesse é feita fixando-se valores de largura e altura de um retângulo em 100x100 *pixels* e 128x128 *pixels*, com centro definido pela linha mediana do centro da mão. A extração e redimensionamento desta região localizada é feita usando *Affine Transformation*. Com a região selecionada, aplica-se o

algoritmo ELGBPHS para a extração de orientações, frequências, fases, tamanhos e taxas de aspecto que representam a imagem estudada. A partir destes dados, o algoritmo LBP produz subimagens e histogramas destas subimagens são calculados. O algoritmo de intersecção do histograma é usado então para comparar a similaridade entre dois histogramas. Se os níveis de cinza de dois histogramas são idênticos, trata-se da mesma pessoa, e se forem diferentes, a identificação é rejeitada. Os resultados apresentados mostram índices de FAR igual a 4,3 e FRR igual a 0,3.

Os autores Tang, Huang e Wang (2012) realizaram um estudo sobre como extrair informações das veias de uma imagem infravermelha da parte dorsal das mãos. Para isto, utilizaram técnicas de detecção de pontos. As imagens analisadas são de propriedade dos autores Zhao e Wang (2008) e o banco de dados é chamado pelos autores de *North China University of Technology (NCUT) database*. Após pesquisa breve sobre este banco de imagens, verificase que o mesmo foi utilizado por diversos autores que estudam na mesma universidade, as imagens não estão disponíveis em nenhum domínio público. Em uma mesma imagem, aplicaram os algoritmos *Difference of Gaussians (DoG)*, *Hessian-Laplace* e *Harris-Laplace*. Estes algoritmos são nomeados como detectores de gotas. Após análises, chegaram à conclusão de que o melhor algoritmo detector de gotas para identificação de veias em uma imagem infravermelha é o *Hessian-Laplace*, no entanto, o algoritmo *Harris-Laplace* também apresentou uma boa detecção de pontos, então sugerem a fusão dos dois métodos através do algoritmo *Scale-Invariant Feature Transform (SIFT)*, e fizeram análises de precisão entre os algoritmos apresentados, mas não demonstram como as análises foram feitas. As conclusões mostram que o melhor algoritmo a ser utilizado neste tipo de processamento realmente é a fusão entre eles, pois apresenta precisão de 98,04%. O algoritmo *Hessian-Laplace* apresentou precisão de 95,49% e o algoritmo *Harris-Laplace* apresentou precisão de 96,08%.

O único trabalho publicado em 2014 é de autoria de Parthiban et al. (2014) e trata-se da identificação de pessoas através do reconhecimento do padrão de veias dos dedos. Os passos propostos são a conversão da imagem colorida para padrão de cinzas (as imagens utilizadas não são relatadas de algum banco de dados ou como foram capturadas), em seguida melhorar o contraste multiplicando cada *pixel* da imagem por uma constante (informação irrelevante, assemelha-se a uma proposta de se adotar *threshold* dinâmico, usando a média ou a variância como sendo este valor constante), redução de ruídos adicionando o filtro *salt and pepper* e o uso de um filtro médio, e então converter a imagem em uma nova imagem com dupla precisão (esta técnica de dobrar a precisão não foi explicada, apenas relatado como sendo realizado através do uso do algoritmo de *Sobel*). A extração de dados é feita com o uso do algoritmo *Gradient Feature Selection*, proposto originalmente por Huang et al. (2003) e a classificação é feita com a distância Euclidiana. Os resultados apresentados mostraram taxa de EER igual

a 0,05.

Em 2015, foram publicados dois trabalhos relevantes ao tema em estudo. O primeiro trabalho analisado é de autoria de Joardar, Chatterjee e Rakshit (2015) e trata-se de um equipamento capaz de identificar pessoas através da captura de imagens no espectro infravermelho utilizando uma câmera *Raspberry Pi Model B*, acoplada a um sistema do tipo *pan-tilt* para que a busca da melhor posição de captura da imagem seja realizada de forma automática. O enfoque principal do trabalho é o sistema automatizado de posicionamento da câmera, pois o processo de identificação é realizado por esqueletonização da imagem já utilizada por diversos outros autores. Criaram para os testes um banco de imagens contendo 300 imagens de 30 diferentes pessoas com faixa etária ente 21 a 42 anos. Na fase de classificação, propõem um novo algoritmo chamado de *Collaborative Representation-Based Classification (CRC)*, e apresentam seus resultados de classificação em taxa de reconhecimento igual a 97,34%.

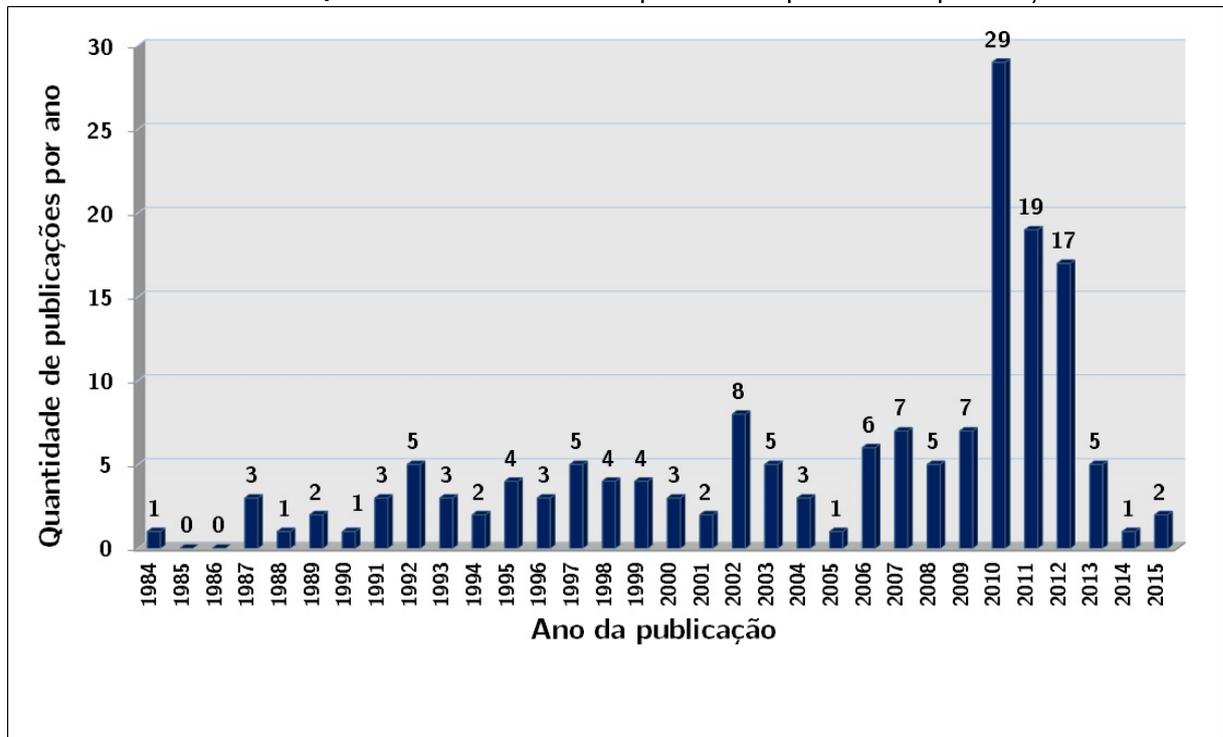
O trabalho de Alejo, Rodriguez e Kemper (2015) apresenta um sistema completo de identificação biométrica baseado no padrão de veias do dorso das mãos. Para a aquisição das imagens criaram um equipamento composto por um sensor chamado de *PalmVein Reader*. Na fase de binarização da imagem, usaram a técnica de se adotar um limiar nos tons de cinza para excluir o fundo da imagem e deixar somente o conteúdo da mão, já relatado nesta tese por diversas vezes como sendo método de *threshold*, para eliminar os nós dos dedos utilizaram a distância Euclidiana na identificação dos locais mais profundos e recortaram a imagem nesta região, na fase de segmentação utilizaram uma técnica de corte da imagem definida pela maior porção da mão, mas não relataram sobre a possibilidade de rotação da imagem, e após a região de interesse ROI ser extraída, aplicam novamente um método de binarização baseado em *threshold* para destacar desta vez as veias da mão e realizar a esqueletonização da mesma e para validação da identificação dos usuários utilizam os valores numéricos encontrados de cada usuário para comparação direta e adotam como padrão de identificação que se a imagem for parecida em até 90% ou mais com a imagem armazenada no banco de dados, o sistema aprova o usuário. Os resultados são relatados em FAR igual a zero e FRR igual a 0,47, mas os autores não relatam os resultados em termos de EER.

3.3 CONCLUSÕES FINAIS SOBRE A REVISÃO BIBLIOGRÁFICA

Foram realizadas análises de 160 trabalhos, sendo que inicialmente foram encontrados 141 trabalhos sobre o tema, e os 19 trabalhos excedentes foram encontrados após análise de referência cruzada dos trabalhos iniciais, considerados importantes pelos autores. O estudo sobre o tema teve início com a proposta realizada por Rice em 1984 e o pedido de patente em 1987 (RICE, 1987), e somente em 1991, MacGregor e Welford (1991) apresentaram trabalhos

sobre o tema mas infelizmente o Sr. Rice não é citado em nenhuma obra posterior como sendo reconhecido o autor original. Desde então, diversos trabalhos foram publicados mas poucos realmente apresentaram um resultado significante com relação às propostas iniciais. No Gráfico 1 abaixo, pode-se perceber que o período entre os anos de 2010 e 2012 foram fundamentais para a publicação do tema, resultando em 66 trabalhos publicados em apenas 3 anos, o que representa 40,6% de toda publicação sobre o tema. Nestes anos ocorreram dois congressos internacionais organizados pela IEEE com o tema específico sobre biometria, provavelmente este fato levou ao alto índice de publicações neste período.

Gráfico 1 - Quantidade de trabalhos publicados por ano de publicação

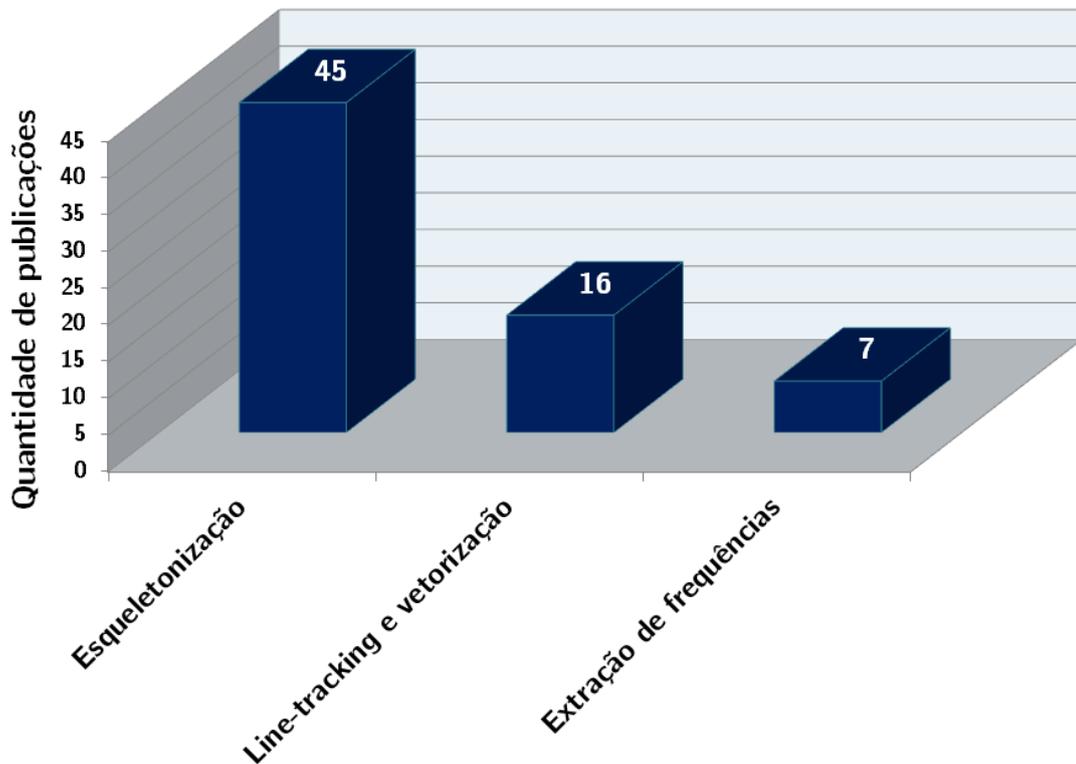


Fonte: Produção do próprio autor

Entre todos os trabalhos publicados, evidencia-se a distinção entre três principais métodos de se reconhecer uma pessoa através do uso da identificação do padrão de veias das mãos. O primeiro método é baseado na esqueletonização da imagem, ou seja, criar linhas com um único *pixel* de largura para definir a veia, ignorando dessa forma sua espessura. Esta técnica é muito útil pois faz com que as variações de espessura que possam existir ao longo dos anos sejam ignoradas. Na verdade, esta técnica representa a maioria dos trabalhos apresentados (45 trabalhos entre os 160 trabalhos analisados) mas depende de diversos passos para a real extração de características das veias, como a utilização de diversos filtros para diminuir ruídos. Outro método utilizado é o *line tracking*, que baseia-se em adotar vetores para representação das veias. Existem diversos métodos diferentes mas todos se baseiam na ideia original de adotar vetores que representarão as características das veias, sendo os outros métodos apenas modi-

ficações da proposta inicial. Com o uso desta proposta, foram identificados 16 trabalhos que realmente utilizaram o método proposto. A terceira proposta é de se considerar a imagem total da mão, e extrair as características desta imagem através da análise da textura, gerando assim frequências. Estes métodos basicamente utilizaram a transformada de *Fourier* modificada, e foram encontrados 6 trabalhos utilizando a transformada de *Wavelet* e um trabalho utilizando a transformada de *Ridgelet*. Baseando-se no critério de quantidade de informações, este terceiro método é o mais eficiente, no entanto, o que mais requer uso computacional, portanto, não foi muito utilizado no passado pelo aumento do tempo de análise por computadores de baixo desempenho. De todos os trabalhos analisados, 56 publicações trataram características específicas, sem utilizar algum método de extração. Pode-se visualizar no Gráfico 2 abaixo a relação dos três métodos mais utilizados.

Gráfico 2 - Métodos de extração utilizados



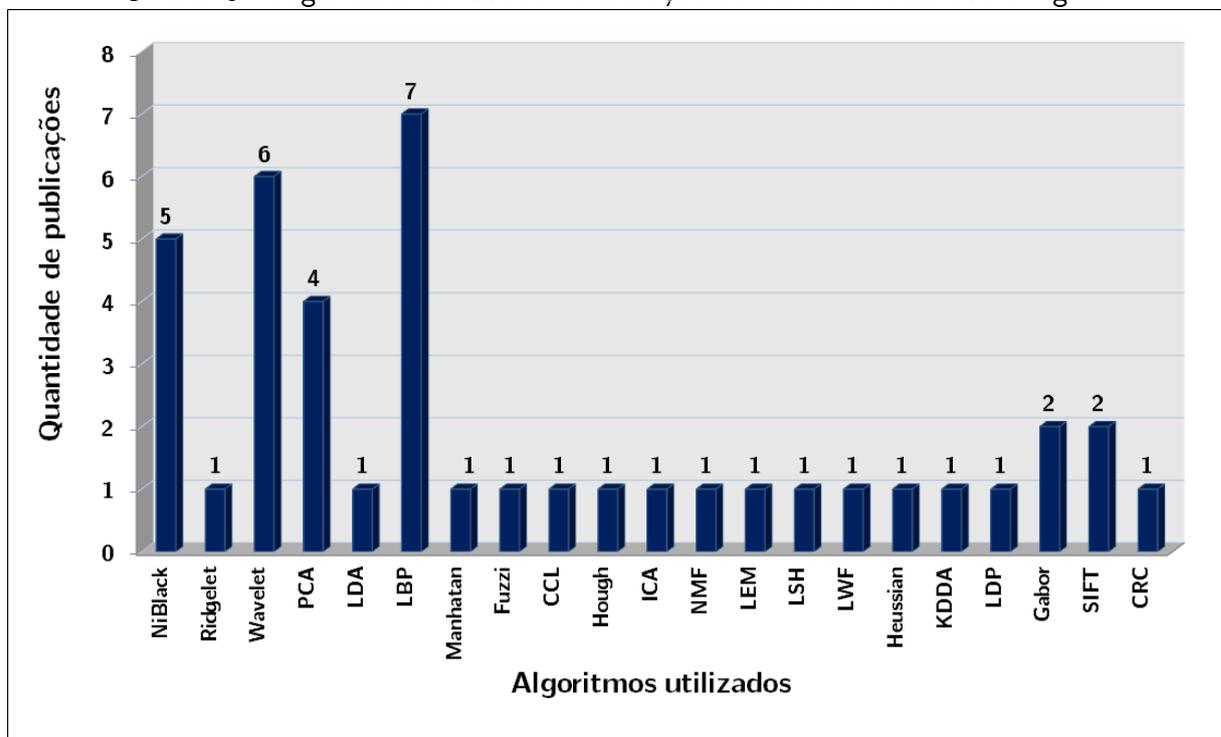
Fonte: Produção do próprio autor

Para a aquisição das imagens, foram encontrados 21 trabalhos que propuseram protótipos. Destes, 19 foram chamados de projetos de “baixo custo”, e três projetos foram considerados de alto desempenho (um projeto utilizando câmera NIR específica, um projeto utilizando um equipamento de ultrassom específico para uso médico e um projeto utilizando uma câmera térmica FIR). Dos projetos relatados como de “baixo custo”, todos utilizaram câmeras portáteis ou do tipo *webcam*, e realizaram modificações nestes equipamentos para a devida captura das imagens. Os outros trabalhos utilizaram três bancos de imagens existentes, sendo o

BOSPHORUS (2010), o CASIA (2010) e o banco utilizado pelos autores Kabacinski e Kowalski (2011). Foi solicitado acesso aos três bancos de imagens para análise, e o primeiro banco foi disponibilizado sem muito trabalho, apenas através do cadastro pelo *site* indicado na bibliografia. O banco de dados tem o nome Bosphorus, e foi carregado para análise visual das imagens geradas. A aprovação do cadastro levou cerca de 10 dias e em seguida foi fornecida uma senha para acesso ao banco de imagens. O segundo banco de imagens também solicitou cadastro, e após uma semana, foi enviada uma resposta por *e-mail* pedindo o preenchimento e envio de um formulário assinado e carimbado pela instituição de ensino e o responsável pelo uso das imagens, com diversas restrições de uso, então o uso deste banco foi descartado pelas dificuldades encontradas, e o terceiro banco de imagens citado não foi encontrado em nenhum local público para solicitação ou acesso.

Os algoritmos utilizados na extração das características das imagens representam a maioria do conteúdo dos trabalhos analisados. Pode-se verificar que o uso dos algoritmos *NiBlack*, transformada de *Wavelet*, PCA e LBP foram muito citados, mas existem diversos outros algoritmos utilizados. O Gráfico 3 abaixo apresenta as siglas destes algoritmos, e a quantidade que cada um foi usada.

Gráfico 3 - Algoritmos utilizados na extração de características das imagens

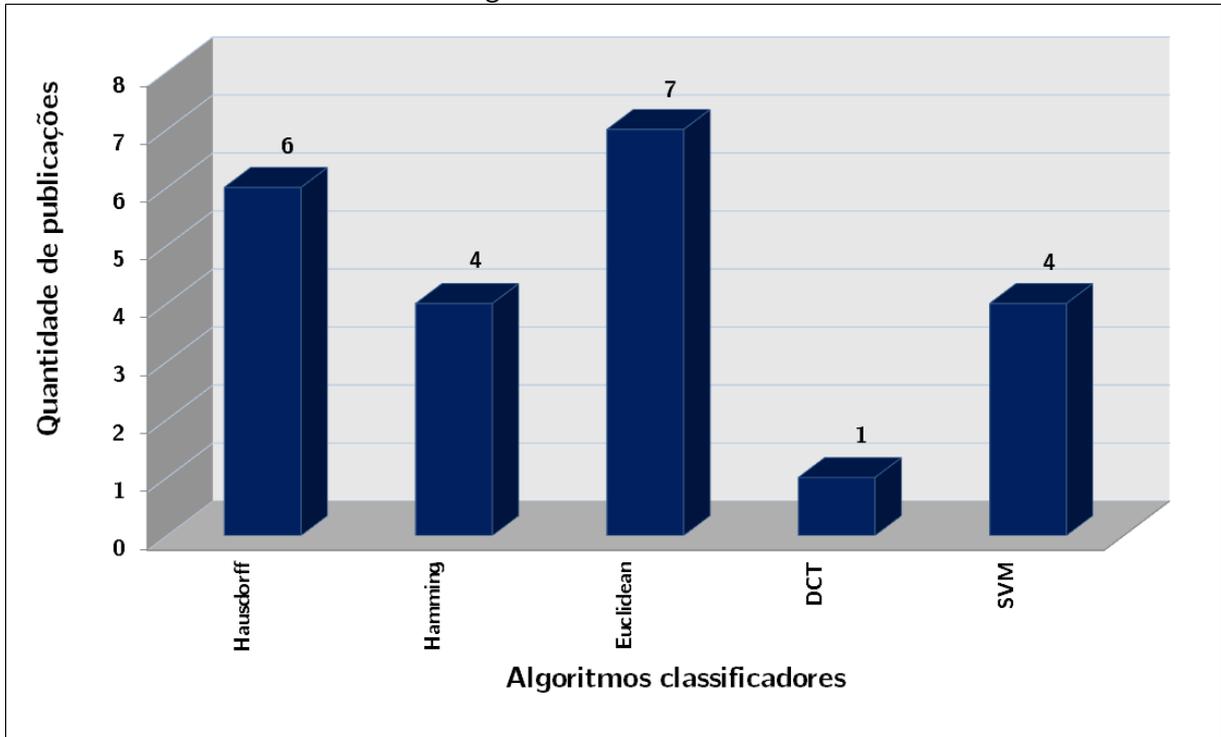


Fonte: Produção do próprio autor

Quanto aos classificadores utilizados, basicamente foram apresentados os métodos da distância de *Hamming*, distância Euclidiana, distância de *Hausdorff*, DCT e SVM. Os trabalhos iniciais utilizaram a distância de *Hausdorff*, em seguida a distância Euclidiana foi a mais uti-

lizada, e os outros métodos foram citados mas não representam a maioria dos trabalhos. Os resultados apresentados não são demonstrados pelos autores como tendo alguma relação com os classificadores, não existe nenhum estudo sobre qual o melhor método a ser utilizado. O Gráfico 4 abaixo apresenta a quantidade de vezes que estes métodos foram utilizados.

Gráfico 4 - Algoritmos classificadores utilizados

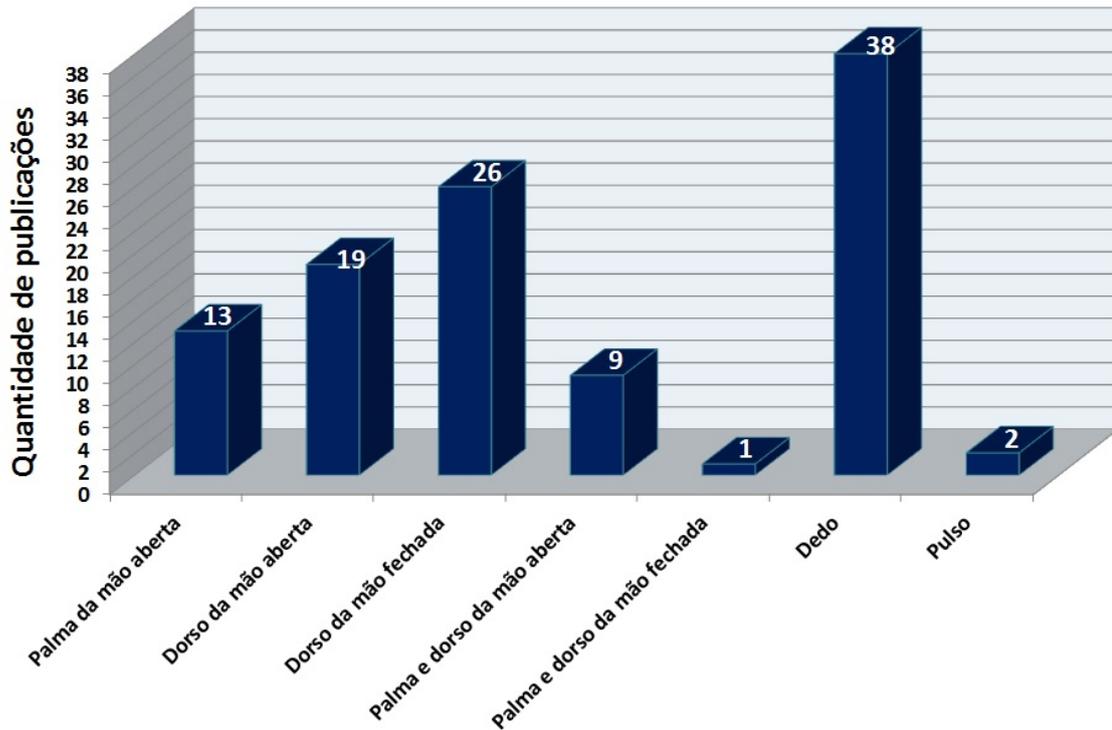


Fonte: Produção do próprio autor

Quanto ao tipo de imagem obtida, foram avaliados todos os trabalhos que analisaram o padrão de veias da região das mãos, sendo que estes padrões foram extraídos das palmas das mãos, da parte dorsal das mãos com a mão fechada e com a mão aberta, sistemas multiclassificadores que utilizaram imagens tanto da palma quanto da parte dorsal das mãos, dos dedos e do pulso. Abaixo no Gráfico 5 pode-se verificar a quantidade de trabalhos analisados de acordo com cada característica já comentada. Neste gráfico, pode-se perceber que o maior enfoque de pesquisa está na análise de padrão de veias dos dedos, que representam cerca de 35,8% dos trabalhos já publicados (38 análises entre 106 trabalhos, lembrando que o total foi de 160 trabalhos, mas que apenas 106 especificaram o uso de algum padrão de veia analisado).

Foram analisados ainda 7 sistemas multimodais que utilizaram o padrão de veias das mãos, dedos e pulso em conjunto com outros sistemas como a impressão digital da mão, mas em todos os casos, o sistema apresenta melhoria nos índices de identificação e proporcionalmente aumento no tempo de processamento, inviabilizando-os quanto ao uso em sistemas com muitos usuários cadastrados. Os melhores tempos de resposta conseguidos foram com o uso de *hardware* dedicado (uso de FPGAs) e este tempo ficou em torno de $10\mu s$ para sistemas

Gráfico 5 - Padrões de veias analisados



Fonte: Produção do próprio autor

unimodais, e os melhores tempos em sistemas multimodais ficou em torno de $900ms$.

Foram ainda analisados 4 trabalhos que trataram especificamente a possibilidade de fraudes nestes sistemas, e 2 trabalhos que analisaram a legislação específica sobre este assunto. Em relação à análise final da revisão bibliográfica, considera-se que os métodos de esqueletonização se esgotaram, pois por volta do ano de 2010 não surgiram novos trabalhos inovadores, os resultados que foram apresentados chegaram ao melhor método possível. Quanto aos métodos de vetorização, não surgiram novos trabalhos, e os resultados apresentaram baixos índices de confiabilidade, e os métodos de extração de características que extraem frequências das imagens são os mais viáveis para estudos pois no passado seu uso era inviabilizado pelo processamento das imagens requererem alto desempenho computacional, o que já não é um empecilho na atualidade.

4 MATERIAIS E MÉTODOS

Neste capítulo serão demonstradas as etapas de desenvolvimento do projeto proposto. Inicialmente um protótipo foi criado para a aquisição das imagens, e o detalhamento de todo o desenvolvimento está descrito abaixo. A seguir, serão apresentados os algoritmos utilizados para devido tratamento de imagens obtidas e o método de identificação de pessoas.

4.1 PROTÓTIPO PARA AQUISIÇÃO DAS IMAGENS

Após a revisão bibliográfica sobre o tema, nota-se que de 160 trabalhos analisados, apenas 3 comentaram sobre um banco de imagens disponível, no entanto, somente um destes bancos está acessível. Após análise do conteúdo, foi concluído que seria interessante obter as próprias imagens com alguns recursos que nunca haviam sido utilizados. A partir desta proposta, foram analisadas todas as câmeras utilizadas em outros trabalhos e citadas como sendo de “baixo custo”, e percebe-se que todas são de baixa resolução e foco manual. Com esta informação, foi definida a pesquisa sobre câmeras de baixo custo que tivessem recursos mais avançados em relação às câmeras relatadas na revisão bibliográfica e escolhido o modelo C525 da empresa *Logitech*. A mesma possui os seguintes recursos: (LOGITECH, 2014)

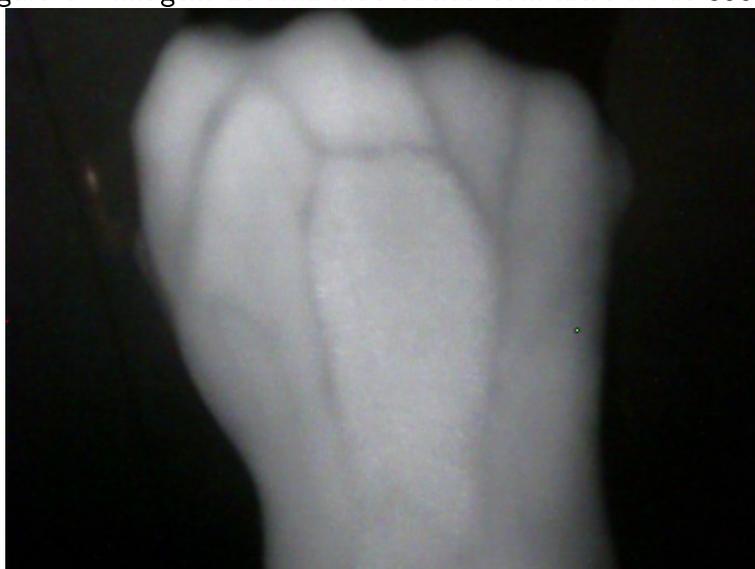
- Videochamada HD (1280 x 720 *pixels*) com sistema recomendado;
- Captura de vídeo HD em até 1280 x 720 *pixels*;
- Tecnologia *Logitech Fluid Crystal™* ;
- Foco automático;
- Fotos com até 8 *megapixels* (com otimização do *software*);
- Microfone embutido com tecnologia *Logitech RightSound™* ;
- USB 2.0 de alta velocidade certificado;
- Clipe universal que se ajusta a *laptops* e monitores LCD ou CRT.

Os recursos mais importantes a serem utilizados neste trabalho são o foco automático e a alta resolução da câmera, até então não utilizados como recursos nos projetos que utilizaram câmeras de baixo custo, caracterizando assim uma opção original. A intenção neste projeto é de obter imagens da parte dorsal das mãos utilizando para isto iluminação infravermelha no espectro próximo, também chamado de *Near Infrared*. Esta câmera escolhida contém um sensor CCD capaz de obter imagens neste espectro, no entanto, como se trata de um

equipamento de uso comercial, normalmente os fabricantes instalam um filtro sobre o sensor para que a luz penetrante seja somente no espectro visível, impedindo que o infravermelho passe para evitar assim ruídos nas imagens. A primeira etapa a ser realizada desta forma é a abertura da câmera para verificação da existência deste filtro, e em caso afirmativo, a retirada do mesmo. Após abertura da câmera, foi necessário remover o conjunto das lentes para verificar a existência do filtro. Trata-se de um vidro levemente esverdeado, que brilha em tom avermelhado muito intenso ao girá-lo e posicioná-lo contra uma fonte de luz.

Com a remoção do filtro, a câmera é capaz de obter imagens em todo o espectro de luz, no entanto, o que interessa é luz com comprimento de onda entre $700nm$ a $1100nm$. Para isto, deve ser instalado um filtro específico. Na revisão da bibliografia, autores citaram três possibilidades: filtro IR, negativo fotográfico “velado” (exposto à luz solar para ficar preto) e disquete. Foram realizadas tentativas com filme fotográfico e com disquete pois estes visavam o baixo custo, mas os resultados não foram satisfatórios. Foi utilizado então um filtro IR com pico de passagem em $850nm$, $67mm$ de diâmetro, de marca *Hoya*. Com o filtro instalado sobre a lente da câmera na parte externa da mesma, foi realizada a captura da imagem de uma mão. O resultado foi satisfatório, e pode ser visto na Figura 3.

Figura 3 - Imagem de uma mão obtida com filtro IR de $850nm$



Fonte: Produção do próprio autor

Para a instalação da câmera, foi criado um protótipo. Em diversos estudos os protótipos criados variaram de acordo com a criatividade dos autores dos projetos. Nenhum trabalho conseguiu expor algum detalhe importante, a não ser quanto às características estéticas e das dimensões para uso comercial. As análises feitas na revisão da bibliografia trataram os trabalhos sobre padrões de veias das mãos, dedos e pulso, e alguns protótipos específicos foram criados para a análise de dedos, como por exemplo um leitor em forma de cunha para posicionamento da mão em uma única posição, evitando assim a rotação do dedo no momento

da aquisição da foto, mas quando se trata da captura de imagens das mãos, nada muito específico foi criado até o momento. Neste projeto, foi pensado em um protótipo robusto, para que futuramente pudesse ser utilizado em um sistema real, e que impedisse ao menos parcialmente a entrada de luz natural proveniente do ambiente onde o mesmo seria instalado, pois mesmo com a instalação de uma lente que não permita a passagem de luz visível, o espectro infravermelho está presente nos ambientes, podendo prejudicar a iluminação da mão a ser analisada. Foi criado então um cubículo com 30cm de lado, com perfis extrudados em alumínio com 30mm de lado (perfil quadrado), pés niveladores em *nylon*, e suportes superiores para transporte. As laterais, topo, base e fundo foram fechados com placas de fibra de madeira de média densidade do tipo *Medium Density Fiberboard* (MDF) de 6mm de espessura cada, revestidas com melamina branco, deixando aberta somente a parte frontal do cubículo para a entrada da mão. Na base do protótipo, foi construída uma estrutura quadrada com 20cm de lado e 2cm de altura, e tampada com acrílico transparente de 5mm , pensando-se em utilizar esta base como apoio da mão no momento da aquisição da imagem.

4.1.1 Sistema de iluminação

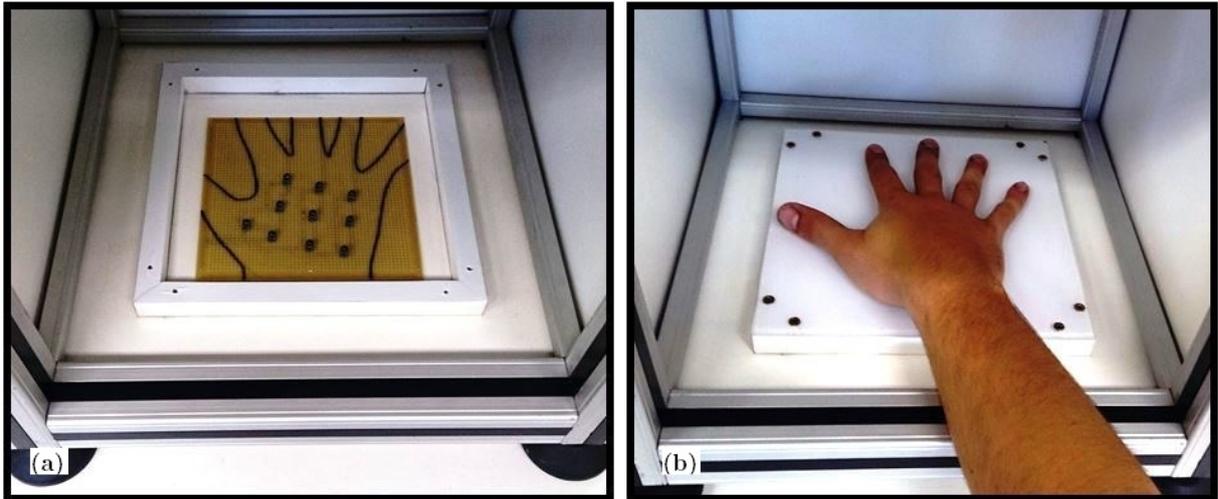
Em todos os projetos analisados, o sistema de iluminação infravermelha utilizou LEDs de modelos diferentes. Os fabricantes foram citados e na prática os LEDs em geral emitem luz no espectro de 720nm , 850nm e 940nm (três modelos mais utilizados). Na escolha de qual melhor LED a ser utilizado, o LED de 720nm está muito próximo do espectro de luz visível, inclusive pode-se notar a olho nu o tom avermelhado quando o mesmo está energizado e este não é o pico de maior absorção de luz pela hemoglobina segundo XiaoXia (2004). O LED de 850nm não emite luz visível e seu pico está exatamente na região de maior absorção de luz pela hemoglobina segundo Wang et al. (2006)b, e este foi o componente escolhido para uso no projeto. Ainda comentando-se sobre o LED de 940nm , sua absorção pela hemoglobina é de praticamente apenas 30% segundo Bin et al. (2009), que no caso deste autor em específico, foi suficiente para captura das imagens, mas os filtros neste espectro são caros (da ordem de três a seis vezes o custo do filtro de 850nm) e são pouco utilizados, portanto, difíceis de serem encontrados para compra. Segundo XiaoXia (2004), os índices de refração entre a luz infravermelha e as diversas estruturas das mãos são muito maiores que os índices de absorção pela hemoglobina, no entanto, as veias tem o efeito de refração muito maior que as outras estruturas, e a hemoglobina apresenta o mesmo efeito, portanto, ao aplicar a radiação infravermelha sobre a mão, a maior parte da imagem aparece em um tom claro, enquanto que as veias aparecem escuras. Seja pela absorção de luz pela hemoglobina, seja pelo efeito de refração pelas veias, o sistema de iluminação é eficiente neste caso.

Os projetos existentes utilizam um único componente de luz (barra com LEDs dispostos em linha), dois conjuntos lineares de LEDs dispostos lado a lado, ou conjuntos concêntricos instalados a mesma região da câmera. Segundo os autores Zhao, Wang e Wang (2007) a luz incidida diretamente sobre a mão apresenta baixo contraste, no entanto, é mais difusa, e se espalha diminuindo regiões muito claras ou muito escuras (homogeneidade). Quando a luz é aplicada ao lado contrário da câmera, fazendo com que a mesma ultrapasse a mão (chamado de modo penetrante pelos autores), o contraste é muito melhor (as veias aparecem com mais nitidez), no entanto, são criadas regiões heterogêneas, dificultando a aplicação de filtros. Quanto à direção, as bordas das mãos apresentam menor volume enquanto que o centro das mãos apresentam maior volume, portanto, ao aplicar luz sobre a mão em uma única posição, é normal iluminar melhor as bordas que o centro da mão. Pensando em todos estes detalhes, foi escolhido um sistema híbrido visando diminuir todos estes efeitos. Foram criados quatro conjuntos lineares de LEDs infravermelhos, com 10 LEDs cada conjunto, e instalados na parte superior do protótipo, dispostos a 45 graus em relação ao topo, direcionando dessa forma luz em todas as direções diretamente sobre a mão.

Os LEDs apontados diretamente para a mão podem gerar pontos de luz mais fortes em algumas regiões e para tentar diminuir estes efeitos, foram criados difusores de luz baseados em um material fino de PVC transparente, e recoberto por um plástico adesivo na cor branca. Este sistema instalado não foi observado em nenhum outro trabalho, mas também é conhecido o fato de que a luz aplicada diretamente sobre a mão não gera bom contraste. Para resolver este problema, foi criado um conjunto de LEDs na base do protótipo (composto por 10 LEDs), dispostos na região palmar, sem a preocupação de iluminar os dedos, que posteriormente serão eliminados nas análises. A Figura 4 (a) apresenta este conjunto instalado e a Figura 4 (b) apresenta a tampa de acrílico instalada, e a mão de um usuário na posição de captura da imagem. Este sistema faz com que a luz atravesse a mão, melhorando assim o contraste da imagem a ser capturada. Para diminuir a concentração de luz em pontos específicos (diminuir a heterogeneidade da iluminação), foi instalada uma tampa de acrílico sobre os LEDs com um plástico adesivo branco colado na parte inferior do acrílico, servindo de difusor de luz. Os quatro conjuntos instalados no topo do protótipo apresentam boa iluminação mas baixo contraste (luz direta) enquanto que os LEDs instalados na base do protótipo geram alto contraste mas baixa heterogeneidade. A hipótese levantada é que a instalação dos dois conjuntos compensem as deficiências individuais, pois este tipo de sistema não foi utilizado até então.

Ainda pensando-se em ter um sistema eficiente de iluminação, foi criado um conjunto com 16 LEDs a serem instalados no mesmo local de instalação da câmera. Dessa forma, o conjunto total de iluminação consiste em 66 LEDs, e é a combinação dos três tipos de iluminação encontrados na bibliografia. Como não havia dispositivo para medição do espectro emitido

Figura 4 - Conjunto de LEDs na base do protótipo



Fonte: Produção do próprio autor

por cada LED, foi feita a opção de compra de LEDs de mesma característica mas de fabricantes diferentes (*Optek* e *Everlight*), na tentativa de garantir que ao menos parte da luz realmente estivesse focada em $850nm$.

Para este conjunto de LEDs também foi criado um difusor de luz como o já descrito. A base criada para a câmera foi feita utilizando uma chapa quadrada de alumínio com $20cm$ de lado e $2mm$ de espessura, e o difusor foi criado para cobrir toda esta área, deixando apenas espaço no centro para a fixação da câmera e do filtro infravermelho.

Para o controle da iluminação, foram criados circuitos eletrônicos independentes, compostos por potenciômetros. O painel criado contém seis potenciômetros, responsáveis pelos ajustes dos seguintes componentes:

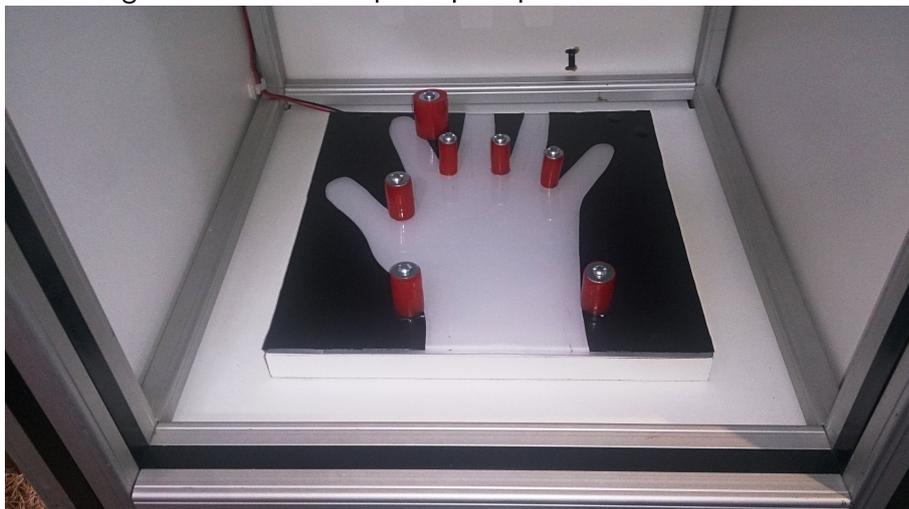
- Potenciômetro 1 = ajuste da iluminação superior barra linear de LEDs frontal;
- Potenciômetro 2 - ajuste da iluminação superior barra linear de LEDs superior esquerda;
- Potenciômetro 3 = ajuste da iluminação superior barra linear de LEDs superior traseira;
- Potenciômetro 4 = ajuste da iluminação superior barra linear de LEDs superior direita;
- Potenciômetro 5 = ajuste da iluminação inferior, base da mão;
- Potenciômetro 6 = ajuste da iluminação superior, câmera.

Toda a alimentação do circuito dos LEDs é feita com uma fonte de alimentação *Direct Current* (DC) de $24V_{cc}$ e $50W$, alimentação de $90Vac$ a $240Vac$, modelo MS-50-5 do fabricante *PWM Steady*. O painel de controle de iluminação e a fonte de alimentação foram fixados na parte traseira do protótipo.

4.1.2 Posicionadores das mãos

Para a captura das imagens, durante o processo de aquisição, notou-se que o usuário tinha grande dificuldade em posicionar corretamente as mãos, alguns colocavam as mãos fechadas, outros colocavam a mão lateralmente ao equipamento, enfim, perde-se grande tempo nas instruções aos usuários quanto ao devido funcionamento do equipamento. Outro problema foi encontrado quanto às dimensões da base, pois alguns usuários colocavam as mãos no fundo do protótipo, fazendo com que a câmera capturasse fotos de parte do braço. No intuito de resolver estes problemas, capturar imagens somente da região de interesse e diminuir o tempo de aquisição de imagens gasto com instruções iniciais de uso a cada usuário, foram instalados pinos na base do protótipo, sendo três pinos de poliuretano vermelho com 10mm de diâmetro e 15mm de altura posicionados exatamente nos “vales” entre os dedos indicador, médio e anelar. No “vale” entre o polegar e o dedo indicador, foi instalado um pino de mesmo material mas com diâmetro de 15mm, e outros dois pinos com este mesmo diâmetro foram instalados lateralmente ao pulso, evitando assim rotação da mão no interior do dispositivo. Ainda foi instalado um pino de mesmo material com 25mm de diâmetro na região à direita da ponta do dedo indicador, que serve de base sobre o correto posicionamento dos dedos. Abaixo na Figura 5 pode-se ver os pinos instalados na base do protótipo e o desenho da mão na mesma base, melhorando assim o posicionamento da mão.

Figura 5 - Base com pinos para posicionamento da mão



Fonte: Produção do próprio autor

Sobre a base, foi colado um material plástico de cor preta no formato de uma mão, para ajudar o usuário a reconhecer de forma automática como este deve posicionar sua mão dentro do equipamento. Esta modificação no protótipo diminuiu o tempo de aquisição das imagens, que estavam sendo realizadas em torno de um minuto e meio gastos nas instruções e aquisição de 10 imagens de cada usuário, e passou a ser de apenas 40 segundos. Os pinos foram

instalados com base na mão direita, portanto, esta foi a mão padronizada nas análises deste trabalho.

Com o protótipo montado, foram então adquiridas imagens para a montagem de um banco de dados. As imagens foram obtidas de 52 alunos de uma faculdade, sendo 10 imagens de cada usuário, totalizando 520 imagens, e foram salvas no formato *Joint Photographics Experts Group* (JPEG). Os arquivos foram salvos com dados de cada usuário, e a identificação foi feita utilizando o número de matrícula, como forma de preservar a identidade das pessoas que se propuseram a colaborar na fase de coleta das imagens. Ainda no arquivo, foram salvos dados como sexo, altura, peso e idade, para que em análises futuras possam ser cruzadas estas informações com as taxas de falsa aceitação e falsa rejeição. O formato dos nomes dos arquivos segue o padrão AAAAAAAA_B_CCC_DD_EE(F), e cada informação dentro desta *string* tem o seguinte significado:

- AAAAAAAA = número de matrícula na faculdade onde o usuário estuda, composto por oito números;
- B = sexo, que pode ser M (masculino) ou F (feminino);
- CCC = altura em centímetros;
- DD = peso corporal em quilogramas;
- EE = idade em anos;
- (F) = amostra da imagem, variando de zero a 9, de acordo com a ordem de aquisição.

A partir das imagens obtidas, é necessário tratar estas imagens de modo a garantir homogeneidade, e eliminar possíveis influências do ambiente. Esta etapa é comumente chamada de pré-processamento, e nesta tese, foram escolhidas três técnicas de equalização. Na fase de classificação dos dados, serão testadas as técnicas de equalização global do histograma, mapeamento e ajuste de intensidade de cinza e equalização de histograma adaptativa por limite de contraste. Também são testadas classificações sem nenhum método de equalização para se comprovar qual é o melhor procedimento a ser adotado no sistema. A seguir, são expostas as técnicas de equalização utilizadas nesta tese.

4.1.3 Equalização global do histograma

Trata-se de uma técnica utilizada em tratamento de imagens digitais com o intuito de ajustar as intensidades dos níveis de cinza para melhoramento do contraste. Esta é a técnica de melhoramento de contraste das imagens mais comentada e utilizada nos trabalhos analisados

na revisão bibliográfica desta tese, portanto, foi escolhida para análise. Ainda comentando sobre este método, vários autores o citam como equalização global do histograma da imagem. A seguir é relatado o princípio de funcionamento do algoritmo desta análise aplicado às imagens:

Seja f uma determinada imagem representada como uma matriz m_r de intensidades de *pixels* variando de 0 a $L - 1$ onde L é o número de possíveis valores de intensidade que normalmente representam o valor máximo igual a 256 por tratarem de imagens com resolução de oito *bits*. Seja h a grandeza que representa o histograma normalizado da imagem I com um *bit* para cada intensidade possível. Dessa forma, pode-se descrever a Equação 1 abaixo como:

$$p_n = \frac{\text{número de pixels com intensidade } n}{\text{número total de pixels}} \quad n = 0, 1, 2, \dots, L - 1. \quad (1)$$

A imagem com o histograma equalizado será definida pela Equação 2:

$$g_{i,j} = \text{base}((L-1) \sum_{n=0}^{f_{i,j}} p_n), \quad (2)$$

onde a base é arredondada para um menor valor, aproximando-se do número inteiro mais próximo. O processo é equivalente a transformar as intensidades de *pixel*, k , de f pela função definida na Equação 3:

$$T(k) = \text{base}((L-1) \sum_{n=0}^k p_n). \quad (3)$$

Considera-se neste caso que a transformação dessa imagem supõe que as intensidades de f e g são variáveis aleatórias contínuas X , Y em $[0, L - 1]$ com Y definidas pela Equação 4:

$$Y = T(X) = (L-1) \int_0^X p_X(x) dx, \quad (4)$$

onde p_X é a função de densidade de probabilidade de f . T é a função de distribuição acumulativa de X multiplicado por $(L - 1)$.

4.1.4 Mapeamento e ajuste de intensidade de cinza

Outra ferramenta para ajuste e melhoramento do contraste em imagens é o mapeamento dos valores de intensidade de níveis de cinza. Os valores de escala de cinza são mapeados e rastreados para ajuste em uma região limiar, de tal forma que sejam definidas escalas de valor mínimo e valor máximo. Caso o valor do *pixel* analisado ultrapasse estas escalas, tanto em nível superior que o máximo ou abaixo do mínimo, o *pixel* é saturado nestes parâmetros. Os

parâmetros que compõem a aplicação no *software Matlab*[®] permitem variação de valores de 0 a 1, independente da classe dada à imagem a ser analisada. Não foram encontrados trabalhos acadêmicos que apresentaram seus resultados com este tipo de aplicação para análise de resultados, então o mesmo foi utilizado na aplicação do algoritmo sobre a mesma imagem utilizada na equalização do histograma para validação ou rejeição de sua aplicabilidade em biometria.

4.1.5 Equalização de histograma adaptativa por limite de contraste

Conhecido pela sigla *Contrast Limited Adaptive Histogram Equalization* (CLAHE), é uma técnica similar à equalização global do histograma mas aplicado em pequenas regiões, denominando essas pequenas regiões como sendo subimagens e analisando a luminosidade de cada seção para encontrar valores ideais de contraste que serão aplicados em toda imagem tratada. Na equalização global do histograma, existe uma característica não desejada do algoritmo amplificar o nível de ruído em regiões relativamente homogêneas do ponto de vista do contraste, e o método CLAHE impede este efeito através da limitação da amplificação do contraste. Para que este método possa ser utilizado é necessário especificar o parâmetro de vizinhança, que representa quantos *bits* em torno de um único *bit* serão utilizados para se aplicar a equalização global do histograma nesta pequena região. (ZUIDERVELD, 1994)

O método CLAHE pode ser dividido em passos descritos pelas Equações 5, 6, 7 e 8 abaixo:

$$N_{m\u00e9dio} = \frac{N_{CR-X_P} \cdot N_{CR-Y_P}}{N_{cinza}} \quad (5)$$

onde:

$N_{m\u00e9dio}$ é o número médio do *pixel* ;

N_{cinza} é o número de níveis de cinza na região analisada;

N_{CR-X_P} é o número de *pixels* na dimensão x (eixo de coordenadas cartesianas) da região analisada;

N_{CR-Y_P} é o número de *pixels* na dimensão y (eixo de coordenadas cartesianas) da região analisada.

Baseado na Equação 5 acima, o índice de limite de contraste N_{CL} pode ser calculado pelo produto entre o múltiplo máximo da média dos *pixels* em cada nível de cinza da região analisada N_{clip} e o número médio de *pixels* $N_{m\u00e9dio}$, demonstrado na Equação 6 abaixo:

$$N_{CL} = N_{clip} \cdot N_{m\u00e9dio} \quad (6)$$

Com base nas equações acima, pode-se calcular o CLAHE da região contextual, e as regras

são dadas abaixo pela Equação 7:

$$\text{Se } H_{CR}(i) > N_{CL}, H_{NCR}(i) = N_{CL};$$

$$\text{Senão se } H_{CR}(i) + N_{acp} \geq N_{CL}, H_{NCR}(i) = N_{CL}; \quad (7)$$

$$\text{Senão } H_{NCR}(i) = H_{CR}(i) + N_{acp}$$

Após a análise das regras acima, o restante dos *pixels* cortados são expressos por N_{LP} , então a distribuição de *pixels* é dada pela Equação 8 abaixo:

$$S = \frac{N_{cinza}}{N_{LP}} \quad (8)$$

4.2 EXTRAÇÃO DAS CARACTERÍSTICAS BIOMÉTRICAS

Após a aquisição da imagem, extração da região de interesse e pré-processamento para melhoramento do contraste, é necessário extrair as suas características, de forma a criar um vetor digital para a devida comparação no sistema de identificação biométrica. De acordo com a revisão bibliográfica, o método mais aplicado no início das pesquisas sobre biometria utilizando o padrão de veias das mãos é a esqueletonização da imagem, transformando toda a resolução desta em padrões preto e branco, afinando as veias a um único *pixel* através de técnicas de *threshold* e binarização destes dados, considerando informação igual a zero quando o *pixel* é preto e informação igual a um quando o *pixel* é branco. Esta é uma técnica eficiente, mas um sistema que chegou às limitações do próprio sistema, conseguindo eficiência nas melhores aplicações de aproximadamente 100% na identificação. Outro método muito utilizado é a vetorização das características da imagem através de técnica conhecida como *line tracking*. Neste método, o esforço computacional é maior que nos métodos que utilizam a esqueletonização, pois as informações da imagem são armazenadas em matrizes com dados como direção das veias, rotações possíveis e outros dados que teoricamente aumentariam a eficiência, mas os sistemas que apresentam esta técnica mostram índices de acerto menores que os índices de esqueletonização. O terceiro método é a extração de características da imagem utilizando uma abordagem espectral através da aplicação da série de *Fourier*, extraíndo assim frequências da imagem. Estas técnicas são pouco usadas pois necessitam de muito processamento computacional, e como os trabalhos apresentados na revisão bibliográfica que utilizaram esta técnica tem mais de quatro anos, nesta época os sistemas computacionais não suportavam

tais tentativas (realizavam a extração mas em tempos elevados tornando a aplicação prática inviável). A representação desta imagem consiste em representar suas características internas através da análise dos *pixels* que denominam as características morfológicas da imagem ou então analisar as características externas quando o interesse não está na textura da imagem e sim na sua forma. Neste caso, o interesse está na região interna da imagem extraída chamada de ROI pois é a região que compõe as veias e a textura destas é de interesse neste estudo. A textura a ser analisada é descrita pelas medições quantitativas de suas propriedades de regularidade, rugosidade e suavidade, e as abordagens podem ser realizadas de forma estatística, estrutural ou espectral. O interesse em aplicar análise de textura neste trabalho é característico da abordagem espectral. (GONZALEZ; WOODS, 2001)

Quanto ao uso em si da transformada *Curvelet* em análises biométricas, não foi encontrado nenhum trabalho anterior que utilizou este método para extração de características de veias das mãos, portanto, a investigação sobre a viabilidade deste método foi feita em outras fontes. O trabalho dos autores Dettori e Semler (2007) realiza a comparação entre as transformadas de *Wavelet*, *Ridgelet* e *Curvelet* na extração de características de diversos tecidos humanos em tomografias computadorizadas. Segundo os autores, foram testados valores de extração com 2, 4 e 6 escalas e ainda 12, 14, 16, 18 e 20 ângulos nos parâmetros da transformada de *Curvelet* e os melhores resultados foram obtidos com 4 escalas e 16 ângulos. Os resultados apresentados mostram que as transformadas de *Wavelet*, *Ridgelet* e *Curvelet* são eficientes na extração de características, no entanto, a transformada de *Curvelet* é mais eficiente que os outros métodos, pois apresentam índices de precisão e exatidão maior em qualquer componente humano testado. Para a identificação de diversos tecidos humanos em tomografias computadorizadas, os índices são apresentados na Tabela 1:

Pode-se verificar na Tabela 1 que em todos os tipos de tecidos analisados, a transformada *Curvelet* foi mais precisa, e o método da transformada *Curvelet* adotado pelos autores foi a *Fast Discret Curvelet Transform* (FDCT) utilizando a função *wrapping*. (DETTORI; SEMLER, 2007)

Em outro trabalho similar, os autores AlZubi, Islam e Abbod (2011) utilizaram os três métodos citados acima para a segmentação e filtragem de imagens, e afirmam que a transformada *Curvelet* é mais precisa na reconstrução de imagens, na detecção de áreas de interesse e ainda no processo de diminuição de ruídos.

O trabalho dos autores Eltoukhy, Faye e Samir (2010) propõe um sistema que compara o uso das transformadas *Wavelet* e *Curvelet* na extração de características de imagens médicas, mais especificamente em mamografias digitais, e para isto, utilizaram o banco de imagens da *Mammographic Image Analysis Society* (MIAS) composto por 322 mamogramas provenientes de 161 pacientes, dos quais 51 casos foram considerados com câncer maligno, 64 casos com

Tabela 1 - Resultados da análise comparativa entre *Wavelet*, *Curvelet* e *Ridgelet*

| ÓRGÃO | DESCRIPTOR | SENSIBILIDADE | PRECISÃO | EXATIDÃO |
|---------|-----------------|---------------|----------|----------|
| Coluna | <i>Curvelet</i> | 99,4% | 95,3% | 98,9% |
| | <i>Ridgelet</i> | 91,5% | 96,8% | 98,0% |
| | <i>Wavelet</i> | 82,6% | 82,6% | 93,7% |
| Coração | <i>Curvelet</i> | 89,7% | 95,5% | 97,1% |
| | <i>Ridgelet</i> | 82,5% | 88,5% | 94,6% |
| | <i>Wavelet</i> | 59,0% | 67,0% | 85,0% |
| Rim | <i>Curvelet</i> | 96,0% | 93,5% | 97,6% |
| | <i>Ridgelet</i> | 95,4% | 82,0% | 93,8% |
| | <i>Wavelet</i> | 77,7% | 69,9% | 88,6% |
| Fígado | <i>Curvelet</i> | 95,9% | 94,3% | 98,0% |
| | <i>Ridgelet</i> | 86,9% | 84,4% | 94,0% |
| | <i>Wavelet</i> | 87,3% | 82,6% | 92,8% |
| Baço | <i>Curvelet</i> | 91,8% | 94,9% | 97,6% |
| | <i>Ridgelet</i> | 76,9% | 88,0% | 93,8% |
| | <i>Wavelet</i> | 65,5% | 69,7% | 89,5% |
| Média | <i>Curvelet</i> | 94,6% | 94,7% | 97,9% |
| | <i>Ridgelet</i> | 86,6% | 88,0% | 94,8% |
| | <i>Wavelet</i> | 74,4% | 74,4% | 89,9% |

Fonte: (DETTORI; SEMLER, 2007)

câncer benigno e 207 casos considerados como normais. Na aplicação da transformada *Wavelet*, os autores empregaram quatro níveis de decomposição, e para a transformada *Curvelet*, utilizaram a técnica *wrapping* com 4 escalas e 16 ângulos. Os resultados obtidos sobre a comparação entre imagens com câncer benigno, maligno e sem câncer apresentaram índices sobre a transformada *Wavelet* de 90,05%, 86,75%, 85,5% e 85,5%, para os quatro níveis de decomposição utilizados enquanto que a transformada *Curvelet* apresentou taxa de acerto de 94,07%, mostrando assim ser uma ferramenta capaz de extrair informações de imagens com o intuito de identificação de padrões.

Visto que a transformada *Curvelet* é o algoritmo mais atual e eficiente na extração de características de imagens, este será o método aplicado neste trabalho. Para utilização do algoritmo, foi necessário realizar um cadastro no *site* dos autores por *e-mail*, solicitando acesso ao *download* para utilização no *software Matlab*[®]. O processo de geração de senha e liberação de acesso ao *site* levou cerca de três dias e o pacote com as ferramentas para utilização da transformada *Curvelet* sobre o *Matlab*[®] tem cerca de 1,29Mb. (CURVELET, 2007)

A finalidade da transformada *Curvelet* nesta tese é a extração de características das imagens e para isto, a mesma será aplicada em duas dimensões (*i.e.* R^2), com variável espacial x , ω será a variável do domínio da frequência e θ e r serão as coordenadas polares no domínio da frequência. Serão consideradas duas janelas, representadas pelos termos $W(r)$ e $V(t)$ respectivamente, que serão chamadas de janela radial e janela angular, respectivamente, que

são suaves, não negativas e reais, com W tendo argumentos reais e positivos apoiadas em $r \in (1/2, 2)$ e V tendo argumentos reais com suporte em $t \in [-1, 1]$.

4.2.1 Transformada *Curvelet*

A transformada *Wavelet* possui limitações para representação ou decomposição de características em objetos que contém bordas e curvas dispostas na imagem randomicamente e singularidades de linhas, e para solucionar estas falhas Candès (1999) criou uma transformada adaptada da *Wavelet* (mais especificamente da Transformada de *Ridgelet*), conhecida como *Curvelet* e é muito utilizada para remoção de ruídos, decomposição de sinais e extração de características de imagens através da análise de texturas, melhoramento de contraste e diversos outros tratamentos utilizados em processamentos de imagens. (STARCK; CANDÈS; DONOHO, 2002)

Em 1999 foi criada a primeira transformada de *Curvelet* no entanto a aplicação da mesma em tratamento de imagens era dificultada pelo excesso de tempo gasto no processamento, pois esta era uma adaptação da transformada de *Ridgelet* e o particionamento espacial de janelas resultava em uma quantidade muito grande de dados redundantes. Este problema foi resolvido em 2006 pelos mesmos autores quando modificaram a transformada de *Curvelet* com base nas diferentes operações da transformada de *Fourier* chamadas de *Unequally Spaced Fast Fourier Transform* (USFFT) e transformada *Curvelet* baseada em invólucro (do inglês *wrapping*) sendo que esta segunda transformada possui melhor desempenho na extração de características e é mais robusta que os outros métodos já citados.

4.2.2 Transformada *Curvelet* digital

As transformações digitais são lineares e utilizam como matrizes de entradas cartesianas a forma $f[t_1, t_2]$, $0 \leq t_1, t_2 < n$, que permitem considerar o dado de saída como uma coleção de coeficientes $C^D(j, l, k)$ obtidos pelo análogo discreto apresentado na Equação 9:

$$c^D(j, l, k) := \sum_{0 \leq t_1, t_2 < n} f[t_1, t_2] \overline{\varphi_{j,l,k}^D[t_1, t_2]} \quad (9)$$

onde cada $\varphi_{j,l,k}^D$ é uma pequena forma de onda digital (na qual o índice sobrescrito D significa Digital).

4.2.3 Transformada Digital *Curvelet* via "invólucro"

A abordagem invólucro, do inglês "*wrapping*" assume o mesmo processo de coronização digital mostrado na seção anterior, mas faz uma escolha diferente, um pouco mais simples de grade espacial para traduzir *Curvelets* em cada escala e ângulo. Em vez de uma grelha inclinada, assume-se uma grade regular e retangular, e definem-se *Curvelets* "cartesianas", da mesma forma que antes, demonstrado abaixo na Equação 10:

$$c(j, l, k) = \int \hat{f}(\omega) \tilde{U}_j(S_{\theta_l}^{-1}\omega) e^{i\langle b, \omega \rangle} d\omega \quad (10)$$

A dificuldade com esta abordagem é que, no plano das frequências, a janela $\tilde{U}_{j,l}[n_1, n_2]$ não cabe em um retângulo de tamanho $\sim 2^j \times 2^{j/2}$. Depois de discretização, a integral sobre ω torna-se uma soma de n_1, n_2 que pode se estender além dos limites permitidos pela transformada 2D *Inverse Fast Fourier Transform* (IFFT). Para entender por que respeitando tamanhos de retângulos de tamanhos respectivos são uma preocupação, é necessário lembrar que o termo $U_{j,l}$ é suportado na região de paralelepípedo demonstrado na Equação 11:

$$P_{j,l} = S_{\theta_l} P_j. \quad (11)$$

Para a maioria dos valores da variável angular θ_l , $P_{j,l}$ é suportada dentro de um retângulo $R_{j,l}$ alinhado com os eixos, e ambos com comprimentos laterais na ordem de 2^j . Esta definição é bem parecida com a discretização do contínuo direcional da transformada *Wavelet* proposta por Vanderghyest e Gobbers (2002). Isto parece ideal, mas existe uma desvantagem evidente para essa abordagem, a sobreamostragem dos coeficientes. Em outras palavras, considerando que a abordagem anterior mostrou que era possível conceber *Curvelets* com espaçamento espacial anisotrópico de cerca de $n/2^j$ em uma direção e $n/2^{j/2}$ na outra, esta abordagem exige uma grade retangular regular com tamanho lateral sobre $n/2^j$ em ambas as direções. Em outras palavras, seria necessário calcular a ordem de 2^{2j} por coeficientes de escala e o ângulo em oposição, para apenas cerca de $2^{3j/2}$ na implementação baseada em USFFT. Ao analisar as escalas mais finais das *Curvelets* tais que $2^j \asymp n$, essa abordagem exigiria $O(n^{2,5})$ de armazenamento contra $O(n^2)$ para a versão USFFT. É possível diminuir a resolução e a ideia é a periodização das amostras de frequência. Como antes, deixa-se o termo $P_{j,l}$ ser um paralelogramo que contém o suporte de janela de localizações discretas $\tilde{U}_{j,l}[n_1, n_2]$. Supõe-se que em cada escala j , existem duas constantes $L_{1,j} \sim 2^j$ e $L_{2,j} \sim 2^{j/2}$ para cada orientação θ_l . Pode-se preencher o plano bidimensional com tradução de $P_{j,l}$ por múltiplos de $L_{1,j}$ na direção horizontal e $L_{2,j}$ na direção vertical. O correspondente da periodização dos dados das

janelas $d[n_1, n_2] = \tilde{U}_{j,l}[n_1, n_2]\hat{f}[n_1, n_2]$ | pode ser visualizado na Equação 12:

$$Wd[n_1, n_2] = \sum_{m_1 \in \mathbb{Z}} \sum_{m_2 \in \mathbb{Z}} d[n_1 + m_1 L_{1,j}, n_2 + m_2 L_{2,j}] \quad (12)$$

Os dados do “invólucro” janelados, em torno da origem, em seguida são definidos como a restrição de $Wd[n_1, n_2]$ com índices n_1, n_2 dentro de um retângulo com lados de comprimento $L_{1,j} \times L_{2,j}$ perto da origem, segundo a Equação 13::

$$0 \leq n_1 < L_{1,j}, \quad 0 \leq n_2 < L_{2,j} \quad (13)$$

Dados os índices (n_1, n_2) inseridos originalmente pelo termo $P_{j,l}$ (possivelmente mais largos que os termos $L_{1,j}, L_{2,j}$) a correspondência entre o índice de invólucro e o índice original é um para um. Portanto, a transformação de invólucro é um simples método de reindexação dos dados. É possível expressar o método de invólucro pela matriz $d[n_1, n_2]$ ao longo da origem através de um método ainda mais simples, usando a função de módulo, expressa na Equação 14:

$$Wd[n_1 \bmod L_{1,j}, n_2 \bmod L_{2,j}] = d[n_1, n_2], \quad (14)$$

com $(n_1, n_2)P_{j,l}$. Intuitivamente, a operação módulo mapeia o termo original (n_1, n_2) dentro de suas novas posições próximas à origem.

Para os ângulos dentro da área $\theta \in (\pi/4, 3\pi/4)$, o invólucro é similar, depois da troca de regras dos eixos de coordenadas, e esta é a situação apresentada na Figura 6. Pode-se visualizar na Figura 6 que os dados de invólucro, inicialmente dentro de um paralelogramo, se localizam dentro de um retângulo por periodicidade. O ângulo é neste caso a área determinada por $(\pi/4, 3\pi/4)$. O paralelo grama preto é a telha $P_{j,l}$ que contém a frequência de apoio da *Curvelet*, enquanto que os paralelogramos cinzas são réplicas resultantes da periodização. O retângulo é centrado na origem. A elipse resultante do invólucro aparece quebrada em partes mas como pode ser visto, não é uma questão de retângulo periódico, onde as bordas são identificadas.

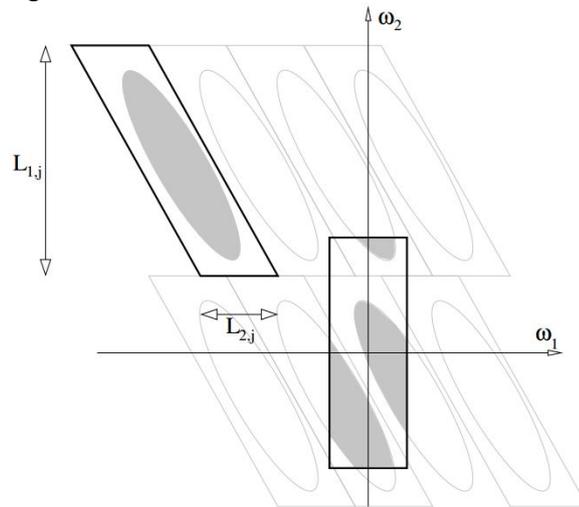
Com estas definições, a arquitetura da FDCT é demonstrada abaixo :

- Aplicar a Transformada Rápida de *Fourier* 2D e obter as amostras

$$\hat{f}[n_1, n_2], \quad -n/2 \leq n_1, n_2 < n/2.$$

- Para cada escala j e ângulo l , forma de produto $\tilde{U}_{j,l}[n_1, n_2]\hat{f}[n_1, n_2]$.
- Envolver este produto ao longo da origem e obter a Equação 15:

Figura 6 - Resultados do método de invólucro



Fonte: (CANDES, 1999)

$$\tilde{f}_{j,l}[n_1, n_2] = W(\tilde{U}_{j,l}\hat{f})[n_1, n_2], \quad (15)$$

onde a área definida por n_1 e n_2 é agora $0 < n_1 < L_{1,j}$ e $0 < n_2 < L_{2,j}$ (para θ dentro da área $(-\pi/4, \pi/4)$).

- Aplicar a Transformada Rápida de *Fourier* 2D Inversa para cada $\tilde{f}_{j,l}$, portanto colecionando os coeficientes discretos $C^D(j, l, k)$.

É evidenciado que o algoritmo tem uma certa complexidade computacional $O(n^2 \log n)$ e na prática, este custo computacional não excede mais que 6 a 10 transformadas rápidas de *Fourier* no plano 2D.

4.3 PROCESSO DE MONTAGEM DO VETOR DE CARACTERÍSTICAS

O processo de obtenção de subimagens por transformada *Curvelet* comentado no item anterior visou extrair as principais características das imagens, mas as subimagens ainda não são digitalizadas. O principal algoritmo utilizado para a binarização de imagens apresentado na revisão bibliográfica é o LBP, e o mesmo será adotado nesta fase do projeto. A principal ideia do algoritmo LBP é de rotular os *pixels* de uma dada imagem baseando-se principalmente nos *pixels* em torno da referência e considerar o resultado desta operação como um número binário.

4.3.1 Operador LBP - “Padrões binários locais”

O início do processamento se dá com a derivação da escala de cinza e do operador de textura de rotação invariante definindo a textura como variável T em um local de vizinhança

de uma imagem com textura monocromática como uma distribuição conjunta dos níveis de cinza de $P(P > 1)$ *pixels* da imagem, representado na Equação 16:

$$T = t(g_c, g_0, \dots, g_{P-1}) \quad (16)$$

onde o índice g_c corresponde ao valor de cinza do *pixel* central da região de vizinhança a ser analisada e o índice $g_p (p = 0, \dots, P-1)$ correspondem aos valores de cinza igualmente espaçados em um círculo de raio $R (R > 0)$ que formam um conjunto de vizinhança simetricamente circular.

Se as coordenadas de g_c são $(0,0)$, então as coordenadas de g_p são dadas pela Equação 17:

$$g_p = (R \sin(2\pi p/P), R \cos(2\pi p/P)). \quad (17)$$

A Figura 7 abaixo ilustra o conjunto de vizinhança simetricamente circular para vários valores de (P, R) . Os valores de cinza de *pixels* de vizinhança que não caem exatamente no centro dos *pixels* são estimados por interpolação.



Fonte: (OJALA; PIETIKAINEN; MAENPAA, 2002)

Como primeiro passo para análise, o algoritmo subtrai os valores de cinza do *pixel* central (g_c) dos valores da vizinhança circularmente simétrica $g_p (p = 0, \dots, P-1)$, dado pela Equação 18:

$$T = t(g_c, g_0 - g_c, g_1 - g_c, \dots, g_{p-1} - g_c) \quad (18)$$

O próximo passo é assumir que as diferenças $g_p - g_c$ são independentes de g_c , portanto permite fatorização resultando na seguinte Equação 19:

$$T \approx t(g_c) t(g_0 - g_c, g_1 - g_c, \dots, g_{p-1} - g_c) \quad (19)$$

Na prática, uma independência exata não é garantida, conseqüentemente, a distribuição fatorizada é somente uma aproximação da distribuição conjunta. Entretanto, é razoável aceitar a possível perda de dados em informações e permitir resultar invariância com respeito aos

desvios na escala de cinza. A saber, a distribuição relatada na Equação 19 descreve no geral a luminância da imagem, que não é relacionada com a textura da imagem local e conseqüentemente não provê informação útil para análise de textura. Conseqüentemente, a maior parte da distribuição conjunta dos níveis de cinza descrita na Equação 16 sobre as características da textura são transportadas pela diferença da distribuição representada pela Equação 20:

$$T \approx t(g_0 - g_c, g_1 - g_c, \dots, g_{p-1} - g_c) \quad (20)$$

Este é um operador de textura altamente discriminante, pois ele registra as ocorrências de vários padrões na vizinhança de cada *pixel* em um histograma $P - dimensional$. Para regiões constantes, as diferenças são zeros em todas as direções. Em uma borda inclinada lentamente, o operador registra as altas diferenças na direção do gradiente e adota valores zero ao longo da borda, no entanto, para um ponto as diferenças são altas em todas as direções. Diferenças $g_p - g_c$ não são afetadas por mudanças como luminância, entretanto, a diferença de distribuição do conjunto é invariante contra os desvios de escalas de cinza. Foi assumida a invariância com respeito à escala cinza considerando justamente os sinais das diferenças em vez de seus valores exatos, resultando na Equação 21:

$$T \approx t(s(g_0 - g), s(g_1 - g_c), \dots, s(g_{p-1} - g_c)) \quad (21)$$

onde:

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (22)$$

Atribuindo um fator binomial 2^P para cada sinal $s(g_p - g_c)$, a Equação 21 pode ser transformada em um único número $LBP_{P,R}$ que caracteriza a estrutura espacial da textura local da imagem, representada pela Equação 23:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (23)$$

O nome “Padrão Binário Local” reflete à funcionalidade do operador, isto é, um local de vizinhança é limitado ao valor de escala cinza do *pixel* central de uma região dentro de um padrão binário. O operador $LBP_{P,R}$ é invariante por definição contra a transformação monotônica da escala de cinzas, isto é, desde que a ordem dos valores de cinza na imagem permaneçam a mesma, a saída do operador $LBP_{P,R}$ permanece constante. (OJALA; PIETIKAINEN; MAENPAA, 2002)

Após extração de subimagens com a transformada *Curvelet*, foi aplicado o operador LBP definido na Equação 23 a cada subimagem, utilizando os parâmetros $P=8$ e $R=2$. Estes parâmetros foram escolhidos devido o trabalho de Nanni, Brahmam e Lumini (2012).

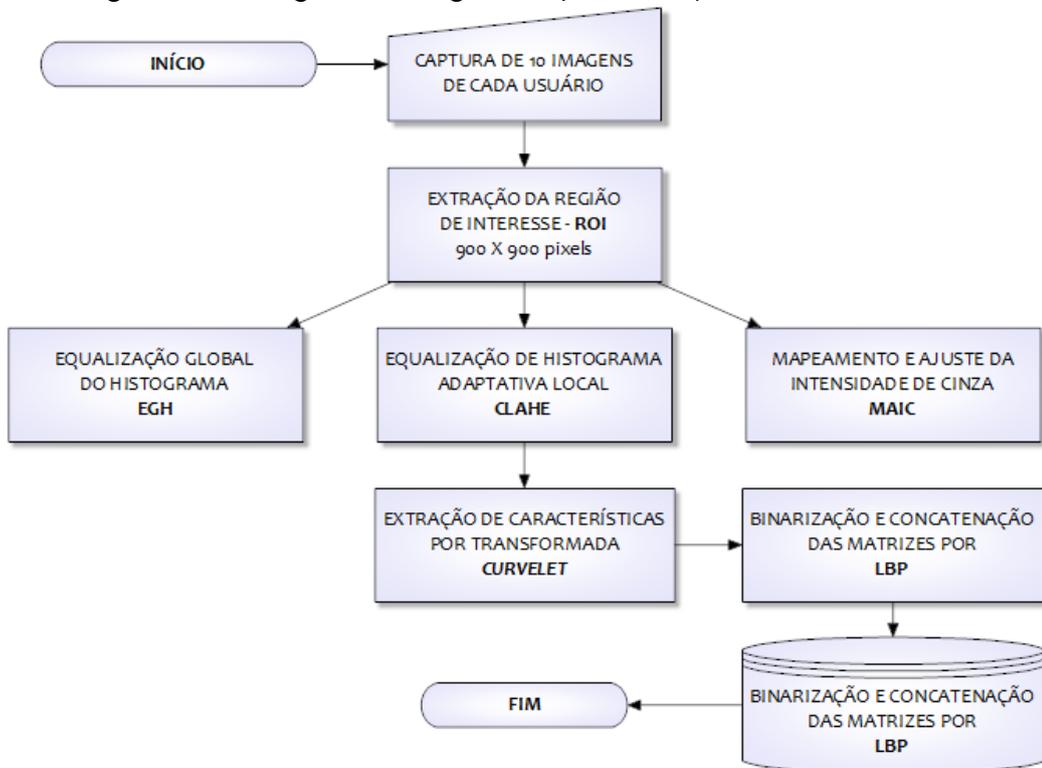
Como são geradas diversas subimagens de acordo com a variação de escalas e ângulos escolhidos (parâmetros *Curvelet* definidos como escala variando de 1 a 5 e ângulo variando entre 8 ou 16), são gerados também diversos vetores provenientes do operador LBP, dessa forma é necessário gerar um único vetor de características, e isto foi realizado concatenando todos os vetores gerados conforme Equação 24 abaixo:

$$V_{CARAC} = (V_{LBP_{S_1}}, V_{LBP_{S_2}}, V_{LBP_{S_3}}, \dots, V_{LBP_{S_n}}) \quad (24)$$

onde V_{CARAC} é o vetor de características que identificam uma pessoa no banco de dados de imagens, e os vetores $V_{LBP_{S_x}}$ são provenientes de cada subimagem gerada.

Abaixo na Figura 8 pode-se visualizar um fluxograma da fase de aquisição, pré-processamento e extração de características das imagens obtidas. Verifica-se que na fase de equalização e melhoramento do contraste da imagem, foram utilizadas três técnicas diferentes. Na extração de características, os parâmetros da transformada *Curvelet* variaram de 1 a 5 escalas e 8 ou 16 ângulos, resultando em 10 análises diferentes.

Figura 8 - Fluxograma do algoritmo para extração de características



Fonte: Produção do próprio autor

4.4 SELEÇÃO DE ATRIBUTOS

Esta fase do trabalho consiste em analisar a variância dos dados por métodos estatísticos para verificação de padrões de repetição, e eliminação de características que não definam diferenças entre as imagens, diminuindo assim o tamanho dos arquivos e aumentando a velocidade de processamento. Na revisão bibliográfica, foram citados diversos algoritmos capazes de extrair características de imagens, e muitos deles também são utilizados como redutores (selecionadores) de características, como os algoritmos PCA e LDA, utilizados por Mandal, Wu e Yuan (2009).

Em análise de imagens, as informações geradas pelos diversos algoritmos podem gerar dados que não são relevantes nas análises. As técnicas de seleção de atributos tem como objetivo avaliar os dados para encontrar as características mais relevantes, ou até eliminar dados que só aumentam o tempo de processamento e não aumentam a precisão do sistema. Os algoritmos LDA e PCA são os mais citados pelos autores, e foram testados, no entanto, o tempo de processamento dos mesmos foi superior a 20 horas, eliminando qualquer possibilidade de uso em um sistema de identificação de pessoas. Foram então pesquisados outros algoritmos que realizassem o mesmo processo, mas com tempos reduzidos, e os mais indicados foram o algoritmo de correlação *Correlation-based Feature Selection* (CFS) com a propriedade *Greedy Stepwise*, disponível no *software Waikato Environment for Knowledge Analysis* (WEKA), e o algoritmo *Symmetrical Uncert Attribute Eval* (SUAE) com a propriedade *Ranker*, também disponível no *software* WEKA. Abaixo os dois algoritmos utilizados nesta tese para selecionar os atributos a serem utilizados na fase de classificação são brevemente relatados.

4.4.1 Algoritmo CFS

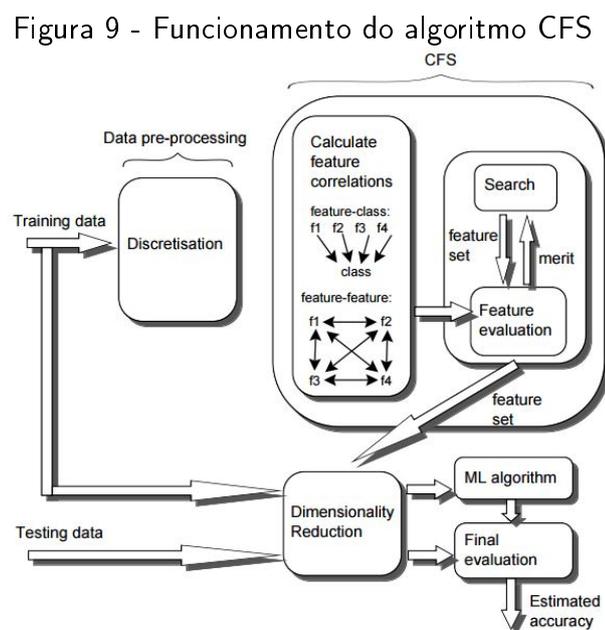
Basicamente trata-se de um filtro que classifica subconjuntos de atributos de acordo com uma correlação baseada na função de avaliação heurística. A principal característica é de avaliar subconjuntos que contenham recursos próprios e altamente correlacionados com a classe, no entanto não se correlacionam entre si. Dessa forma, as características irrelevantes são ignoradas pois terão baixa correlação, e portanto, baixa relevância na avaliação da classe. Os recursos tratados como redundantes são extraídos do grupo ou subconjunto e os recursos que são considerados com alta correlação com uma ou mais características da classe são mantidos. A principal equação que define o algoritmo proposto é apresentado abaixo como

Equação 25:

$$M_S = \frac{k\bar{r}_{cf}}{\sqrt{k + k(k-1)\bar{r}_{ff}}} \quad (25)$$

onde M_S é a heurística "mérito" de um subconjunto S contendo k características, \bar{r}_{cf} é a correlação de classe média do recurso ($f \in S$), e \bar{r}_{ff} é a intercorrelação média. O numerador da Equação 25 pode ser considerado uma indicação do quanto preditiva a classe de um conjunto de características pode ser, e o denominador é a quantidade de redundância existente entre os recursos. A implementação da classe CFS permite escolher entre três estratégias de buscas heurísticas: para a frente (progressão ou antecipação, do inglês *forward selection*), para trás (regressão linear com eliminação, do inglês *backward elimination*), ou pela estratégia do "melhor primeiro" (do inglês *best first*). A seleção *forward selection* se inicia sem recursos e com rapidez acrescenta uma característica de cada vez até que não seja possível acrescentar mais dados. A seleção *backward elimination* começa com o conjunto completo de recursos e rapidamente remove uma característica de cada vez, enquanto a avaliação não degrada o conteúdo. A seleção *best first* pode começar sem nenhum recurso ou todos os recursos. A Figura 9 extraída do trabalho original do autor Hall (1999) exemplifica o algoritmo CFS proposto.

A propriedade *Greedy Stepwise* faz uma busca "gananciosa" nos subconjuntos de cada espaço de atributos. (WITTEN; FRANK, 2005)



Fonte: (HALL, 1999)

4.4.2 Algoritmo SUAE

Trata-se de um algoritmo de seleção de atributos, baseado no conceito da entropia. Em geral, uma característica é boa se for relevante para o conceito de classe, desde que não seja redundante com qualquer das outras características relevantes desta mesma classe. Se for adotada a correlação entre duas variáveis como uma medida, a definição acima relata que uma característica é boa se ela está altamente correlacionada com a classe mas não está altamente correlacionada com qualquer uma das outras características. Em outras palavras, se a correlação entre a característica e a classe é alta o suficiente para torná-la relevante à classe e a correlação entre ela e quaisquer outras características relevantes não atingir um nível de modo que possa ser previsto por qualquer um dos outros relevantes características, esta será considerada como uma boa característica para a tarefa de classificação. Neste sentido, o problema da característica de seleção se resume a encontrar uma medida adequada de correlações entre características e um procedimento para selecionar os recursos com base nesta medida. Existem duas abordagens para medir a correlação entre duas variáveis aleatórias. A primeira é com base na correlação linear clássica e a segunda é com base na teoria da informação. Sob a primeira abordagem, a medida mais bem conhecida é o coeficiente de correlação linear. Para um par de variáveis (X, Y) , o linear coeficiente de correlação r é dado pela Equação 26:

$$r = \frac{\sum_i (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_i (x_i - \bar{x}_i)^2} \sqrt{\sum_i (y_i - \bar{y}_i)^2}} \quad (26)$$

onde \bar{x}_i é a média de X , e \bar{y}_i é a média de Y . O valor de r situa-se entre -1 e 1 , inclusive. Se X e Y são completamente correlacionados, r tem o valor de 1 ou -1 mas se X e Y são totalmente independentes, r é igual a zero. Existem várias vantagens de escolher correlação linear como medida de recurso para a classificação. Em primeiro lugar, proporciona a remoção de recursos com correlação linear para a classe com valores próximos de zero, em segundo lugar, ajuda a reduzir a redundância entre os recursos selecionados. Medidas de correlação linear podem não ser capazes de capturar correlações que não são de natureza linear. Outra limitação é que o cálculo requer que todos os recursos contenham valores numéricos. Para superar estas deficiências, outra abordagem está em escolher uma medida de correlação baseada no conceito de informação teórica da entropia. A entropia de uma variável X é definida pela Equação 27:

$$H(X) = - \sum_i P(x_i) \log_2(P(x_i)), \quad (27)$$

e a entropia de X depois de observar valores de outra variável Y é definida pela Equação

28:

$$H(X|Y) = - \sum_j P(y_j) \sum_i P(x_i|y_j) \log_2(P(x_i|y_j)) \quad (28)$$

onde $P(x_i)$ é a probabilidade para todos os valores de X e $P(x_i|y_j)$ são as probabilidades posteriores de X dados os valores de Y . O valor pelo qual a entropia de X diminui reflete a informação adicional sobre X fornecido por Y e é chamado de informações de ganho, dado pela Equação 29:

$$IG(X|Y) = H(X) - H(X|Y) \quad (29)$$

De acordo com esta medida, uma característica Y é considerada mais correlacionada à característica X do que para característica Z , se $IG(X|Y) > IG(Z|Y)$. (YU; LIU, 2003)

4.5 CLASSIFICADORES PARA AVALIAÇÃO DOS ALGORITMOS PROPOSTOS

Após realizar as etapas anteriores, a próxima abordagem deste trabalho está na classificação e predição dos dados obtidos com as imagens para se avaliar se o método até aqui proposto é válido. Para que esta avaliação seja eficiente, são necessárias diferentes abordagens de avaliação com base em mineração de dados, de forma a analisar a precisão do modelo aqui proposto, e além disso verificar se a velocidade de processamento destas análises não torna o algoritmo invalidado para aplicações práticas. Segundo Han (2005), a escalabilidade, interpretabilidade dos resultados e a robustez também são importantes nesta análise. Existem diversas abordagens diferentes de classificação de dados, e os principais métodos citados na revisão bibliográfica deste trabalho e que serão utilizados para a análise dos dados são:

4.5.1 Métodos *Bayesianos*

Os métodos *bayesianos* são baseados na probabilidade da ocorrência de um evento com relação às condições que podem estar relacionadas a este evento descrito. O início desta teoria se dá com a publicação em 1763 do trabalho de Thomas Bayes. A definição dada Por Thomas Bayes tem como base a premissa de que o método aplicado permite representar dados corretos ou incorretos de incerteza através da análise conjunta de probabilidades. A Equação 30 define o conceito *bayesiano*. (JIAO et al., 2007)

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}, \quad (30)$$

onde A e B são eventos.

$P(A)$ e $P(B)$ são as probabilidades de A e B sem relação de uma com a outra;

$P(A|B)$ é a probabilidade de A dado que B é verdadeiro;

$P(B|A)$ é a probabilidade de B dado que A é verdadeiro.

O classificador *Naive Bayes* é um caso especial das redes *bayesianas*, e se baseia no princípio de se encontrar regras específicas que respondam a perguntas tanto de forma afirmativa quanto de forma negativa a um dado aspecto a ser analisado. Cada dado analisado é chamado de nó da rede e este representa um atributo para a descrição de um domínio de interesse, e o grafo gerado pela rede é interligado, representando a dependência entre os atributos, gerando assim uma amostra de probabilidade distributiva. A principal qualidade deste classificador está na aplicação de conjuntos de dados onde os atributos são independentes entre si. (GU; CERCONE, 2006)

O classificador *Naive Bayes* se encontra disponível para utilização na plataforma WEKA. Os dados gerados a partir da extração por transformada de *Curvelet*, e concatenação por LBP são selecionados no *software* após a geração do arquivo de dados e posteriormente são selecionados os parâmetros para análise. As características de cada parâmetro podem ser vistas abaixo, e após a descrição das características, o texto após a descrição do parâmetro indica o valor adotado para o parâmetro em questão na análise deste algoritmo:

- ***debug*** - Se definido como verdadeiro, o classificador pode gerar saída de informações adicionais para o console = ***FALSE***.
- ***displayModellnOldFormat*** - Usa formato antigo para a saída do modelo. O formato antigo é melhor quando há muitos valores de classe. O novo formato é melhor quando há menos classes e muitos atributos = ***FALSE***.
- ***useKernelEstimator*** - Usa um estimador de *kernel* para atributos numéricos, em vez de uma distribuição normal = ***FALSE***.
- ***useSupervisedDiscretization*** - Usa discretização supervisionada para converter atributos numéricos para nominais = ***FALSE***.

Todos os parâmetros estavam selecionados como ***FALSE*** por padrão de *software* e de acordo com as características de cada um, não foi necessário alterá-los para melhor aplicação do método de classificação. Os resultados gerados são demonstrados no próximo capítulo deste trabalho.

4.5.2 Métodos de aprendizado “preguiçoso”

O termo vem do inglês “*lazy learning*” e trata-se de um método de aprendizagem em que a generalização dos dados de treinamento é adiada até que uma consulta seja realizada ao sistema, no qual a principal vantagem é de se aproximar localmente a função de destino. A base deste método é a regressão linear não paramétrica. O principal algoritmo que utiliza este método é o *Kernel Nearest Neighbor* (KNN) e os estimadores não paramétricos de regressão simples são versões locais de estimadores. Intervalos de confiança podem também ser calculados em cada ponto, ou, se a variância é assumida ser constante, pode ser calculado usando uma estimativa agrupada da variância da população.

Geralmente há apenas uma observação em cada ponto projetado. No entanto, se é sabido que $\mu(t)$ é uniforme, pontos que estão juntos devem ter aproximadamente a mesma média. Assim, se é desejado estimar $\mu(t^*)$, poderia se escolher alguns pontos de t^* e proceder como se os valores dos dados que caem na vizinhança são realmente uma amostra feita no instante t^* . O estimador é então definido pela Equação 31 abaixo:

$$\mu(t^*) = \mu(t^*) + \frac{1}{n^*} \sum_{t_i \in N(t^*)} [\mu(t_i) - \mu(t^*)] + \frac{1}{n^*} \sum_{t_i \in N(t^*)} \varepsilon_i \quad (31)$$

em que $N(t^*)$ é a vizinhança, n^* é o número de pontos de dados na vizinhança, y_i é o dado em t_i , e ε_i é o desvio de y_i de $u(t_i)$. (ALTMAN, 1992)

O classificador *Kernel Nearest Neighbor* também se encontra disponível para utilização na plataforma WEKA. Os mesmos dados utilizados no classificador *Naive Bayes* foram utilizados e os resultados são apresentados no próximo capítulo deste trabalho. As características de cada parâmetro podem ser vistas abaixo, e o texto logo após a explicação de cada parâmetro representa o valor adotado no *software* durante a análise utilizando este algoritmo:

- **KNN** - O número de vizinhos a ser utilizado = **1**.
- **crossValidate** - Se for escolhida validação cruzada, será usado para escolher o melhor valor entre 1 e k o valor especificado como o parâmetro KNN = **FALSE**.
- **debug** - Se definido como verdadeiro, o classificador pode gerar informações adicionais de saída para o console = **FALSE**.
- **distanceWeighting** - Obtém o método de ponderação da distância utilizada = **no distance weighting**.
- **meanSquared** - Se o erro quadrático médio é usado em vez de erro médio absoluto ao executar validação cruzada para problemas de regressão = **FALSE**.

- ***nearestNeighborSearchAlgorithm*** - O algoritmo de busca do vizinho mais próximo a ser utilizado. Para este parâmetro, existem quatro escolhas possíveis, citadas abaixo:
 1. ***BallTree***: O mesmo consiste em estratégias de busca de divisão e conquista para consultas de proximidade satisfatórias envolvendo métricas arbitrárias à distância. (UHL-MANN, 1991)
 2. ***CoverTree***: A estrutura de dados requer o (n) espaço, e independentemente da estrutura da métrica ainda mantém todas as propriedades de desempenho de uma rede de navegação (KRAUTHGAMER; LEE, 2004). Se o conjunto de pontos tem uma constante de expansão c limitada, o que é uma medida da dimensionalidade intrínseca, a estrutura de dados em árvore de cobertura pode ser construída em $O(c^6 n \log n)$. Além disso, as consultas aos vizinhos mais próximos exigem tempo somente logarítmico em n , em particular, $O(c^{12} \log n)$. Dessa forma, a aplicação deste princípio sobre o método KNN aumenta significativamente a velocidade de processamento por busca de força bruta, variando entre uma e várias ordens de magnitude em conjuntos de dados de aprendizagem de máquina natural. (BEYGELZIMER; KAKADE; LANGFORD, 2006)
 3. ***KDTree***: A construção da árvore é realizada da seguinte maneira: Se um nó tem $\langle maximal - inst - number \rangle$ (opção -L no *software* WEKA) casos, mais nenhuma divisão é realizada. Além disso, se a divisão deixaria um lado vazio, o ramo não é dividido, mesmo se as instâncias no nó resultante são mais do que $\langle maximal - inst - number \rangle$ instâncias. O algoritmo não pode lidar com valores perdidos. (FRIEDMAN; BENTLEY; FINKEL, 1977)
 4. ***LinearNNSearch***: Trata-se da métrica utilizada para cálculo da distância do vizinho mais próximo. Neste parâmetro podem ser utilizadas as métricas da distância Euclidiana, distância de Chebyshev, distância de Levenshtein e distância de Manhattan. Foi utilizado este método e escolhida a distância Euclidiana por apresentar os melhores resultados após uso de todas as alternativas = ***LinearNNSearch***.
- ***windowSize*** - Obtém o número máximo de instâncias permitidas no conjunto de treinamento. Um valor "0" significa nenhum limite para o número de instâncias de formação = 0.

Todos os parâmetros selecionados por padrão resultaram nos melhores resultados para esta classificação após testes executados. Assim como no item anterior, os resultados gerados são demonstrados no próximo capítulo deste trabalho.

4.5.3 Métodos por árvores de decisão

Uma árvore de decisão é uma ferramenta de apoio à decisão que usa um gráfico de árvore ou modelo de decisões e suas possíveis consequências, incluindo resultados de chance de eventos, custos de recursos e de utilidade. Na verdade é uma maneira de exibir um algoritmo. As árvores de decisão são comumente usadas em pesquisa de operações, especificamente na análise de decisão, para ajudar a identificar uma estratégia mais provável para alcançar um objetivo. Existem diversos algoritmos que são utilizados em mineração de dados e que utilizam como método a árvore de decisão. Neste trabalho, são utilizados dois métodos: *Random Forest* e C4.5.

4.5.3.1 Algoritmo *Random Forest*

É uma combinação de preditores de árvore de modo que cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e com a mesma distribuição de todas as árvores da floresta. É muito utilizado em classificação de padrões por ser muito eficiente quando aplicado a grandes conjuntos de dados, e ter alta velocidade de processamento. Cada árvore é formada por uma abordagem *topdown* em conjuntos binários. (BREIMAN, 2001)

As características de cada parâmetro podem ser vistas abaixo, e o texto logo após a explicação de cada parâmetro representa o valor adotado no *software* durante a análise deste algoritmo:

- ***debug*** - Se definido como verdadeiro, o classificador pode gerar informações adicionais para saída do console = ***FALSE***.
- ***maxDepth*** - A profundidade máxima das árvores, o valor "0" define a profundidade para ilimitado = ***0***.
- ***numFeatures*** - O número de atributos para ser usado em seleção aleatória = ***0***.
- ***numTrees*** - O número de árvores a serem geradas = ***100***.
- ***seed*** - As sementes de número aleatório para serem utilizadas = ***1***.

Todos os parâmetros selecionados por padrão resultaram nos melhores resultados para esta classificação após testes executados. Os resultados gerados são demonstrados no próximo capítulo deste trabalho.

4.5.3.2 Algoritmo C4.5/J48

O algoritmo constrói árvores de decisão a partir de um conjunto de dados de treinamento utilizando o conceito de entropia de informação. Os dados de treinamento são um conjunto $S = s_1, s_2, \dots$ de amostras já classificadas. Cada s_i amostra é composta por um vetor p -dimensional $(x_{1,i}, x_{2,i}, \dots, x_{p,i})$, onde os x_j representam atributos ou características da amostra, bem como a classe em que s_i cai. Em cada nó da árvore, o algoritmo C4.5 escolhe o atributo dos dados que se divide mais eficazmente em seu conjunto de amostras enriquecidas em subconjuntos de uma classe. O critério de divisão é o ganho de informação normalizada (diferença de entropia). O atributo com o ganho de informação normalizada mais alto é escolhido para tomar a decisão. Todas as amostras na lista pertencem à mesma classe. Quando isso acontece, ele simplesmente cria um nó (folha) para a árvore de decisão dizendo o que escolher dessa classe. Nenhum dos recursos fornecem qualquer ganho de informação. Neste caso, o algoritmo C4.5 cria um nó de decisão mais alto na árvore utilizando o valor esperado da classe. No *software* WEKA o algoritmo C4.5 é implementado sobre a plataforma Java com o nome J48. (SALZBERG, 1994)

As características de cada parâmetro podem ser vistas abaixo e o texto logo após a explicação de cada parâmetro representa o valor adotado no *software* durante a análise deste algoritmo:

- **binarySplits** - Se usar divisões binárias nos atributos nominais ao construir as árvores = **FALSE**.
- **confidenceFactor** - O fator de confiança utilizado para a poda da árvore (valores menores incorrem em mais poda) = **0,25**.
- **debug** - Se definido como verdadeiro, o classificador pode gerar informações adicionais para a saída do console = **FALSE**.
- **minNumObj** - O número mínimo de casos por folha = **2**.
- **numFolds** - Determina a quantidade de dados utilizados para a redução de erros de poda. Um *fold* é usado para a poda, o resto para o crescimento da árvore = **3**.
- **reducedErrorPruning** - Solicita redução de erros de poda = **FALSE**.
- **saveInstanceData** - Salva os dados de treinamento para visualização = **FALSE**.
- **seed** - A quantidade de sementes usadas para randomizar os dados quando o algoritmo de redução de erros de poda é usado = **1**.

- ***subtreeRaising*** - Considera a operação de levantamento de sub-árvores quando efetuar poda = ***TRUE***.
- ***unpruned*** - Se a poda deve ser realizada = ***FALSE***.
- ***useLaplace*** - Se as contagens em folhas são suavizadas com base em Laplace = ***FALSE***.

Assim como nos outros algoritmos analisados anteriormente, os parâmetros selecionados por padrão resultaram nos melhores resultados para esta classificação após testes executados. Os resultados gerados são demonstrados no próximo capítulo deste trabalho.

4.5.4 Métodos baseados em Redes Neurais Artificiais

Baseiam-se em algoritmos de aprendizado com capacidade de representação de dados relacionados mas não-lineares e ainda multivariáveis, construídos a partir de uma rede neural composta por nós (neurônios) análogos aos neurônios humanos, interligados uns aos outros, e dessa forma a identificação de padrões é realizada através do aprendizado. As conexões têm pesos numéricos que podem ser ajustados com base na experiência, tornando redes neurais adaptáveis às entradas. Usualmente uma rede neural artificial deve ter ao menos três estruturas definidas como parâmetros de entrada (primeira camada), camadas ocultas (segunda camada), e camada de saída. Em redes neurais artificiais, o sistema apresenta resultados a partir de um pré-processamento da rede para aprendizado, ou seja, em primeiro lugar se deve treinar a rede para em seguida utilizá-la na classificação. Existem diversos tipos de redes neurais artificiais, e este trabalho utiliza como classificador a rede *Multi Layer Perceptron* (MLP), por estar disponível no *software* WEKA e por apresentar bons resultados em classificação de dados segundo a revisão da bibliografia deste trabalho.

4.5.4.1 Redes Neurais artificiais MLP

Nestes tipos de redes o princípio básico de funcionamento concentra-se no treinamento supervisionado utilizando o algoritmo de retropropagação de erro, baseando-se na regra de aprendizagem por correção de erro. A aprendizagem por retropropagação de erros é realizada em duas etapas: a propagação em si, onde um padrão de atividades é aplicado sobre os nós de entrada e este se propaga até os nós de saída com todos os pesos sinápticos fixos, gerando assim resultados parciais da rede. A partir destes resultados é que são gerados os pesos sinápticos ajustados a partir de uma regra de correção de erros, que subtrai da resposta real da rede a resposta desejada, gerando um sinal de erro para se executar a retropropagação no sentido contrário das conexões sinápticas. (KOVACS, 2002)

O modelo dos neurônios em uma rede MLP tem três principais características:

- Cada neurônio da rede é definido por uma função de ativação não-linear suave, ou seja, diferenciável em qualquer ponto da rede, e normalmente é utilizada a forma de não-linearidade sigmóide, definida pela Equação 32 :

$$y_j = \frac{1}{1 + \exp(-\nu_j)} \quad (32)$$

onde ν_j é a soma ponderada de todas as entradas sinápticas somadas ao *bias* do neurônio j e y_j é a saída deste neurônio;

- A rede pode conter uma ou diversas camadas de neurônios ocultas, e estas obrigatoriamente não fazem parte das camadas de entrada e saída da rede. Estas camadas de neurônios ocultos ajudam no aprendizado da rede para execução de atividades complexas extraíndo as características mais significativas dos vetores da camada de neurônios de entrada;
- A alta conectividade desta rede é a principal característica determinada pelas diversas sinapses da rede. Uma simples modificação em uma das conexões pode gerar a necessidade de mudança nas próximas conexões sinápticas e de seus pesos. (HAYKIN, 2001)

No *software* WEKA o algoritmo MLP é implementado sobre a plataforma Java, disponível na aba *functions*. As características de cada parâmetro podem ser vistas abaixo e o texto logo após a explicação de cada parâmetro representa o valor adotado no *software* durante a aplicação deste algoritmo:

- **GUI** - Traz uma interface ao usuário que irá permitir a pausa e alteração da rede neural durante o treino = **TRUE**.
- **autoBuild** - Adiciona e conecta-se às camadas ocultas na rede = **TRUE**.
- **debug** - Se definido como verdadeiro, o classificador pode gerar informações adicionais para a saída do console = **FALSE**.
- **decay** - Este parâmetro fará com que a taxa de aprendizagem diminua = **TRUE**.
- **hiddenLayers** - Define as camadas ocultas da rede neural. A quantidade de camadas deve ser colocada sobre vírgulas, e o parâmetro "a" soma os atributos com as classes e divide por 2 = **a**.
- **learningRate** - O valor dos pesos são atualizados em caso afirmativo neste parâmetro = **0,3**.

- ***momentum*** - Dinâmica aplicada aos pesos durante a atualização = ***0,2***.
- ***nominalToBinaryFilter*** - O que irá pré-processar as instâncias com o filtro. Isso poderia ajudar a melhorar o desempenho se existirem atributos nominais nos dados = ***TRUE***.
- ***normalizeAttributes*** - Normalizar os atributos. Isso poderia ajudar a melhorar o desempenho da rede = ***TRUE***.
- ***normalizeNumericClass*** - Normalizar a classe se esta for numérica = ***TRUE***.
- ***reset*** - Permitir que a rede reinicie com uma taxa de aprendizagem inferior. Se a rede diverge da resposta, esta irá repor automaticamente a rede com uma taxa de aprendizagem mais baixa e começar a treinar novamente = ***FALSE***.
- ***seed*** - Quantidade de sementes usadas para inicializar o gerador de números aleatórios, que são usados para definir os pesos iniciais dos nós entre conexões, e também para embaralhar os dados de treinamento = ***0***.
- ***trainingTime*** - O número de épocas para treinar completamente a rede = ***500***.
- ***validationSetSize*** - O tamanho em porcentagem do conjunto de validação. O treinamento vai continuar até que perceba-se que o treinamento está piorando o resultado = ***0***.
- ***validationThreshold*** - Usado para encerrar valores testes. A validação aqui determina quantas vezes seguidas o erro no conjunto de validação pode piorar antes da formação ser terminada = ***20***.

Todos os parâmetros selecionados por padrão resultaram nos melhores resultados para esta classificação após testes executados. Os resultados gerados são demonstrados no próximo capítulo deste trabalho.

4.5.5 Método de validação cruzada

Trata-se de uma técnica utilizada na avaliação da capacidade de generalização de um modelo, a partir de um conjunto de dados e é conhecido popularmente pelo seu termo em inglês *cross-validation*. Este método é muito utilizado como técnica de predição na análise de classificadores, utilizados em técnicas de mineração de dados. O princípio básico de funcionamento desta técnica consiste na divisão do conjunto total de dados em subconjuntos que sejam mutuamente exclusivos, e em seguida separar estes subconjuntos para a validação e treinamento do modelo a ser testado. Neste trabalho foi utilizado o método *k-fold*, e o conjunto de dados

foi dividido por 10 *folds*. Cada *fold* contém uma imagem de cada usuário, portanto todos os *folds* são compostos por 52 imagens. O *fold* 1 contém a primeira imagem de cada usuário, o *fold* 2 contém a segunda imagem de cada usuário e assim sucessivamente. A precisão final é apresentada pela Equação 33 e representa o modelo estimado da validação. Foram utilizados nos parâmetros dos classificadores 10% do conteúdo para treinamento e 90% do conteúdo para testes. (em inglês, são comumente encontrados os termos *training set* e *test set*)

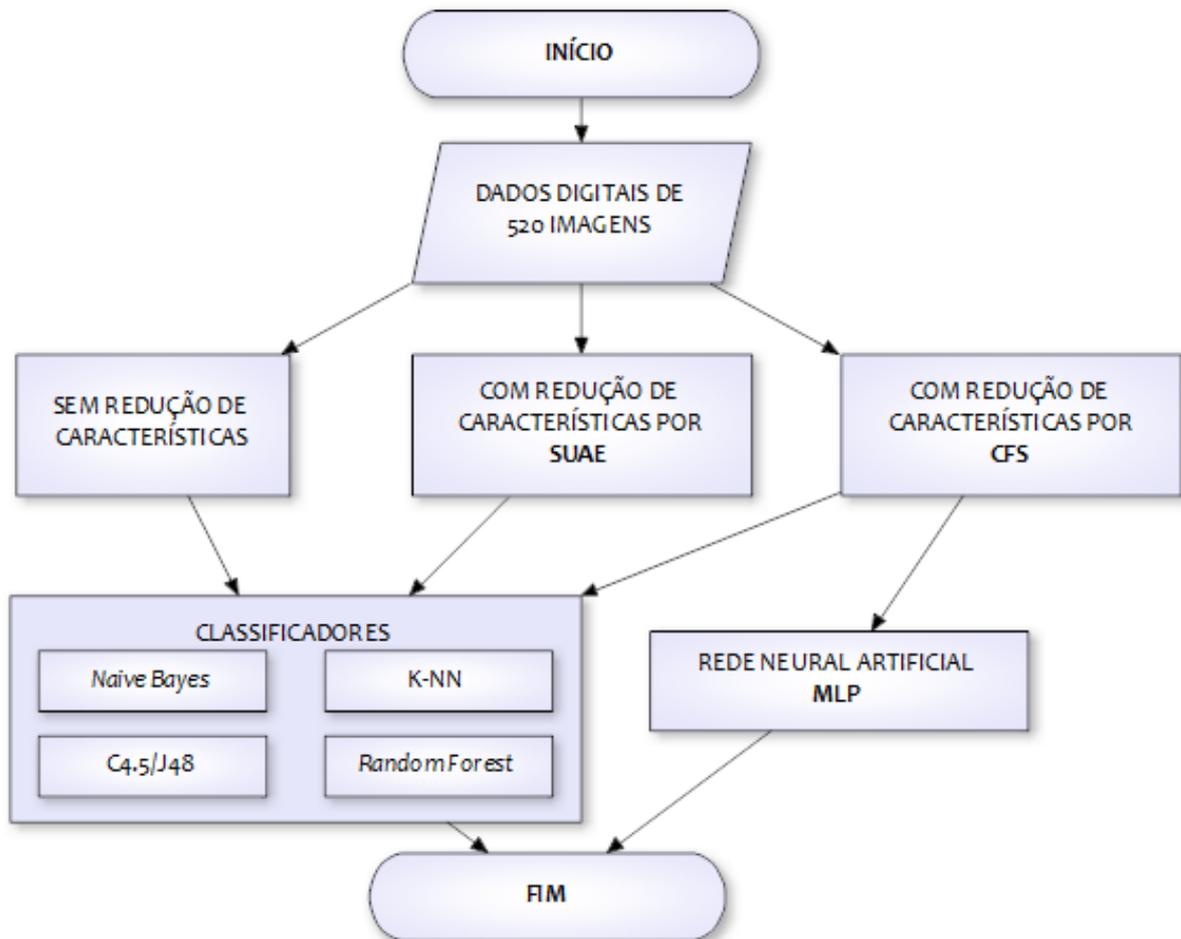
$$Ac_f = \frac{1}{v} \sum_{i=1}^v \epsilon_{y_i, \hat{y}_i} = \frac{1}{v} \sum_{i=1}^v (y_i - \hat{y}_i) \quad (33)$$

onde v é o número de dados de validação e $\epsilon_{y_i, \hat{y}_i}$ é o resíduo dado pela diferença entre o valor real da saída i e o valor predito. Dessa forma, é possível inferir de forma quantitativa a capacidade de generalização do modelo.

Os resultados das classificações normalmente são apresentados de forma gráfica através da curva ROC. Esta curva apresenta no eixo das coordenadas a taxa de falsos positivos conhecida como a especificidade sendo a probabilidade do sistema utilizado fornecer um resultado negativo e no eixo das abscissas a taxa de verdadeiros positivos também conhecido como parâmetro de sensibilidade do sistema classificado. Foi desenvolvida durante a Segunda Guerra Mundial para analisar objetos detectados nos radares em campos de batalha, discriminando-os em inimigos ou ruídos e atualmente tem sido utilizada em diversas áreas como biometria e medicina, principalmente analisando o campo ROC como o principal critério de avaliação de classificadores utilizados em sistemas de mineração de dados, sendo considerado o mais importante parâmetro de análise de um classificador. O melhor resultado possível para área ROC é igual a um, sendo que todos os dados classificados são identificados corretamente (taxa de verdadeiros positivos igual a um e taxa de falsos positivos igual a zero). (DAVIS; GOADRIC, 2006)

Abaixo na Figura 10 pode-se visualizar um fluxograma da fase de seleção de atributos e classificação das características das imagens obtidas. Verifica-se que na fase de seleção de atributos da imagem, foram utilizadas duas técnicas diferentes. Na classificação dos dados, foram utilizados cinco diferentes algoritmos.

Figura 10 - Fluxograma do processo de classificação dos dados



Fonte: Produção do próprio autor

5 RESULTADOS E DISCUSSÕES

Os primeiros resultados obtidos são a aquisição e devido armazenamento da imagem com a utilização do protótipo criado. A primeira etapa é extrair a região de interesse da imagem, e esta consiste em uma porção quadrada da parte dorsal da mão. Em seguida são realizadas equalizações de imagem extraída após sua aquisição com o uso dos três algoritmos comentados no capítulo anterior: Equalização Global do Histograma, Mapeamento e Ajuste de Intensidade de Cinza e Equalização Adaptativa por Limite de Contraste. A próxima etapa do trabalho foi realizar a extração de características das imagens com o uso da transformada de *Curvelet* e em seguida foi realizada a digitalização (binarização) dos dados obtidos pelo algoritmo LBP. Com os dados a serem testados, a fase de aquisição e pré-processamento dos dados foi concluída, então, para se classificar os dados no intuito de testar a precisão do sistema, foram aplicadas duas técnicas de seleção de atributos para verificar posteriormente se a totalidade dos dados realmente seria necessária na identificação dos dados. Os algoritmos aplicados na seleção de atributos foram o CFS e o SUAE, comentados no capítulo anterior. Os resultados seguintes dizem respeito às classificações dos dados realizadas pelos algoritmos propostos no capítulo anterior, tanto com a totalidade dos dados extraídos pela transformada de *Curvelet* quanto após aplicação das técnicas de seleção de atributos. Foram utilizados cinco diferentes algoritmos para avaliação de qual o melhor método a ser aplicado. Os algoritmos de classificação dos dados utilizados foram: *Naive Bayes*, *Kernel Nearest Neighbor*, *C4.5/J48*, *Random Forest* e *Rede Neural Artificial Multilayer Perceptron*. Para que as análises fossem realizadas, foi utilizada a técnica de validação cruzada conhecida pelo termo em inglês *cross-validation*. Os resultados desta tese em sua fase inicial de desenvolvimento foram publicados no artigo disponível no Apêndice A. (JANES; BRANDÃO JR, 2014)

Abaixo, seguem os resultados obtidos:

5.1 AQUISIÇÃO DE IMAGENS

A Figura 11 abaixo apresenta uma amostra de imagem adquirida com seu nome descrito. Conforme descrito na metodologia, verifica-se que o número de matrícula (identificação pessoal) do usuário é 112146890, se trata de um homem (sexo masculino definido na *string* como M), tem 1,79 metros de altura, 65 quilogramas, 22 anos de idade e foi a sexta imagem adquirida da mesma pessoa (índice 5, sendo que a primeira das 10 imagens tem índice zero).

Figura 11 - Amostra de imagem adquirida com nome atribuído



Fonte: Produção do próprio autor

5.2 PRÉ-PROCESSAMENTO DAS IMAGENS

As imagens foram obtidas com o *zoom* da câmera aberto totalmente, de forma a capturar a maior imagem possível dentro do protótipo, no entanto os pinos, a base e diversos outros pontos na imagem não são de interesse na identificação do usuário. A região de interesse que será utilizada é a maior porção quadrada da parte dorsal da mão, extraída das imagens e armazenada para posterior processamento. Para a extração, foi utilizado o *software Matlab*[®]. A normalização da imagem também deve ser feita, portanto, a região extraída foi normalizada em uma imagem quadrada de 900x900 *pixels*, transformada para padrão de cinzas pois apesar de se ter configurado a câmera para obter imagens sem cor, o padrão salvo como *jpeg* configura as imagens como coloridas no padrão *Red Green Blue* (RGB), e ainda redimensionada de forma que todo o banco de imagens tenha a mesma característica. Abaixo na Figura 12 pode-se ver a extração da região de interesse ROI e sua devida normalização realizada por *software*.

Após a extração da região de interesse, ainda na fase de pré-processamento da imagem, foi necessária a melhoria do contraste e diminuição do nível de ruídos, tanto dos provenientes da captura da imagem quanto os ruídos gerados pelo melhoramento do contraste. A imagem deve ser tratada para tentar diminuir as influências de iluminação não uniformes e outros ruídos indesejados que possam afetar o desempenho do algoritmo proposto dadas as variações do padrão da imagem adquirida. Para isto, foram propostos três tipos de equalização de imagens baseando-se na revisão bibliográfica para avaliar qual o melhor método a ser adotado neste trabalho. São analisadas a Equalização global do histograma, o Mapeamento e ajuste

Figura 12 - Extração da região de interesse ROI



Fonte: Produção do próprio autor

de intensidade de cinza e a Equalização de histograma adaptativa por limite de contraste. Abaixo, são apresentados os resultados destes três métodos.

5.3 RESULTADOS OBTIDOS PARA SUAVIZAÇÃO DE IMAGENS

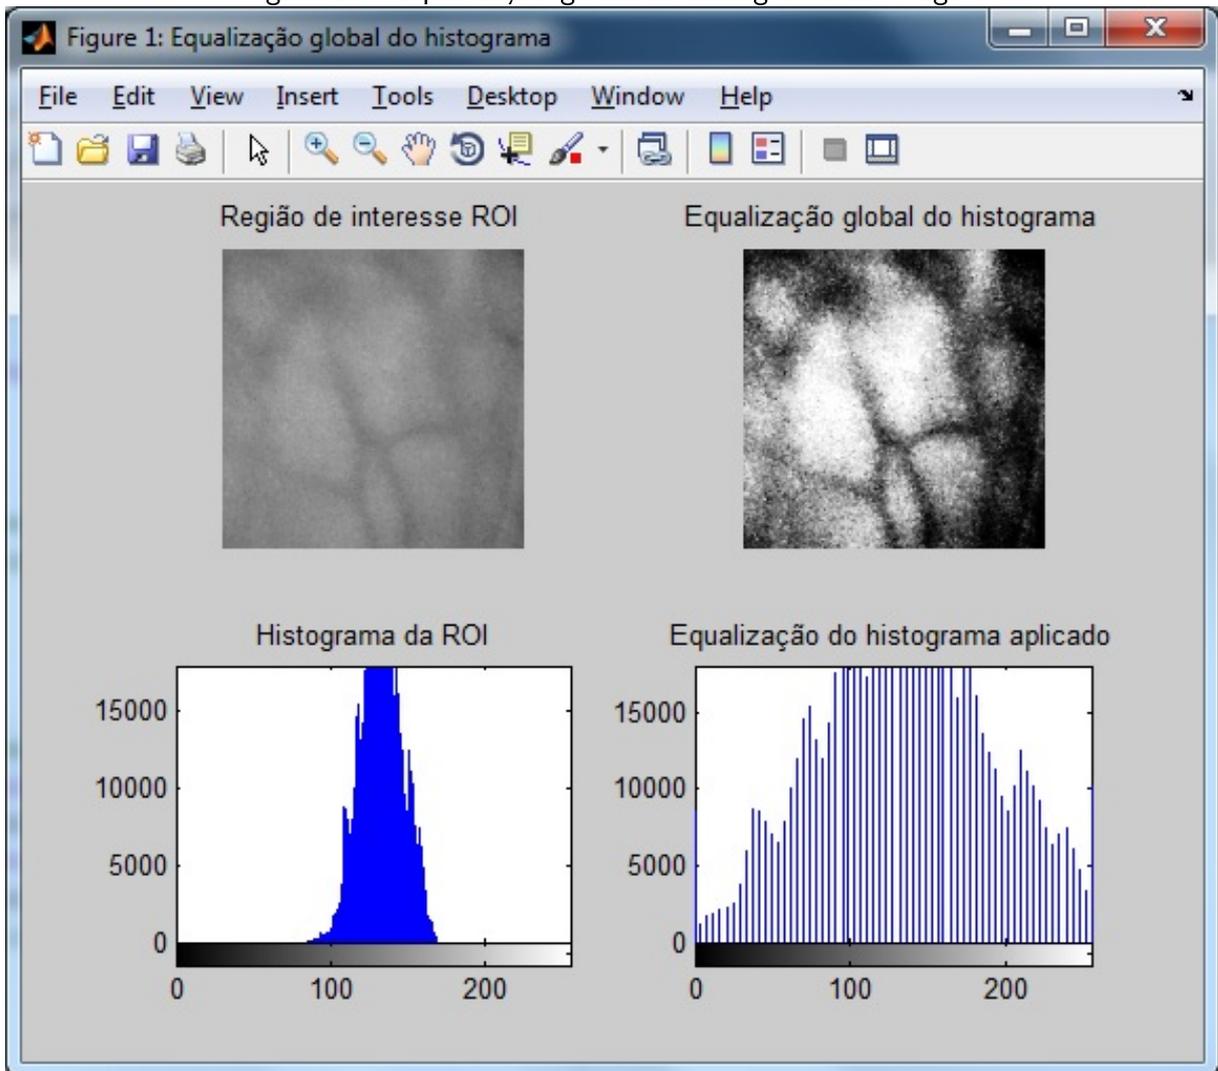
As três técnicas propostas no capítulo anterior foram aplicadas às imagens. Os resultados são apresentados a seguir. Vale lembrar que a proposta de aplicação destes algoritmos é de suavizar as imagens, extrair ruídos que possam gerar problemas no momento de identificação de pessoas pelo sistema biométrico proposto e acima de tudo equalizar as imagens evitando assim influências externas no momento de captura da imagem.

5.3.1 Equalização global do histograma

Utilizando a imagem extraída na fase de pré-processamento (imagem ROI), e com o uso do *software Matlab®*, foi aplicada então a equalização global do histograma e o resultado está apresentado na Figura 13 a seguir:

Nota-se que os resultados não são satisfatórios, pois o tratamento aplicado na imagem deixou as bordas escuras e o centro da imagem muito clara. Na verdade, o método aplicado piorou a qualidade da imagem do ponto de vista de normalização.

Figura 13 - Equalização global do histograma da imagem



Fonte: Produção do próprio autor

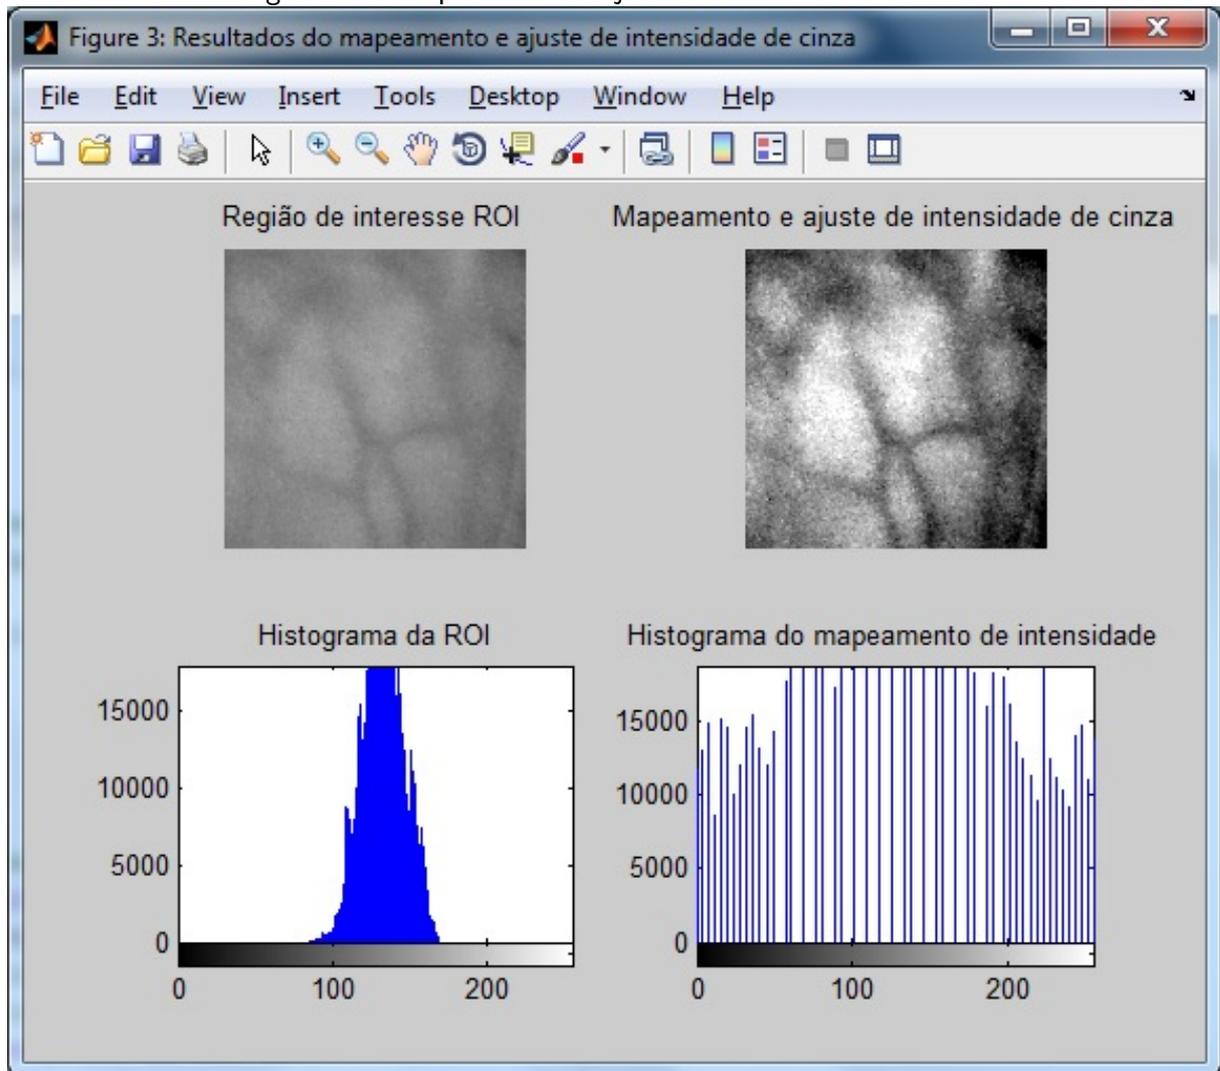
5.3.2 Mapeamento e ajuste de intensidade de cinza

Como se pode visualizar na Figura 14, os resultados apresentaram praticamente as mesmas características da equalização global do histograma, mesmo após variação de todos os parâmetros possíveis nas aplicações realizadas pelo *software* sobre a imagem. É um método que não satisfaz a proposta de melhorar o contraste no caso das imagens capturadas neste trabalho.

5.3.3 Equalização adaptativa por limite de contraste

Utilizando mais uma vez a imagem extraída na fase de pré-processamento anterior (imagem ROI), e com o uso do *software Matlab*[®], foi aplicada então a equalização de histograma adaptativa por limite de contraste CLAHE e o resultado está apresentado na Figura 15 a

Figura 14 - Mapeamento e ajuste de intensidade de cinza



Fonte: Produção do próprio autor

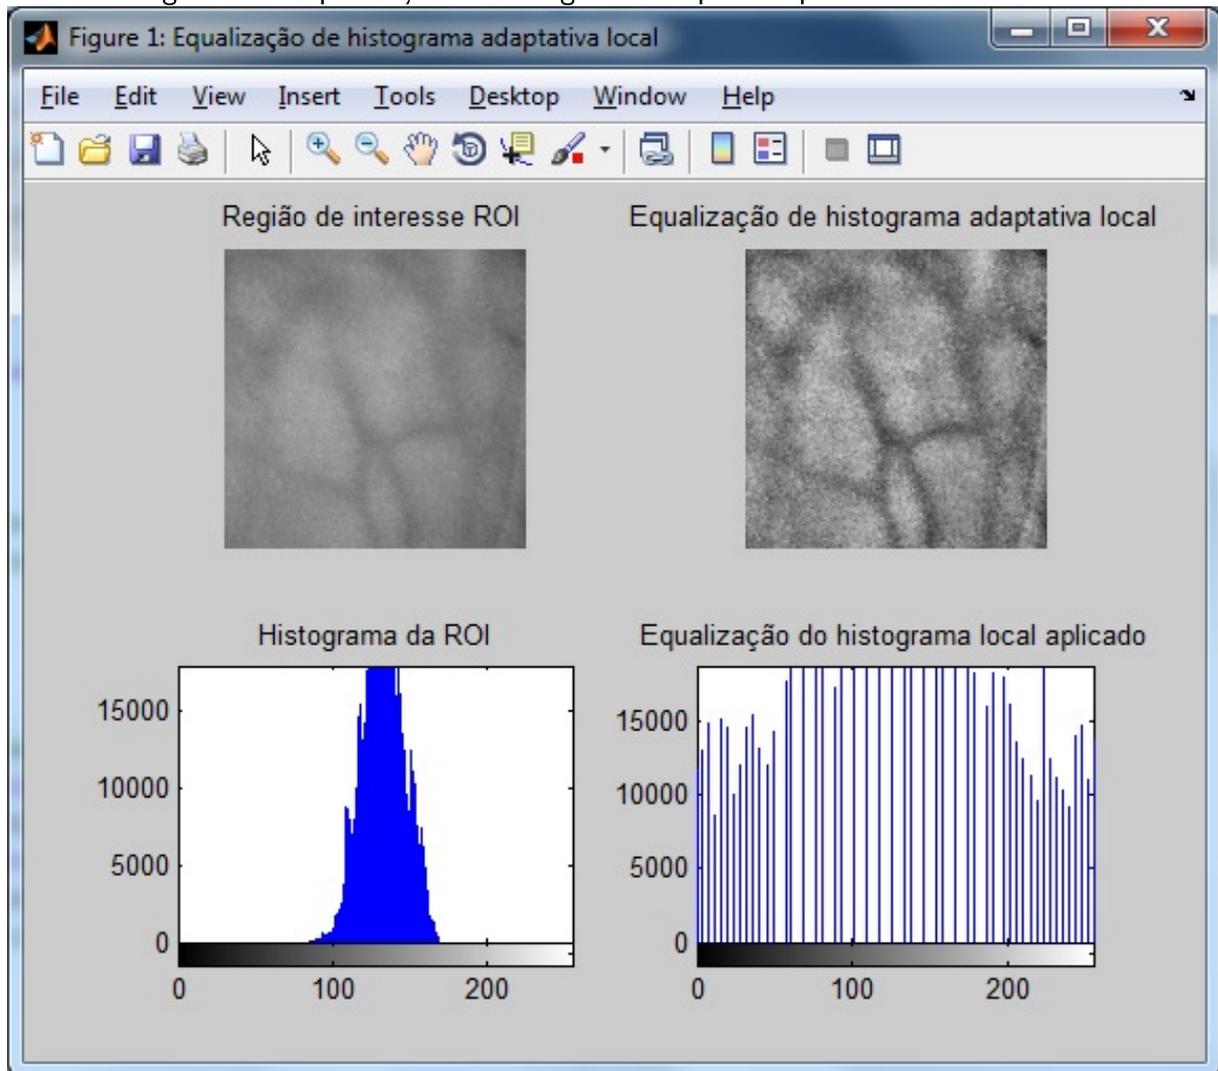
seguir:

Verifica-se dessa forma que os resultados obtidos são satisfatórios, mostrando que o contraste da imagem foi melhorado sem a geração de níveis muito diferentes de escala de cinza no histograma e sem geração de muitos ruídos ao menos visíveis na imagem gerada, portanto, este será o método de melhoramento de contraste utilizado no trabalho em questão. A Figura 16 abaixo apresenta todos os três resultados obtidos nas tentativas de melhoramento do contraste das imagens. O melhor resultado obtido foi o último algoritmo utilizado ao aplicar a equalização do histograma adaptativa por limite de contraste.

5.4 EXTRAÇÃO DE CARACTERÍSTICAS

Foram aplicadas as Equações 10, 11, 12, 13, 14 e 15 sobre cada imagem obtida, escolhendo variações de escalas de 1 até 5, e ângulos variando entre 8 ou 16 como parâmetros de análise,

Figura 15 - Equalização de histograma adaptativa por limite de contraste



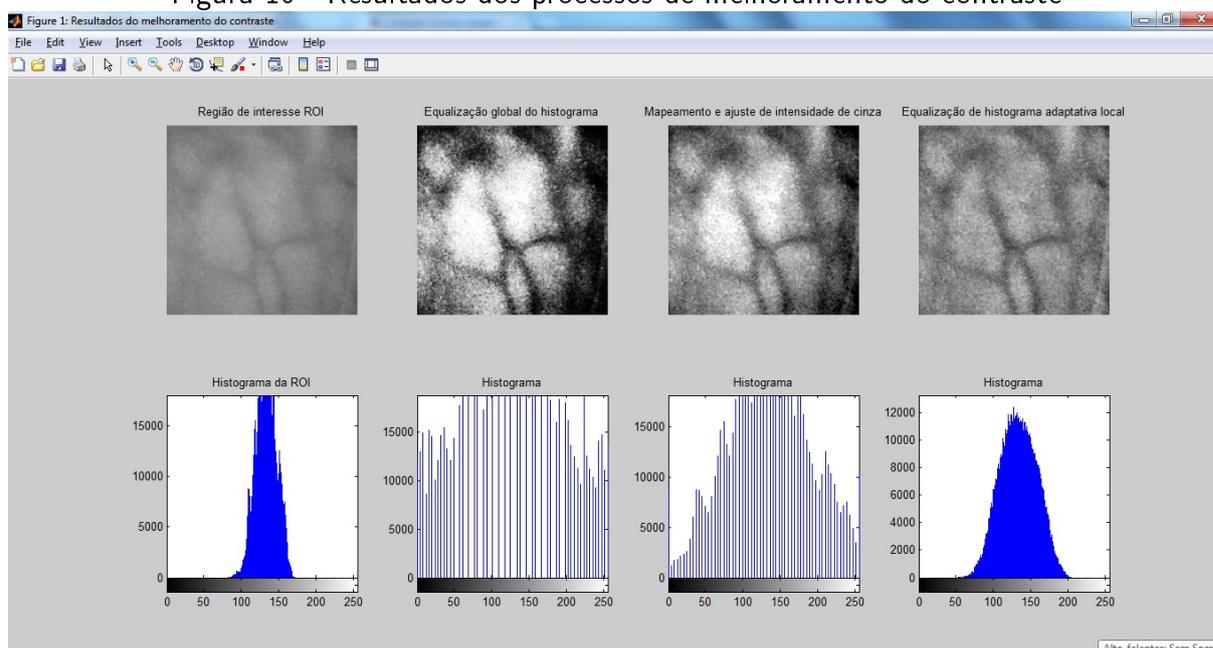
Fonte: Produção do próprio autor

índices indicados pela bibliografia como sendo os melhores parâmetros para obtenção de características de imagens. Após a aplicação da transformada *Curvelet*, foram criadas subimagens e sub-bandas divididas de acordo com o número de escalas adotado.

Os resultados gerados representam diversos subconjuntos matriciais, cada um com seu subgrupo, separando as características da imagem em subimagens. O primeiro conjunto é composto de apenas uma matriz, o segundo conjunto é composto de oito matrizes, o terceiro conjunto é composto de 16 matrizes e o quarto e último conjunto é composto de apenas uma matriz, no caso da utilização de extração com 4 escalas e 16 ângulos. Este conjunto representa o resultado apenas da primeira escala e do primeiro ângulo analisados, sendo que o processo inteiro é realizado com 4 escalas e 16 ângulos.

A Tabela 2 abaixo apresenta a quantidade de características extraídas em cada análise e o tempo de análise para a transformada de *Curvelet*.

Figura 16 - Resultados dos processos de melhoramento do contraste



Fonte: Produção do próprio autor

Tabela 2 - Quantidade de características extraídas por imagem

| <i>CURVELETS</i> | Qtde. de atributos | Tempo de extração <i>Curvelet</i> em segundos |
|--------------------------|---------------------------|--|
| 1 escala com 8 ângulos | 512 | 0,095379 |
| 1 escala com 16 ângulos | 512 | 0,093365 |
| 2 escalas com 8 ângulos | 512 | 0,099750 |
| 2 escalas com 16 ângulos | 512 | 0,107618 |
| 3 escalas com 8 ângulos | 1536 | 0,539721 |
| 3 escalas com 16 ângulos | 2560 | 0,433915 |
| 4 escalas com 8 ângulos | 3584 | 0,524686 |
| 4 escalas com 16 ângulos | 6656 | 0,537801 |
| 5 escalas com 8 ângulos | 5632 | 0,540046 |
| 5 escalas com 16 ângulos | 10752 | 0,584043 |

Fonte: Produção do próprio autor

5.5 PROCESSO DE DIGITALIZAÇÃO DAS IMAGENS.

O operador LBP foi aplicado sobre todas as subimagens geradas e relatadas na Tabela 2, e a Tabela 3 abaixo apresenta os tempos para concatenação dos dados em um único vetor, utilizando LBP. Estes resultados representam a aplicação das Equações 23 e 24 em cada imagem ROI extraída.

A fase posterior consiste na verificação da variância dos dados por métodos estatísticos para verificação de padrões de repetição, e eliminação de características que não definam diferenças entre as imagens, diminuindo assim o tamanho dos arquivos e aumentando a velocidade de

Tabela 3 - Tempos envolvidos na binarização das subimagens com LBP

| <i>CURVELETS</i> | Tempo de montagem por LBP (em segundos) |
|--------------------------|--|
| 1 escala com 8 ângulos | 0,000021 |
| 1 escala com 16 ângulos | 0,000021 |
| 2 escalas com 8 ângulos | 0,000027 |
| 2 escalas com 16 ângulos | 0,000034 |
| 3 escalas com 8 ângulos | 0,140712 |
| 3 escalas com 16 ângulos | 0,097899 |
| 4 escalas com 8 ângulos | 0,126410 |
| 4 escalas com 16 ângulos | 0,135967 |
| 5 escalas com 8 ângulos | 0,139350 |
| 5 escalas com 16 ângulos | 0,159923 |

Fonte: Produção do próprio autor

processamento.

5.6 SELEÇÃO DE ATRIBUTOS

No primeiro processo de seleção de atributos das imagens, foi utilizado o algoritmo CFS. A Equação 25 foi aplicada a todas as características extraídas das imagens com a variação dos parâmetros da transformada *Curvelet* e a seleção na quantidade de dados em cada caso pode ser visualizada na Tabela 4.

Tabela 4 - Quantidade de características extraídas com algoritmo CFS

| <i>CURVELETS</i> | Qtde. de atributos originais | Qtde. de atributos originais após seleção |
|--------------------------|-------------------------------------|--|
| 1 escala com 8 ângulos | 512 | 12 |
| 1 escala com 16 ângulos | 512 | 12 |
| 2 escalas com 8 ângulos | 512 | 6 |
| 2 escalas com 16 ângulos | 512 | 6 |
| 3 escalas com 8 ângulos | 1536 | 10 |
| 3 escalas com 16 ângulos | 2560 | 10 |
| 4 escalas com 8 ângulos | 3584 | 16 |
| 4 escalas com 16 ângulos | 6656 | 16 |
| 5 escalas com 8 ângulos | 5632 | 18 |
| 5 escalas com 16 ângulos | 10752 | 18 |

Fonte: Produção do próprio autor

O segundo algoritmo aplicado para seleção de atributos foi o SUAEE. A Equação 26 foi aplicada a todas as características extraídas das imagens com a variação dos parâmetros da transformada *Curvelet* e a seleção na quantidade de dados em cada caso pode ser visualizada

na Tabela 5.

Tabela 5 - Quantidade de características extraídas com algoritmo SUAE

| <i>CURVELETS</i> | Qtde. de atributos originais | Qtde. de atributos originais após seleção |
|--------------------------|-------------------------------------|--|
| 1 escala com 8 ângulos | 512 | 190 |
| 1 escala com 16 ângulos | 512 | 190 |
| 2 escalas com 8 ângulos | 512 | 245 |
| 2 escalas com 16 ângulos | 512 | 245 |
| 3 escalas com 8 ângulos | 1536 | 222 |
| 3 escalas com 16 ângulos | 2560 | 223 |
| 4 escalas com 8 ângulos | 3584 | 239 |
| 4 escalas com 16 ângulos | 6656 | 232 |
| 5 escalas com 8 ângulos | 5632 | 208 |
| 5 escalas com 16 ângulos | 10752 | 199 |

Fonte: Produção do próprio autor

Em ambos os casos, a quantidade de dados foi reduzida, e foram avaliadas as precisões do sistema utilizando a totalidade das características, utilizando apenas as seleções realizadas pelo algoritmo CFS e, por fim, utilizando o algoritmo SUAE. Apenas na fase de classificação foi possível avaliar se estes métodos melhoram o desempenho do sistema proposto. Na próxima fase do trabalho, são apresentados os resultados dos testes de classificação.

5.7 RESULTADOS OBTIDOS COM OS CLASSIFICADORES

Na próxima subseção 5.7.1 são apresentados os resultados obtidos com os algoritmos classificadores propostos no capítulo anterior, e estes são apresentados por tabelas e gráficos, provenientes dos processamentos dos algoritmos utilizando o pacote de *software* WEKA. O *software* é um conjunto de algoritmos de aprendizado de máquina para tarefas de mineração de dados, baseado em JAVA e com código aberto, criado em 1993 pela Universidade de Waikato, Nova Zelândia. Muitos algoritmos propostos em trabalhos acadêmicos estão disponíveis para uso. São apresentados os resultados do uso dos algoritmos *Naive Bayes*, algoritmo K-NN, algoritmo C4.5/J48, algoritmo *Random Forest* e a rede neural artificial MLP.

Os resultados apresentados pelo *software* WEKA são o tempo de criação do modelo a ser classificado (campo ***Time***), a taxa de verdadeiro positivo que indica quantas classes foram identificadas de forma correta (campo ***TP Rate***, onde TP significa *True Positive*), a taxa de falso positivo que indica quantas classes foram identificadas de forma incorreta (campo ***FP Rate***, onde FP significa *False Positive*), e o campo ROC area é uma representação gráfica que ilustra o desempenho de um sistema de classificação binária, já comentada no capítulo anterior.

Estes critérios de avaliação de classificação são muito utilizados em diversas áreas, no entanto, para biometria as principais métricas são calculadas a partir das falsas identificações. Os dois principais parâmetros avaliados são a taxa de falso negativo, comumente conhecida pela sigla FRR e a taxa de falso positivo, conhecida pela sigla FAR. A FAR é a probabilidade do sistema identificar de forma incorreta uma pessoa que não deveria ser identificada pelo sistema, e a FRR é a probabilidade do sistema identificar positivamente uma pessoa que não deveria ser identificada. A representação da curva ROC neste caso é realizada colocando-se a taxa FRR no eixo x de um plano cartesiano e a taxa FAR no eixo y deste mesmo plano cartesiano. A curva ROC então é representada de forma gráfica e o ponto da curva que mais se aproxima da origem é conhecida como a taxa EER. Sistemas biométricos “perfeitos” (Todos os indivíduos aprovados ou rejeitados corretamente) deveriam apresentar EER igual a zero.

Para que esta tese apresente as mesmas métricas utilizadas em outros trabalhos, os índices foram calculados a partir dos resultados do *software* WEKA. O resultado *FPRate* na verdade já é a taxa FAR, e a taxa FRR é igual a $1 - TPRate$. A área ROC igual a 1 representa a melhor condição possível do classificador, podendo-se estimar precisão de 100%. Dessa forma, todos os resultados apresentados pelo *software* WEKA foram transformados em métricas comuns às análises biométricas.

5.7.1 Classificação de dados sem uso de técnicas de seleção

A Tabela 6 apresenta os resultados da classificação utilizando o algoritmo *Naive Bayes*. O menor tempo de classificação foi de 0,08 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 1 e 2 escalas com 8 ou 16 ângulos e o maior tempo de classificação foi de 2,11 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 5 escalas e 16 ângulos. Esses resultados eram esperados pois quanto maior a quantidade de escalas e ângulos utilizadas na extração de características, maior a quantidade de dados gerados. Os melhores resultados obtidos foram a FRR igual a 0,433, FAR igual a 0,008 e área ROC igual a 0,922, para 4 escala e 8 ângulos. Pode-se notar que as variações de ângulo não alteram os resultados para 1 e 2 escalas, percebe-se que a transformada de *Curvelet* extrai os mesmos dados, independente da quantidade de ângulos escolhidos. Vale lembrar que os melhores resultados possíveis para representação de um sistema com 100% de precisão são FRR igual a zero, FAR igual a zero e área ROC igual a um.

A Tabela 7 apresenta os resultados da classificação utilizando o algoritmo K-NN. Os tempos de classificação foram praticamente nulos, os resultados foram apresentados em tempo real. Os melhores resultados obtidos foram a FRR igual a 0,531, FAR igual a 0,010 e área ROC

Tabela 6 - Resultados obtidos com o uso do classificador *Naive Bayes*

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,08 | 0,735 | 0,014 | 0,880 |
| 1 escala, 16 ângulos | 0,08 | 0,735 | 0,014 | 0,880 |
| 2 escalas, 8 ângulos | 0,08 | 0,602 | 0,012 | 0,912 |
| 2 escalas, 16 ângulos | 0,08 | 0,602 | 0,012 | 0,912 |
| 3 escalas, 8 ângulos | 0,23 | 0,483 | 0,009 | 0,915 |
| 3 escalas, 16 ângulos | 0,61 | 0,527 | 0,010 | 0,915 |
| 4 escalas, 8 ângulos | 0,67 | 0,433 | 0,008 | 0,922 |
| 4 escalas, 16 ângulos | 1,31 | 0,542 | 0,011 | 0,909 |
| 5 escalas, 8 ângulos | 1,33 | 0,481 | 0,009 | 0,912 |
| 5 escalas, 16 ângulos | 2,11 | 0,552 | 0,011 | 0,889 |

Fonte: Produção do próprio autor

igual a 0,729, para 1 escala e 8 ou 16 ângulos. Pode-se notar novamente que as variações de ângulo não alteram os resultados para 1 e 2 escalas, percebe-se que a transformada de *Curvelet* extrai os mesmos dados, independente da quantidade de ângulos escolhidos. Este algoritmo apresenta um resultado pior que o algoritmo *Naive Bayes* analisado anteriormente, com resultados obtidos de FRR igual a 0,433, FAR igual a 0,008 e área ROC igual a 0,922, para 4 escala e 8 ângulos.

Tabela 7 - Resultados obtidos com o uso do classificador K-NN

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,00 | 0,531 | 0,010 | 0,729 |
| 1 escala, 16 ângulos | 0,00 | 0,531 | 0,010 | 0,729 |
| 2 escalas, 8 ângulos | 0,00 | 0,654 | 0,013 | 0,667 |
| 2 escalas, 16 ângulos | 0,00 | 0,654 | 0,013 | 0,667 |
| 3 escalas, 8 ângulos | 0,00 | 0,594 | 0,012 | 0,697 |
| 3 escalas, 16 ângulos | 0,00 | 0,662 | 0,013 | 0,663 |
| 4 escalas, 8 ângulos | 0,00 | 0,640 | 0,013 | 0,674 |
| 4 escalas, 16 ângulos | 0,02 | 0,710 | 0,014 | 0,638 |
| 5 escalas, 8 ângulos | 0,00 | 0,671 | 0,013 | 0,658 |
| 5 escalas, 16 ângulos | 0,02 | 0,727 | 0,014 | 0,629 |

Fonte: Produção do próprio autor

A Tabela 8 apresenta os resultados da classificação utilizando o algoritmo C4.5/J48. O menor tempo de classificação foi de 1,05 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 2 escalas e 8 ou 16 ângulos e o maior tempo de classificação foi de 13,26 segundos obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 5 escalas e 16 ângulos. Os melhores resultados obtidos foram a FRR igual a 0,587, FAR igual a 0,012 e área ROC igual a 0,712, para 5 escalas e 8 ângulos. Este algoritmo apresenta um resultado pior que o algoritmo *Naive Bayes* analisado anteriormente, com resultados obtidos de FRR igual a 0,433, FAR igual a 0,008 e área ROC igual a 0,922, para 4 escala e 8 ângulos, e o algoritmo K-NN com FRR igual a 0,531, FAR igual a 0,010 e

área ROC igual a 0,729, para 1 escala e 8 ou 16 ângulos

Tabela 8 - Resultados obtidos com o uso do classificador C4.5/J48

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 1,79 | 0,788 | 0,015 | 0,627 |
| 1 escala, 16 ângulos | 1,09 | 0,788 | 0,015 | 0,627 |
| 2 escalas, 8 ângulos | 1,05 | 0,763 | 0,015 | 0,633 |
| 2 escalas, 16 ângulos | 1,05 | 0,763 | 0,015 | 0,633 |
| 3 escalas, 8 ângulos | 2,61 | 0,694 | 0,014 | 0,663 |
| 3 escalas, 16 ângulos | 3,99 | 0,708 | 0,014 | 0,650 |
| 4 escalas, 8 ângulos | 5,02 | 0,673 | 0,013 | 0,671 |
| 4 escalas, 16 ângulos | 10,39 | 0,667 | 0,013 | 0,676 |
| 5 escalas, 8 ângulos | 8,16 | 0,587 | 0,012 | 0,712 |
| 5 escalas, 16 ângulos | 13,26 | 0,638 | 0,013 | 0,682 |

Fonte: Produção do próprio autor

A Tabela 9 apresenta os resultados da classificação utilizando o algoritmo *Random Forest*. O menor tempo de classificação foi de 2,68 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 2 escalas e 8 ou 16 ângulos e o maior tempo de classificação foi de 17,19 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 5 escalas e 16 ângulos. Os melhores resultados obtidos foram a FRR igual a 0,519, FAR igual a 0,010 e área ROC igual a 0,921, para 1 escala e 8 ou 16 ângulos. Este algoritmo apresenta um resultado pior que o algoritmo *Naive Bayes* analisado anteriormente, com resultados obtidos de FRR igual a 0,433, FAR igual a 0,008 e área ROC igual a 0,922, para 4 escala e 8 ângulos mas supera os algoritmos K-NN com FRR igual a 0,531, FAR igual a 0,010 e área ROC igual a 0,729, para 1 escala e 8 ou 16 ângulos e o algoritmo C4.5/J48 com FRR igual a 0,531, FAR igual a 0,010 e área ROC igual a 0,729, para 1 escala e 8 ou 16 ângulos.

Tabela 9 - Resultados obtidos com o uso do classificador *Random Forest*

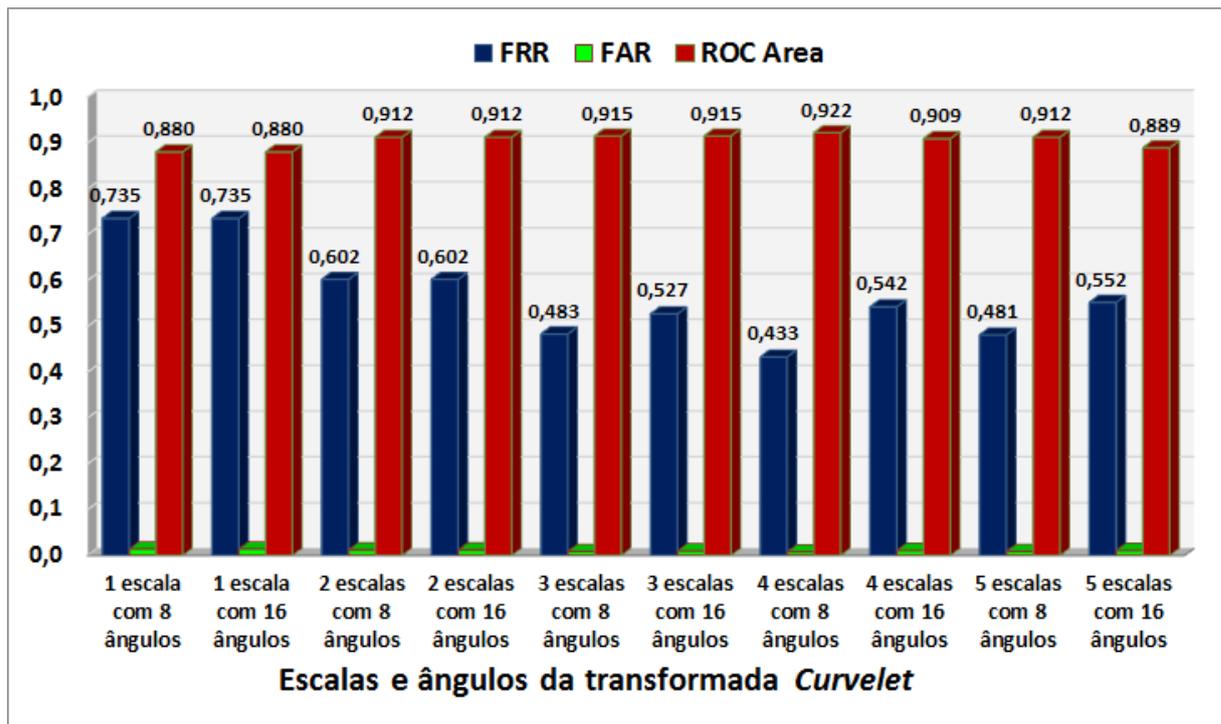
| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 3,37 | 0,519 | 0,010 | 0,921 |
| 1 escala, 16 ângulos | 2,76 | 0,519 | 0,010 | 0,921 |
| 2 escalas, 8 ângulos | 2,68 | 0,527 | 0,010 | 0,935 |
| 2 escalas, 16 ângulos | 2,68 | 0,527 | 0,010 | 0,935 |
| 3 escalas, 8 ângulos | 4,66 | 0,552 | 0,011 | 0,932 |
| 3 escalas, 16 ângulos | 5,53 | 0,677 | 0,013 | 0,906 |
| 4 escalas, 8 ângulos | 6,94 | 0,679 | 0,013 | 0,899 |
| 4 escalas, 16 ângulos | 11,29 | 0,815 | 0,016 | 0,842 |
| 5 escalas, 8 ângulos | 9,86 | 0,785 | 0,015 | 0,850 |
| 5 escalas, 16 ângulos | 17,19 | 0,867 | 0,017 | 0,787 |

Fonte: Produção do próprio autor

Os Gráficos 6, 7, 8 e 9 apresentam os resultados das áreas ROC e das taxas FRR e FAR de cada classificador analisado. Na ordem de precisão, o melhor algoritmo utilizado para

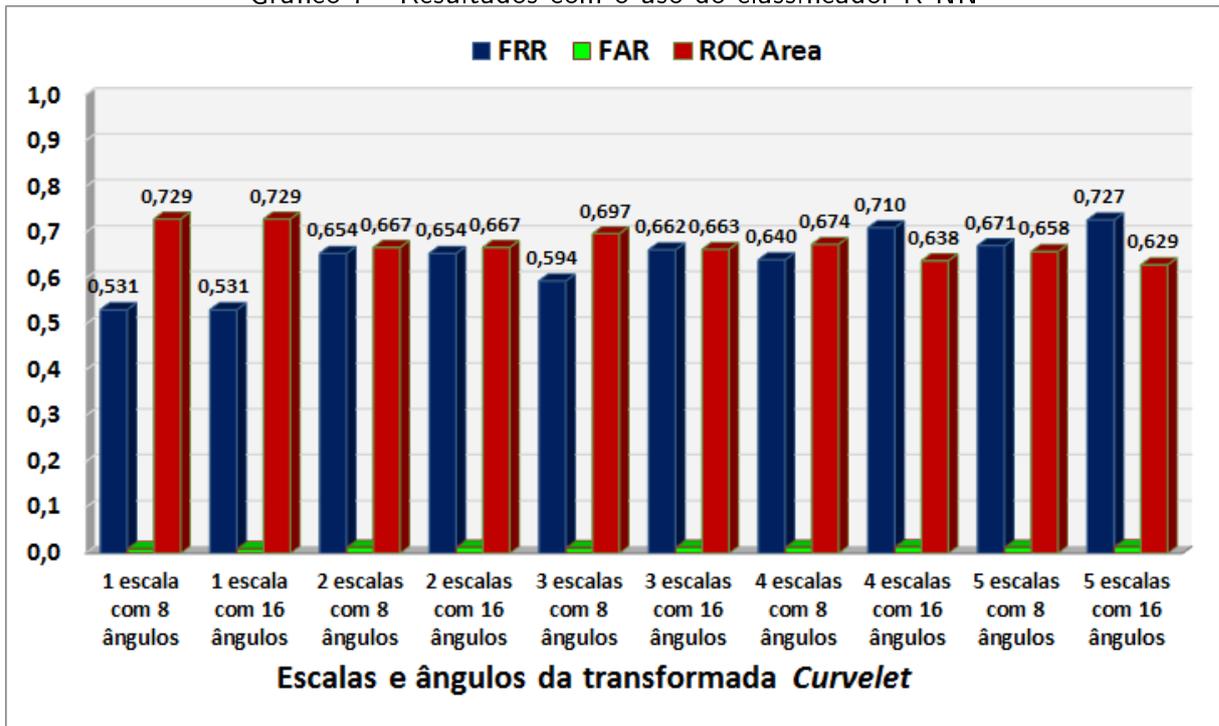
classificação dos dados foi o *Naive Bayes*, seguido pelos algoritmos *Random Forest*, *C4.5/J48* e *KNN*. Nota-se que para classificação dos dados extraídos das imagens, não existe um padrão definido de qual o melhor ângulo ou qual a melhor escala a ser utilizada na transformada de *Curvelet*, os resultados são aleatórios em cada caso avaliado quando utilizada a totalidade dos dados sem o uso de técnicas de seleção.

Gráfico 6 - Resultados com o uso do classificador *Naive Bayes*



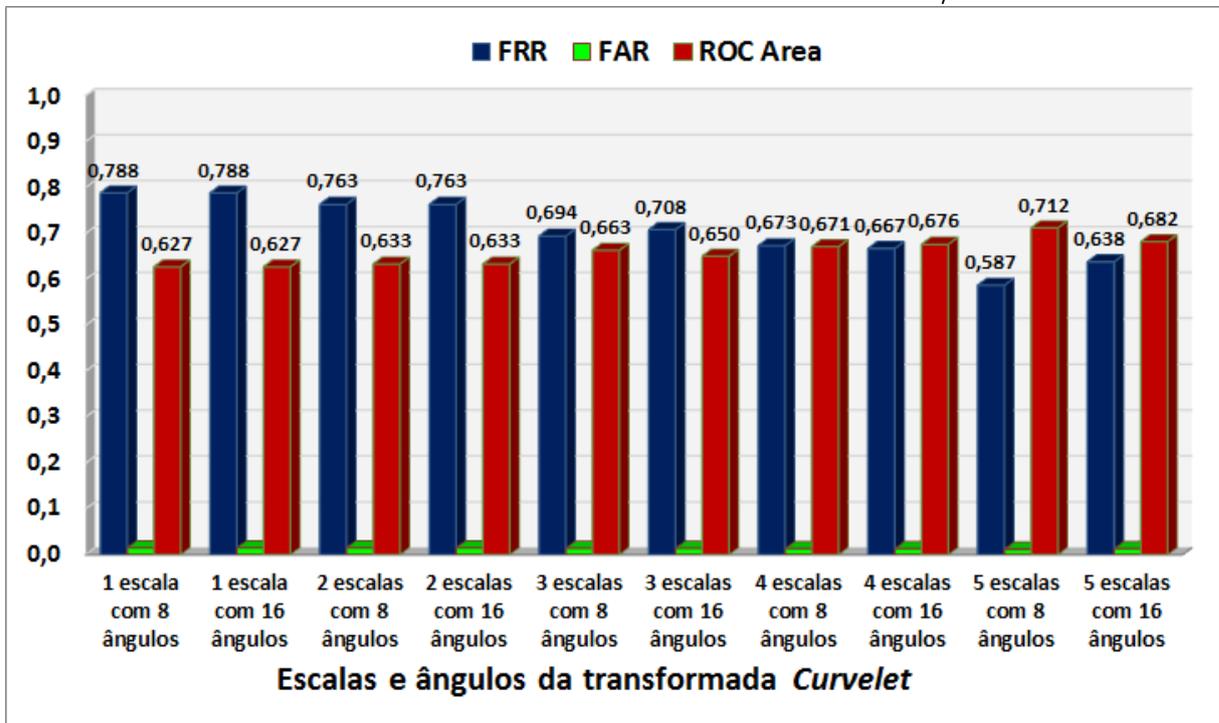
Fonte: Produção do próprio autor

Gráfico 7 - Resultados com o uso do classificador K-NN

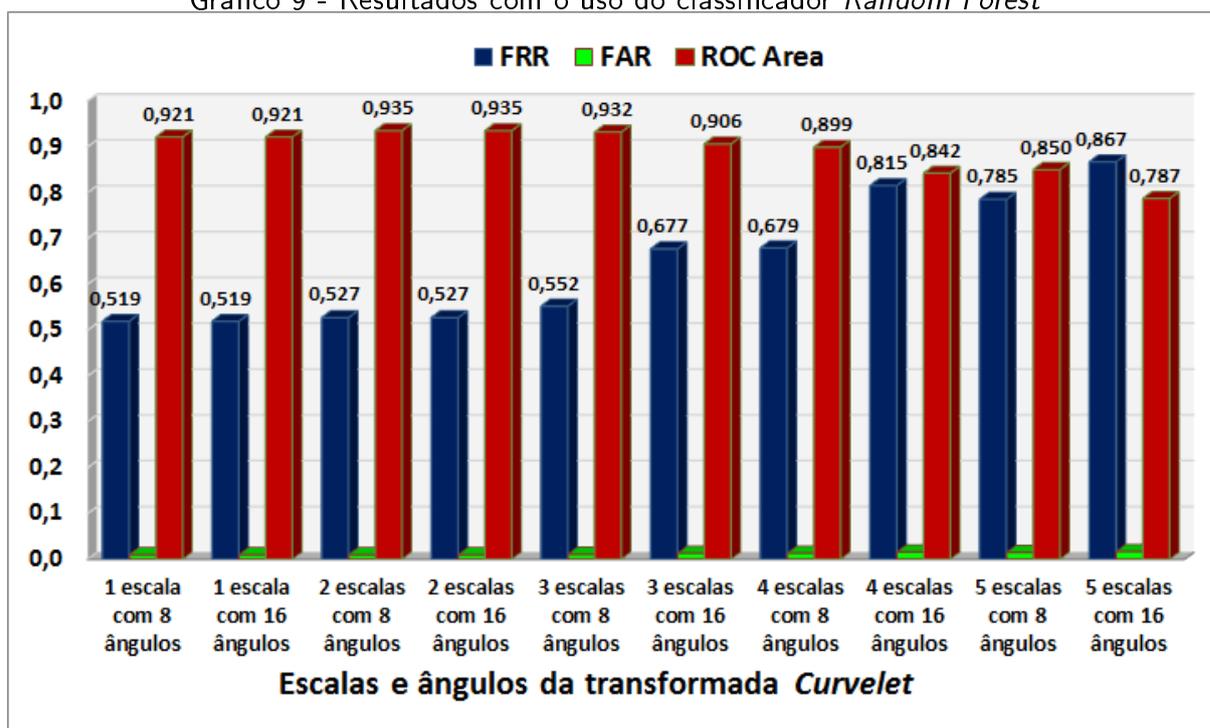


Fonte: Produção do próprio autor

Gráfico 8 - Resultados com o uso do classificador C4.5/J48



Fonte: Produção do próprio autor

Gráfico 9 - Resultados com o uso do classificador *Random Forest*

Fonte: Produção do próprio autor

5.7.2 Classificação de dados após algoritmo SUAEE

A Tabela 10 apresenta os resultados da classificação utilizando o algoritmo *Naive Bayes* após seleção de características utilizando o algoritmo SUAEE. Os tempos de classificação foram praticamente nulos devido à quantidade de dados a serem avaliados terem sido reduzidos pelo algoritmo proposto. Os melhores resultados obtidos foram a FRR igual a 0,188, FAR igual a 0,004 e área ROC igual a 0,978, para 5 escala e 16 ângulos. O uso do algoritmo SUAEE para seleção dos dados apresenta um resultado muito superior que o algoritmo *Naive Bayes* analisado anteriormente com todos os dados, com resultados obtidos de FRR igual a 0,433, FAR igual a 0,008 e área ROC igual a 0,922, para 4 escala e 8 ângulos, mostrando que a aplicação da técnica é válida.

A Tabela 11 apresenta os resultados da classificação utilizando o algoritmo K-NN após seleção de características utilizando o algoritmo SUAEE. Os melhores resultados obtidos foram a FRR igual a 0,177, FAR igual a 0,003 e área ROC igual a 0,910, para 5 escala e 16 ângulos.

Os resultados apresentados pelo algoritmo K-NN antes da aplicação do algoritmo SUAEE foi de FRR igual a 0,531, FAR igual a 0,010 e área ROC igual a 0,729, para 1 escala e 8 ou 16 ângulos, portanto, percebe-se mais uma vez a melhoria com o uso da técnica de seleção de atributos.

A Tabela 12 apresenta os resultados da classificação utilizando o algoritmo C4.5/J48 após

Tabela 10 - Resultados com o classificador *Naive Bayes* e algoritmo SUAE

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,03 | 0,646 | 0,013 | 0,916 |
| 1 escala, 16 ângulos | 0,03 | 0,646 | 0,013 | 0,916 |
| 2 escalas, 8 ângulos | 0,02 | 0,535 | 0,010 | 0,936 |
| 2 escalas, 16 ângulos | 0,03 | 0,535 | 0,010 | 0,936 |
| 3 escalas, 8 ângulos | 0,03 | 0,358 | 0,007 | 0,949 |
| 3 escalas, 16 ângulos | 0,02 | 0,348 | 0,007 | 0,951 |
| 4 escalas, 8 ângulos | 0,02 | 0,267 | 0,005 | 0,967 |
| 4 escalas, 16 ângulos | 0,03 | 0,267 | 0,005 | 0,974 |
| 5 escalas, 8 ângulos | 0,03 | 0,192 | 0,004 | 0,970 |
| 5 escalas, 16 ângulos | 0,02 | 0,188 | 0,004 | 0,978 |

Fonte: Produção do próprio autor

Tabela 11 - Resultados com o classificador K-NN e algoritmo SUAE

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,00 | 0,600 | 0,012 | 0,694 |
| 1 escala, 16 ângulos | 0,00 | 0,600 | 0,012 | 0,694 |
| 2 escalas, 8 ângulos | 0,00 | 0,615 | 0,012 | 0,686 |
| 2 escalas, 16 ângulos | 0,00 | 0,615 | 0,012 | 0,686 |
| 3 escalas, 8 ângulos | 0,00 | 0,475 | 0,009 | 0,758 |
| 3 escalas, 16 ângulos | 0,00 | 0,469 | 0,009 | 0,761 |
| 4 escalas, 8 ângulos | 0,00 | 0,325 | 0,006 | 0,834 |
| 4 escalas, 16 ângulos | 0,00 | 0,333 | 0,007 | 0,830 |
| 5 escalas, 8 ângulos | 0,00 | 0,179 | 0,004 | 0,909 |
| 5 escalas, 16 ângulos | 0,00 | 0,177 | 0,003 | 0,910 |

Fonte: Produção do próprio autor

seleção de características utilizando o algoritmo SUAE. Os tempos de análise não excederam meio segundo pois os dados analisados são reduzidos. Os melhores resultados obtidos foram a FRR igual a 0,481, FAR igual a 0,009 e área ROC igual a 0,767, para 5 escala e 8 ângulos. Este algoritmo novamente apresenta um resultado superior que os alcançados anteriormente com FRR igual a 0,587, FAR igual a 0,012 e área ROC igual a 0,712, para 5 escalas e 8 ângulos.

A Tabela 13 apresenta os resultados da classificação utilizando o algoritmo *Random Forest* após seleção de características utilizando o algoritmo SUAE. O menor tempo de classificação foi de 1,69 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 1 escala e 8 ângulos e o maior tempo de classificação foi de 1,89 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 2 escalas e 8 ângulos. Os melhores resultados obtidos foram a FRR igual a 0,179, FAR igual a 0,004 e área ROC igual a 0,990, para 5 escala e 16 ângulos. A aplicação do algoritmo de seleção de dados melhorou os resultados de FRR igual a 0,519, FAR igual a 0,010 e área ROC igual a 0,921, para 1 escala e 8 ou 16 ângulos obtidos anteriormente.

Tabela 12 - Resultados com o classificador C4.5/J48 e algoritmo SUAE

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,39 | 0,802 | 0,016 | 0,620 |
| 1 escala, 16 ângulos | 0,36 | 0,802 | 0,016 | 0,620 |
| 2 escalas, 8 ângulos | 0,50 | 0,762 | 0,015 | 0,635 |
| 2 escalas, 16 ângulos | 0,55 | 0,762 | 0,015 | 0,635 |
| 3 escalas, 8 ângulos | 0,39 | 0,617 | 0,012 | 0,702 |
| 3 escalas, 16 ângulos | 0,41 | 0,637 | 0,012 | 0,692 |
| 4 escalas, 8 ângulos | 0,41 | 0,573 | 0,011 | 0,727 |
| 4 escalas, 16 ângulos | 0,41 | 0,569 | 0,011 | 0,729 |
| 5 escalas, 8 ângulos | 0,33 | 0,481 | 0,009 | 0,767 |
| 5 escalas, 16 ângulos | 0,33 | 0,488 | 0,010 | 0,765 |

Fonte: Produção do próprio autor

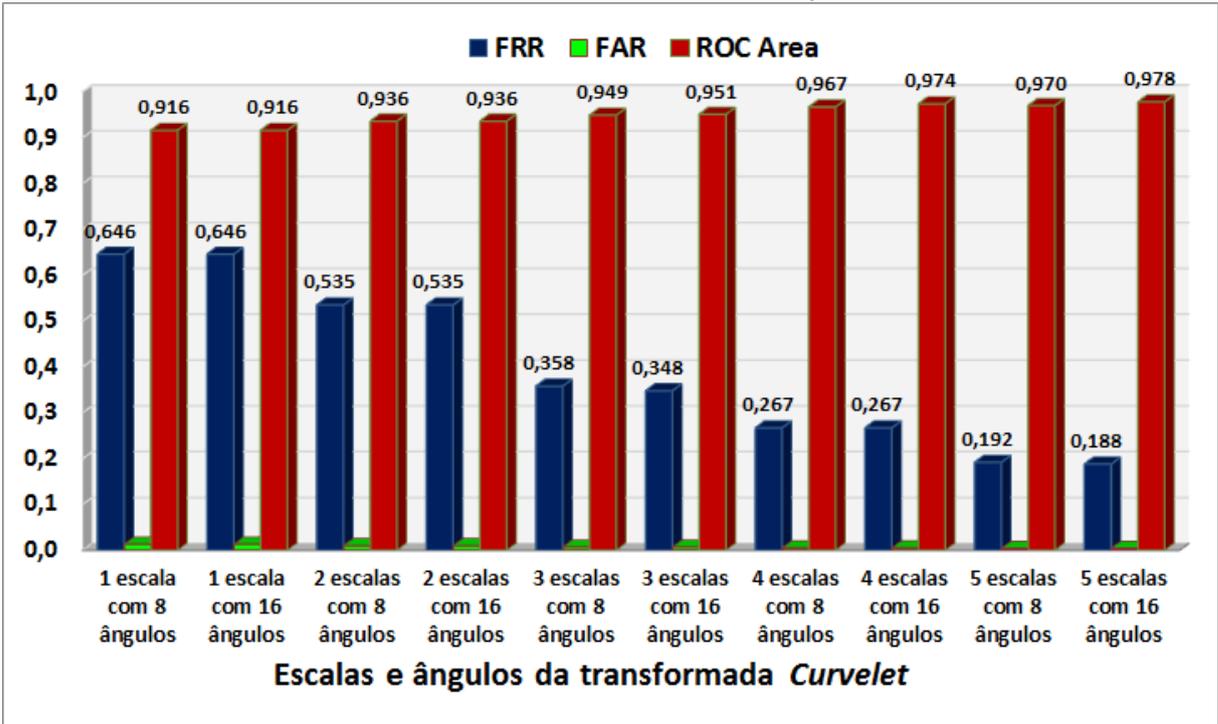
Tabela 13 - Resultados com o classificador *Random Forest* e algoritmo SUAE

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 1,81 | 0,590 | 0,012 | 0,931 |
| 1 escala, 16 ângulos | 1,69 | 0,590 | 0,012 | 0,931 |
| 2 escalas, 8 ângulos | 1,89 | 0,538 | 0,011 | 0,946 |
| 2 escalas, 16 ângulos | 1,87 | 0,538 | 0,011 | 0,946 |
| 3 escalas, 8 ângulos | 1,81 | 0,333 | 0,007 | 0,969 |
| 3 escalas, 16 ângulos | 1,87 | 0,335 | 0,007 | 0,968 |
| 4 escalas, 8 ângulos | 1,75 | 0,248 | 0,005 | 0,987 |
| 4 escalas, 16 ângulos | 1,76 | 0,265 | 0,005 | 0,987 |
| 5 escalas, 8 ângulos | 1,76 | 0,192 | 0,004 | 0,988 |
| 5 escalas, 16 ângulos | 1,79 | 0,179 | 0,004 | 0,990 |

Fonte: Produção do próprio autor

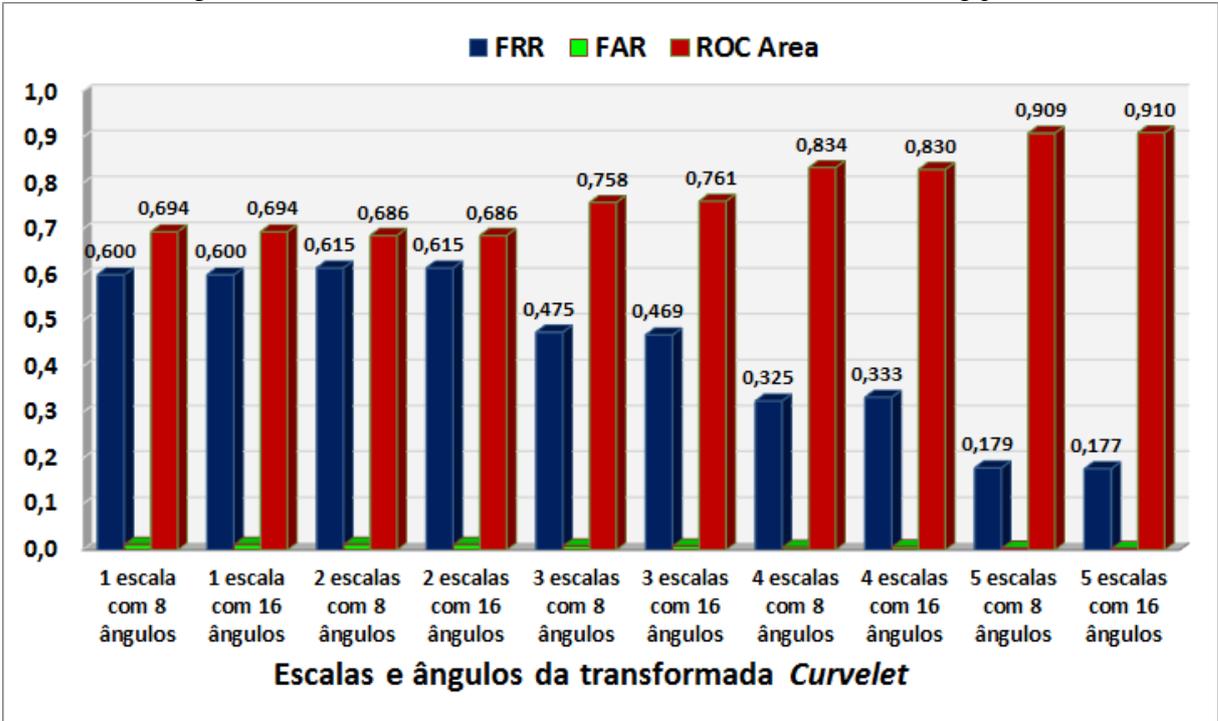
Os Gráficos 10, 11, 12 e 13 apresentam os resultados das áreas ROC e das taxas FRR e FAR de cada classificador analisado. Na ordem de precisão, o melhor algoritmo utilizado para classificação dos dados foi o K-NN, seguido pelos algoritmos *Random Forest*, *Naive Bayes* e C4.5/J48. Nota-se que para classificação dos dados extraídos das imagens, a melhor escala a ser utilizada na transformada de *Curvelet* é igual a 5, com variações entre 8 ou 16 ângulos, os resultados não são aleatórios em cada caso avaliado, pode-se afirmar após análise das Tabelas 10, 11, 12 e 13 que quanto maior a quantidade de subimagens extraídas, maior a precisão do sistema com a seleção das características pelo uso do algoritmo SUAE.

Gráfico 10 - Resultados com classificador *Naive Bayes* utilizando S UAE



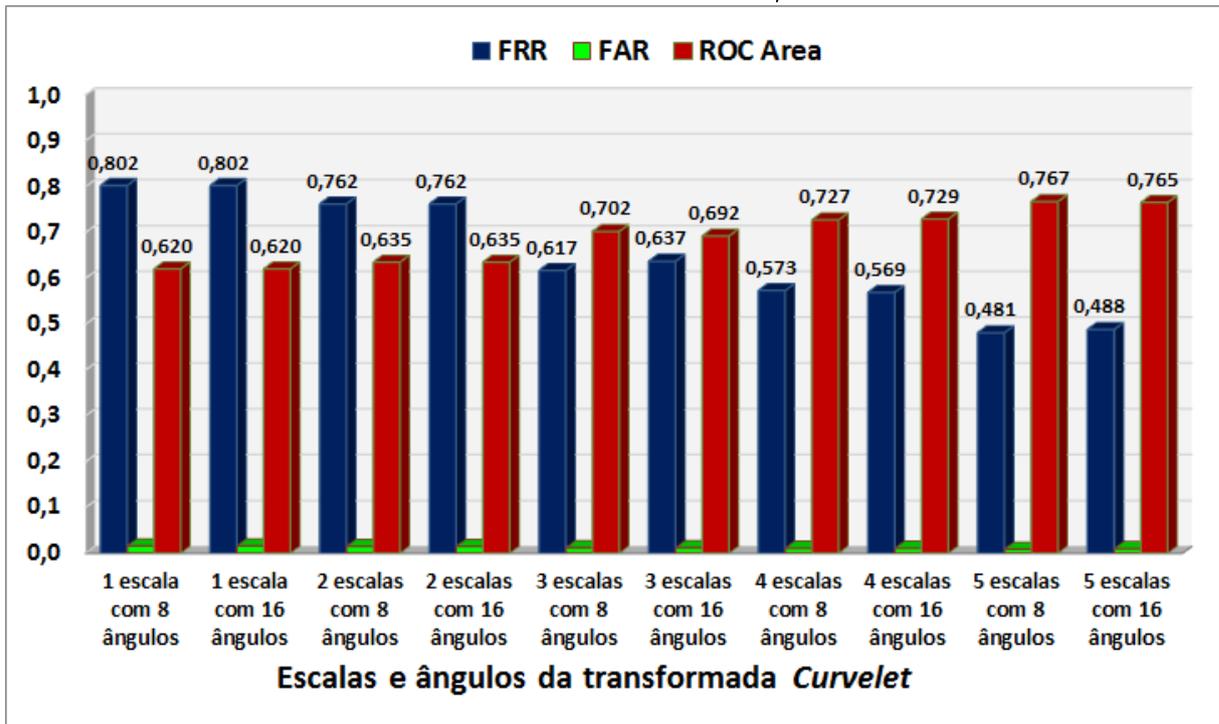
Fonte: Produção do próprio autor

Gráfico 11 - Resultados com classificador K-NN utilizando S UAE

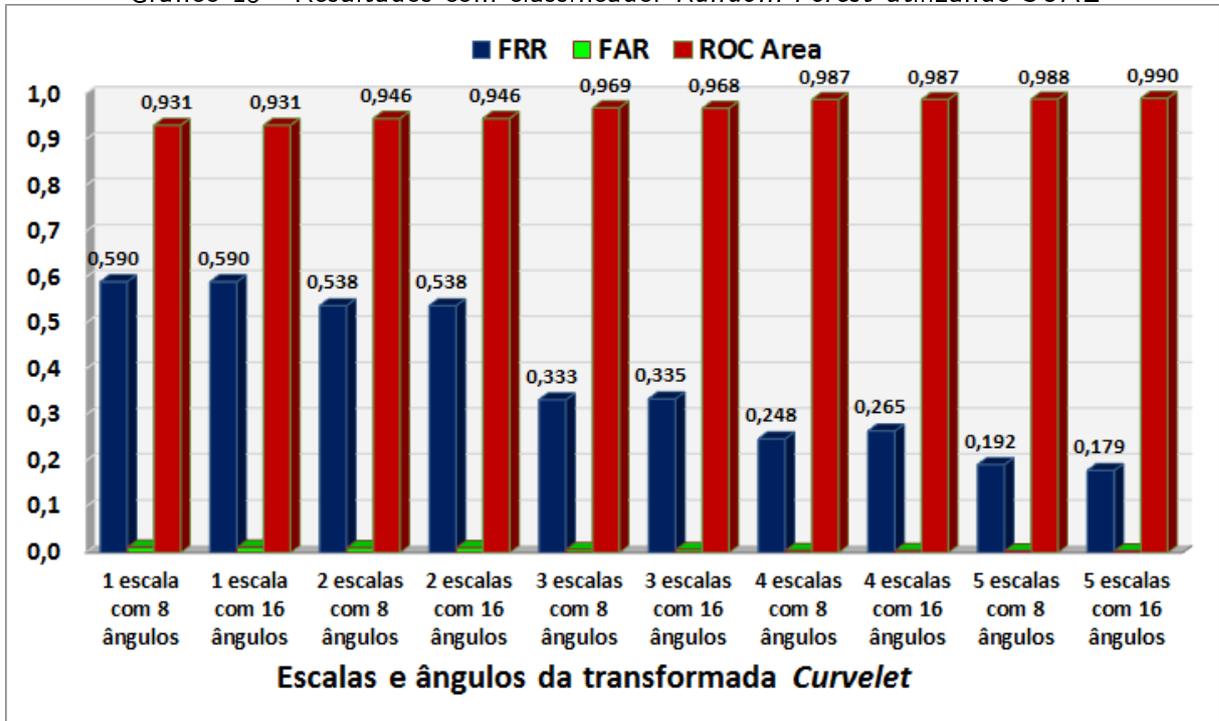


Fonte: Produção do próprio autor

Gráfico 12 - Resultados com classificador C4.5/J48 utilizando SUAE



Fonte: Produção do próprio autor

Gráfico 13 - Resultados com classificador *Random Forest* utilizando SUAE

Fonte: Produção do próprio autor

5.7.3 Classificação de dados após algoritmo CFS

A Tabela 14 apresenta os resultados da classificação utilizando o algoritmo *Naive Bayes* após seleção de características utilizando o algoritmo CFS. Os tempos de classificação foram nulos, pois a quantidade de dados foi muito reduzida, e a classificação ocorreu praticamente em tempo real. Os melhores resultados obtidos foram a FRR igual a 0,150, FAR igual a 0,003 e área ROC igual a 0,995, para 5 escala e 8 ou 16 ângulos. Comparando-se com os resultados obtidos antes da seleção de características as taxas de FRR igual a 0,531, FAR igual a 0,010 e área ROC igual a 0,729 melhoraram e após o uso do algoritmo SVAE apresentando taxas de FRR igual a 0,188, FAR igual a 0,004 e área ROC igual a 0,978, para 5 escala e 16 ângulos também melhoraram. Este algoritmo de seleção de características, além de ser o melhor em termos de quantidade de dados a serem analisados, também supera o algoritmo SVAE.

Tabela 14 - Resultados com o classificador *Naive Bayes* e algoritmo CFS

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,00 | 0,677 | 0,013 | 0,923 |
| 1 escala, 16 ângulos | 0,03 | 0,677 | 0,013 | 0,923 |
| 2 escalas, 8 ângulos | 0,00 | 0,648 | 0,013 | 0,934 |
| 2 escalas, 16 ângulos | 0,00 | 0,648 | 0,013 | 0,934 |
| 3 escalas, 8 ângulos | 0,00 | 0,463 | 0,009 | 0,945 |
| 3 escalas, 16 ângulos | 0,00 | 0,629 | 0,012 | 0,925 |
| 4 escalas, 8 ângulos | 0,00 | 0,281 | 0,006 | 0,983 |
| 4 escalas, 16 ângulos | 0,00 | 0,281 | 0,006 | 0,983 |
| 5 escalas, 8 ângulos | 0,00 | 0,150 | 0,003 | 0,995 |
| 5 escalas, 16 ângulos | 0,02 | 0,150 | 0,003 | 0,995 |

Fonte: Produção do próprio autor

A Tabela 15 apresenta os resultados da classificação utilizando o algoritmo K-NN após seleção de características utilizando o algoritmo CFS. Os tempos de classificação foram praticamente nulos como no caso anterior, os resultados foram apresentados em tempo real, assim como aconteceu antes das reduções, conforme esperado pelo fato da quantidade de dados ter sido reduzida.

Os melhores resultados obtidos foram a FRR igual a 0,150, FAR igual a 0,003 e área ROC igual a 0,924, para 5 escala e 8 ou 16 ângulos. Comparando-se com os resultados obtidos antes da seleção de características as taxas de FRR igual a 0,531, FAR igual a 0,010 e área ROC igual a 0,729, para 1 escala e 8 ou 16 ângulos melhoraram e após o uso do algoritmo SVAE com taxas de FRR igual a 0,177, FAR igual a 0,003 e área ROC igual a 0,910, para 5 escala e 16 ângulos também melhoraram.

A Tabela 16 apresenta os resultados da classificação utilizando o algoritmo C4.5/J48 após seleção de características utilizando o algoritmo CFS. Pode-se afirmar novamente que os tem-

Tabela 15 - Resultados com o classificador K-NN e algoritmo CFS

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,00 | 0,721 | 0,014 | 0,632 |
| 1 escala, 16 ângulos | 0,00 | 0,721 | 0,014 | 0,632 |
| 2 escalas, 8 ângulos | 0,00 | 0,667 | 0,013 | 0,660 |
| 2 escalas, 16 ângulos | 0,02 | 0,667 | 0,013 | 0,660 |
| 3 escalas, 8 ângulos | 0,00 | 0,481 | 0,009 | 0,755 |
| 3 escalas, 16 ângulos | 0,00 | 0,644 | 0,013 | 0,672 |
| 4 escalas, 8 ângulos | 0,00 | 0,388 | 0,008 | 0,802 |
| 4 escalas, 16 ângulos | 0,00 | 0,388 | 0,008 | 0,802 |
| 5 escalas, 8 ângulos | 0,00 | 0,150 | 0,003 | 0,924 |
| 5 escalas, 16 ângulos | 0,00 | 0,150 | 0,003 | 0,924 |

Fonte: Produção do próprio autor

pos de classificação foram praticamente nulos como nos dois casos anteriores. Os melhores resultados obtidos foram a FRR igual a 0,429, FAR igual a 0,008 e área ROC igual a 0,800, para 5 escala e 8 ou 16 ângulos. Comparando-se com os resultados obtidos antes da seleção de características as taxas de FRR igual a 0,587, FAR igual a 0,012 e área ROC igual a 0,712, para 5 escalas e 8 ângulos melhoraram e após o uso do algoritmo SUAE com taxas de FRR igual a 0,481, FAR igual a 0,009 e área ROC igual a 0,767, para 5 escala e 8 ângulos também melhoraram. Este algoritmo de seleção de características, além de ser o melhor em termos de quantidade de dados a serem analisados, também supera o algoritmo SUAE como no uso do algoritmo *Naive Bayes* e do algoritmo K-NN.

Tabela 16 - Resultados com o classificador C4.5/J48 e algoritmo CFS

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------------|--------------|--------------|--------------|
| 1 escala, 8 ângulos | 0,69 | 0,802 | 0,016 | 0,632 |
| 1 escala, 16 ângulos | 0,03 | 0,802 | 0,016 | 0,632 |
| 2 escalas, 8 ângulos | 0,02 | 0,742 | 0,015 | 0,659 |
| 2 escalas, 16 ângulos | 0,03 | 0,742 | 0,015 | 0,659 |
| 3 escalas, 8 ângulos | 0,02 | 0,638 | 0,013 | 0,705 |
| 3 escalas, 16 ângulos | 0,03 | 0,721 | 0,014 | 0,673 |
| 4 escalas, 8 ângulos | 0,05 | 0,550 | 0,011 | 0,751 |
| 4 escalas, 16 ângulos | 0,03 | 0,550 | 0,011 | 0,751 |
| 5 escalas, 8 ângulos | 0,05 | 0,429 | 0,008 | 0,800 |
| 5 escalas, 16 ângulos | 0,05 | 0,429 | 0,008 | 0,800 |

Fonte: Produção do próprio autor

A Tabela 17 apresenta os resultados da classificação utilizando o algoritmo *Random Forest* após seleção de características utilizando o algoritmo CFS. O menor tempo de classificação foi de 0,69 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 2 escalas e 8 ângulos e o maior tempo de classificação foi de 1,06 segundos, obtido com as imagens que foram extraídas pela transformada de *Curvelet* utilizando 1 escala e 8

ângulos. Os melhores resultados obtidos foram a FRR igual a 0,127, FAR igual a 0,002 e área ROC igual a 0,996, para 5 escala e 8 ou 16 ângulos. Comparando-se com os resultados obtidos antes da seleção de características as taxas de FRR igual a 0,519, FAR igual a 0,010 e área ROC igual a 0,921, para 1 escala e 8 ou 16 ângulos melhoraram e após o uso do algoritmo SUAEE com taxas de FRR igual a 0,179, FAR igual a 0,004 e área ROC igual a 0,990, para 5 escala e 16 ângulos também melhoraram. Este algoritmo de seleção de características, além de ser o melhor em termos de quantidade de dados a serem analisados, também supera o algoritmo SUAEE como no uso do algoritmo *Naive Bayes*, do algoritmo K-NN e do algoritmo C4.5/J48.

Tabela 17 - Resultados com o classificador *Random Forest* e algoritmo CFS

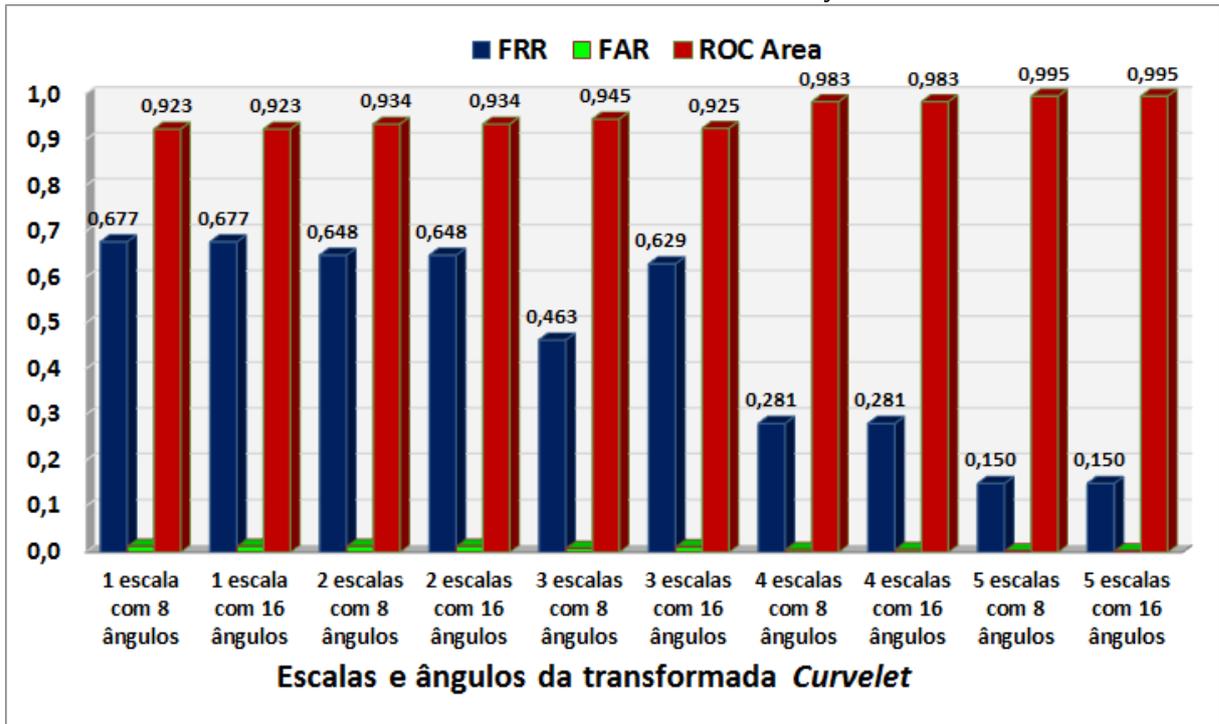
| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------|-------|-------|----------|
| 1 escala, 8 ângulos | 1,06 | 0,688 | 0,013 | 0,922 |
| 1 escala, 16 ângulos | 0,86 | 0,688 | 0,013 | 0,922 |
| 2 escalas, 8 ângulos | 0,69 | 0,621 | 0,012 | 0,928 |
| 2 escalas, 16 ângulos | 0,70 | 0,621 | 0,012 | 0,928 |
| 3 escalas, 8 ângulos | 0,86 | 0,396 | 0,008 | 0,951 |
| 3 escalas, 16 ângulos | 0,92 | 0,569 | 0,011 | 0,942 |
| 4 escalas, 8 ângulos | 0,94 | 0,285 | 0,006 | 0,987 |
| 4 escalas, 16 ângulos | 0,92 | 0,285 | 0,006 | 0,987 |
| 5 escalas, 8 ângulos | 1,01 | 0,127 | 0,002 | 0,996 |
| 5 escalas, 16 ângulos | 0,84 | 0,127 | 0,002 | 0,996 |

Fonte: Produção do próprio autor

Os Gráficos 14, 15, 16 e 17 apresentam os resultados das áreas ROC e das taxas FRR e FAR de cada classificador analisado. Na ordem de precisão, o melhor algoritmo utilizado para classificação dos dados foi o *Random Forest*, os algoritmos *Naive Bayes* e K-NN apresentam resultados iguais em termos de taxas FRR e FAR mas o primeiro é superior no critério de área ROC, e o pior algoritmo é o C4.5/J48. Nota-se que para classificação dos dados extraídos das imagens, a melhor escala a ser utilizada na transformada de *Curvelet* é igual a 5, com variações entre 8 ou 16 ângulos, como já havia sido verificado na aplicação do algoritmo SUAEE.

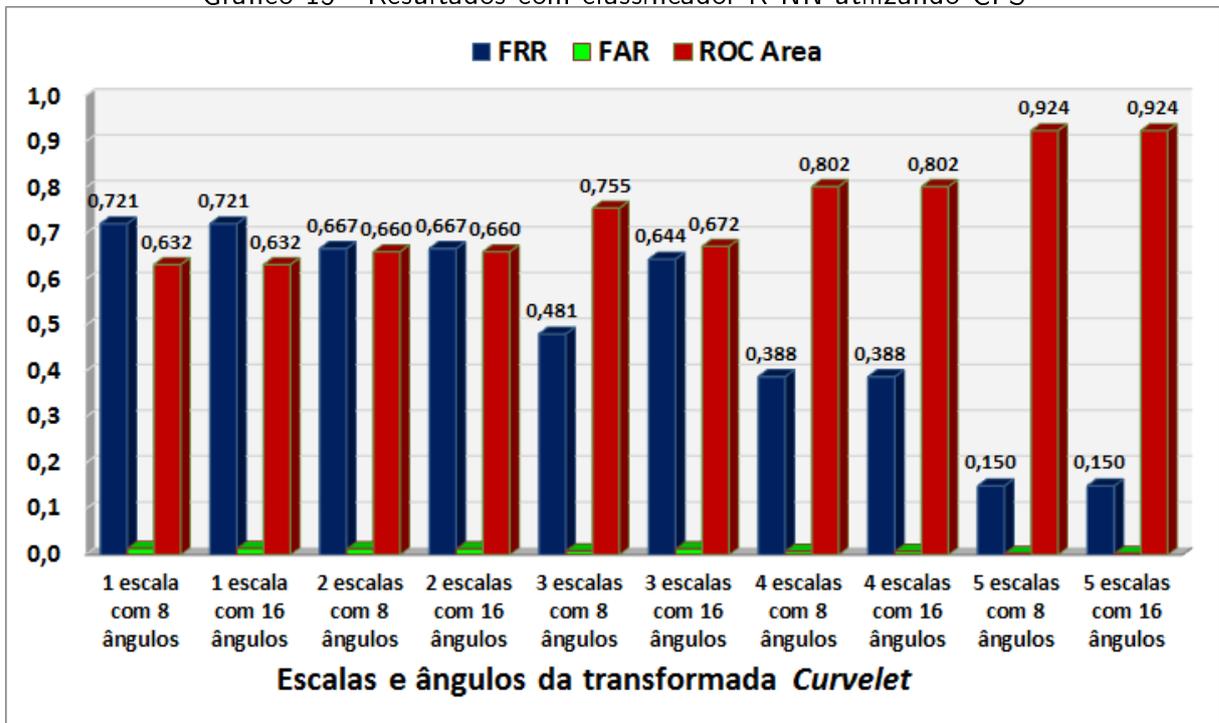
5.8 ANÁLISE DE CLASSIFICAÇÃO COM REDE NEURAL ARTIFICIAL

A rede neural artificial criada utiliza o parâmetro “a” no campo *hyddenLayers*. Este parâmetro define a quantidade de camadas ocultas e quantos neurônios artificiais constituirão cada camada. A quantidade de camadas ocultas é fixada em única por este parâmetro e a quantidade de neurônios artificiais é calculada somando-se a quantidade de atributos de cada imagem (parâmetros de entrada da rede neural artificial) com as classes da rede (parâmetros de saída da rede neural, que neste caso são os usuários cadastrados no sistema biométrico), e

Gráfico 14 - Resultados com classificador *Naive Bayes* utilizando CFS

Fonte: Produção do próprio autor

Gráfico 15 - Resultados com classificador K-NN utilizando CFS

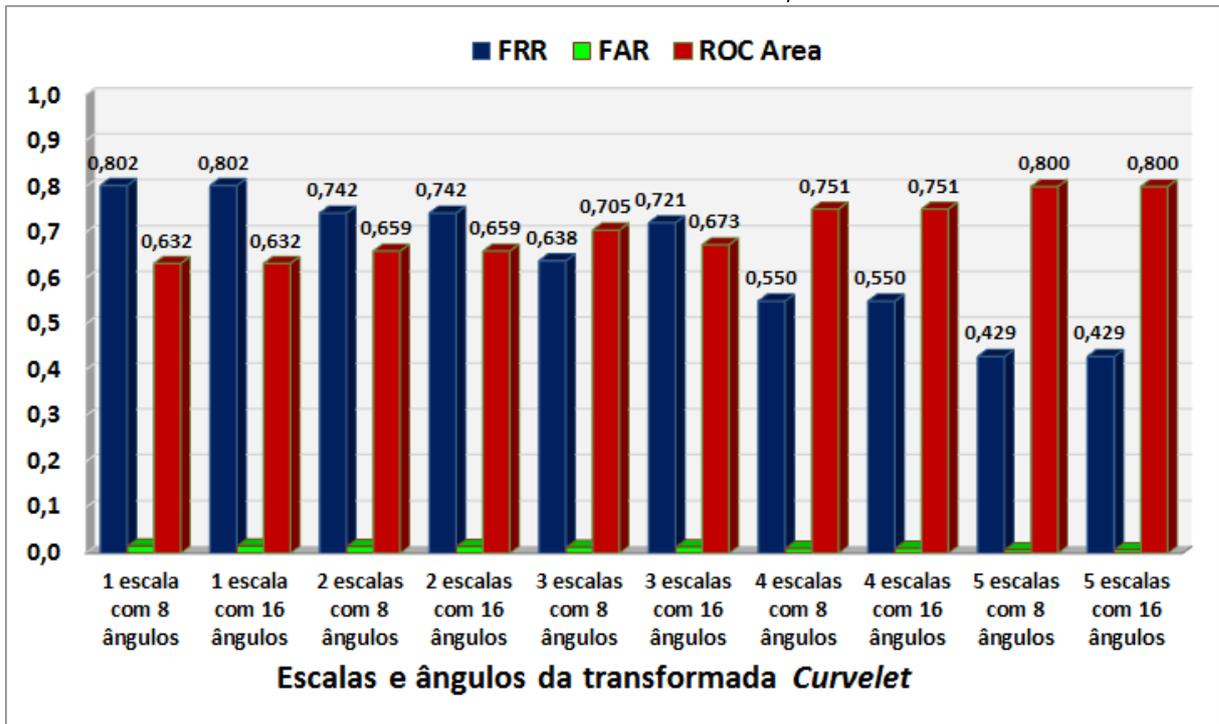


Fonte: Produção do próprio autor

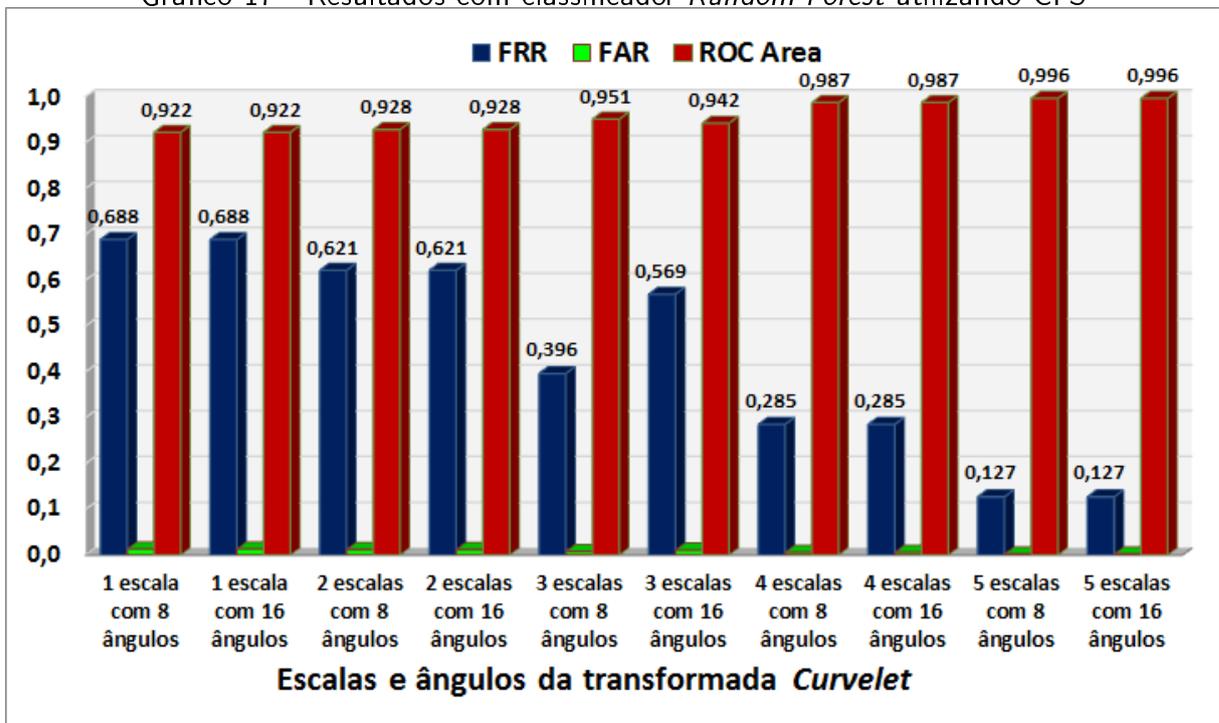
dividindo o resultado por dois. A quantidade de neurônios artificiais criados em cada análise pode ser visualizada na Tabela 18.

Foram realizados três testes distintos sendo o primeiro com todos os parâmetros extraídos de cada imagem, o segundo teste com aplicação das técnicas de seleção de características **SUAE**

Gráfico 16 - Resultados com classificador C4.5/J48 utilizando CFS



Fonte: Produção do próprio autor

Gráfico 17 - Resultados com classificador *Random Forest* utilizando CFS

Fonte: Produção do próprio autor

e e o terceiro teste com técnicas de seleção de características **CFS**. As análises realizadas mostraram que a rede neural artificial se torna inaplicável quando a quantidade de dados de entrada é elevado, do ponto de vista do tempo demandado para a resolução. A quantidade de dados de entrada utilizada para os testes são os mesmos demonstrados na Tabela 18. O tempo

Tabela 18 - Quantidade de neurônios artificiais criados na classificação por RNA

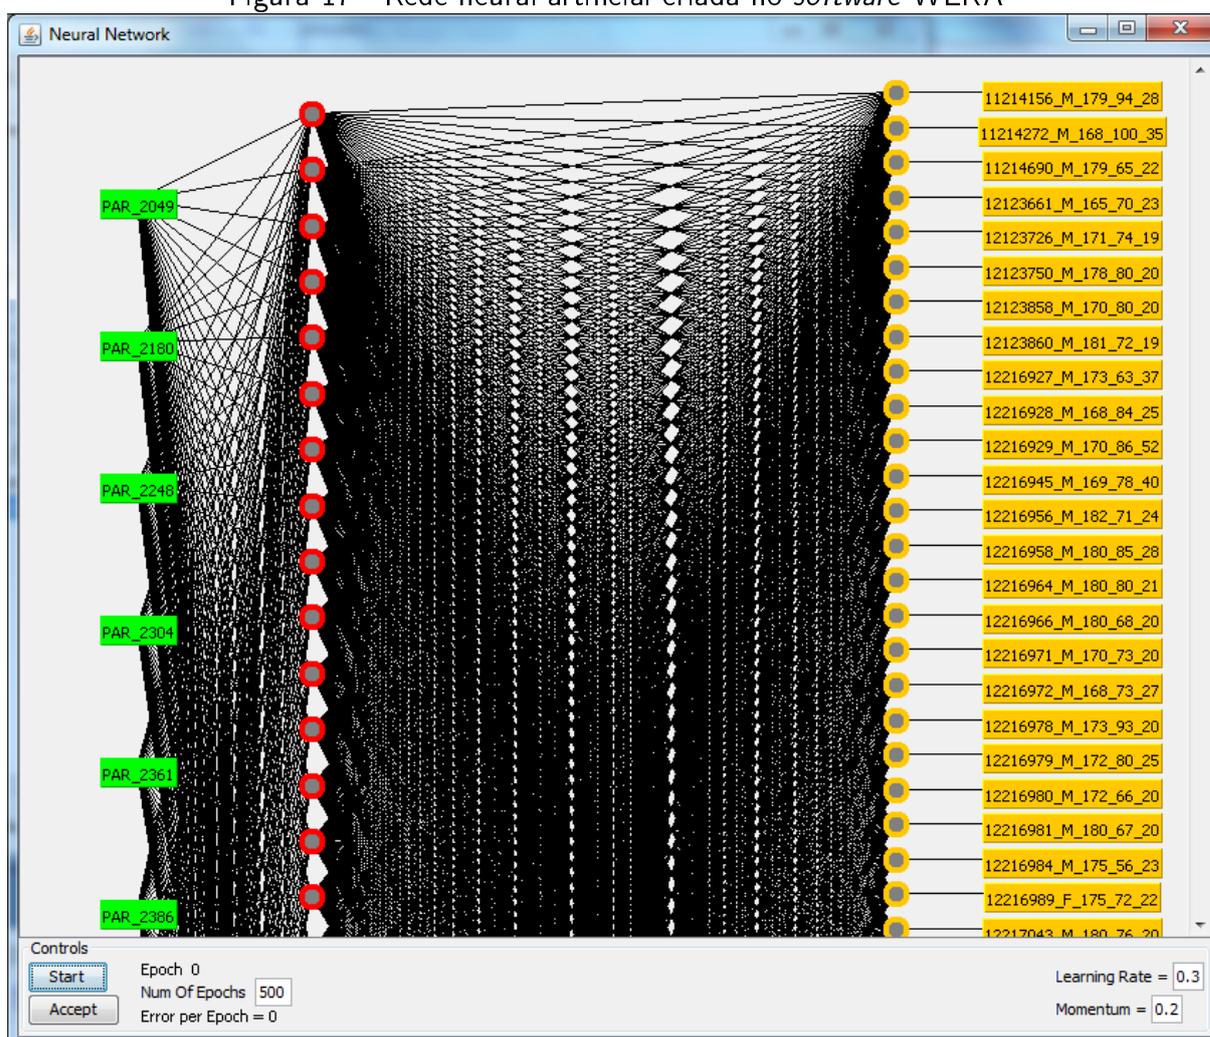
| <i>CURVELETS</i> | Qtde. de neurônios artificiais criados com os dados originais | Qtde. de neurônios artificiais criados após seleção por SUAE | Qtde. de neurônios artificiais criados após seleção por CFS |
|-----------------------|---|---|--|
| 1 escala, 8 ângulos | 282 | 121 | 32 |
| 1 escala, 16 ângulos | 282 | 121 | 32 |
| 2 escalas, 8 ângulos | 282 | 149 | 29 |
| 2 escalas, 16 ângulos | 282 | 149 | 29 |
| 3 escalas, 8 ângulos | 794 | 137 | 31 |
| 3 escalas, 16 ângulos | 1306 | 138 | 31 |
| 4 escalas, 8 ângulos | 1818 | 146 | 34 |
| 4 escalas, 16 ângulos | 3354 | 192 | 34 |
| 5 escalas, 8 ângulos | 2842 | 130 | 35 |
| 5 escalas, 16 ângulos | 5402 | 126 | 35 |

Fonte: Produção do próprio autor

de execução da rede levou cerca de 22 horas para geração de resultados quando utilizados todos os parâmetros extraídos pela transformada de *Curvelet*. A mesma característica foi verificada com o uso de reduções por algoritmo **SUAE** pois apesar de reduzir a quantidade de dados a serem analisados, o tempo de execução da rede levou cerca de 8 horas para geração de resultados. Estes dois casos demonstram inviabilidade de uso em sistemas reais de identificação de pessoas. Com a aplicação da técnica de seleção de dados utilizando o algoritmo **CFS** os resultados foram satisfatórios, pois os tempos de execução foram em média de 37,49 segundos para a construção e análise da rede completa e classificação dos 52 usuários da análise efetuada, o que resulta em média 720 *ms* segundos para a identificação de uma pessoa.

A Figura 17 ilustra a rede neural artificial criada no *software* WEKA. O número de épocas (do inglês *number of epochs*) utilizado foi 500 (tempo de treinamento, trata-se de quinhentos ciclos de propagação e retropropagação da rede neural artificial durante o treinamento), e após testes efetuados, nota-se que a partir de 100 épocas os resultados são praticamente os mesmos, apresentando uma variação de FRR em **0,004**, com o tempo de processamento cinco vezes mais rápido.

Os resultados obtidos podem ser visualizados na Tabela 19. Pode-se notar na tabela citada que os resultados se repetem quanto à variação de ângulos, neste caso só são relevantes as alterações de escala na extração de características por transformada de *Curvelet*. Levando-se em consideração que a extração de dados com variação de ângulos altera significativamente o tempo de processamento (8 ângulos utiliza menos tempo computacional no processamento que 16 ângulos), é razoável adotar neste método de classificação apenas extrações com 8

Figura 17 - Rede neural artificial criada no *software* WEKA

Fonte: Produção do próprio autor

ângulos. Dessa forma, os melhores resultados obtidos foram a FRR igual a 0,038, FAR igual a 0,001 e área ROC igual a 0,999, para 5 escalas e 8 ou 16 ângulos. Os melhores resultados obtidos até então eram da classificação por árvore de decisão *Random Forest* após seleção com algoritmo CFS utilizando 5 escalas e 8 ângulos, que apresentavam a FRR igual a 0,127, FAR igual a 0,002 e área ROC igual a 0,996, mostrando assim que a rede neural artificial proposta supera todas as outras técnicas de classificação utilizadas neste trabalho.

O Gráfico 18 apresenta os resultados das taxas FAR, FRR e área ROC obtidas pelo processo de classificação por RNA, mostrados na Tabela 19.

5.9 ANÁLISE DA QUANTIDADE DE IMAGENS UTILIZADAS

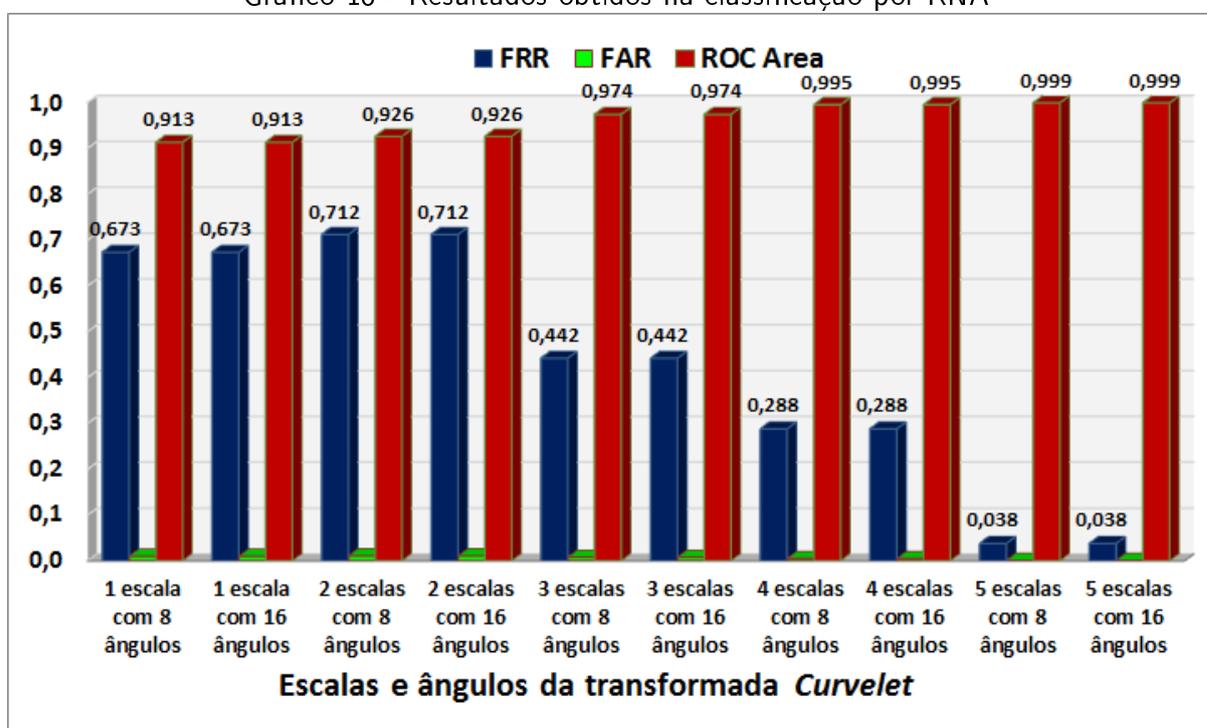
Foram criados dez bancos de dados diferentes variando a quantidade de imagens em cada banco. No primeiro banco de dados, foi colocada somente a primeira imagem capturada da mão de cada usuário, no segundo banco de dados foram colocadas as primeiras e segundas

Tabela 19 - Resultados com o classificador RNA e algoritmo CFS

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------|-------|-------|----------|
| 1 escala, 8 ângulos | 37,62 | 0,673 | 0,010 | 0,913 |
| 1 escala, 16 ângulos | 35,58 | 0,673 | 0,010 | 0,913 |
| 2 escalas, 8 ângulos | 29,09 | 0,712 | 0,011 | 0,926 |
| 2 escalas, 16 ângulos | 29,39 | 0,712 | 0,011 | 0,926 |
| 3 escalas, 8 ângulos | 32,90 | 0,442 | 0,008 | 0,974 |
| 3 escalas, 16 ângulos | 47,46 | 0,442 | 0,008 | 0,974 |
| 4 escalas, 8 ângulos | 38,88 | 0,288 | 0,005 | 0,995 |
| 4 escalas, 16 ângulos | 39,11 | 0,288 | 0,005 | 0,995 |
| 5 escalas, 8 ângulos | 42,49 | 0,038 | 0,001 | 0,999 |
| 5 escalas, 16 ângulos | 42,35 | 0,038 | 0,001 | 0,999 |

Fonte: Produção do próprio autor

Gráfico 18 - Resultados obtidos na classificação por RNA



Fonte: Produção do próprio autor

imagens de cada usuário, o terceiro banco de dados é composto pela primeira, segunda e terceira imagem de cada usuário e assim sucessivamente até o uso das dez imagens. A hipótese levantada nesta análise é de que possam ser realizadas classificações com um número menor de imagens capturadas. Para as análises, foram aplicados novamente os cinco classificadores escolhidos neste trabalho, e as extrações de características foram feitas com o uso da transformada de *Curvelet*, com os parâmetros de escala igual a 5 e ângulo igual a 8, pois estes foram os que apresentaram melhor classificação na seção anterior. A Tabela 20 apresenta os resultados com o uso do classificador *Naive Bayes* aplicado aos diversos bancos de dados criados. Pode-se observar que a partir de 4 imagens em cada banco, o resultado em relação

às taxas FRR, FAR e área ROC já são satisfatórios. Para se obter um resultado razoável, ou seja, mais próximo dos resultados obtidos com dez imagens, é necessário neste classificador utilizar ao menos cinco imagens.

Tabela 20 - Classificador *Naive Bayes* com variação da quantidade de imagens

| Quantidade | Tempo | FRR | FAR | ROC area |
|------------|-------|-------|-------|----------|
| 1 imagem | 0,00 | 1,000 | 0,020 | 0,490 |
| 2 imagens | 0,00 | 1,000 | 0,020 | 0,412 |
| 3 imagens | 0,00 | 0,891 | 0,017 | 0,768 |
| 4 imagens | 0,00 | 0,495 | 0,001 | 0,932 |
| 5 imagens | 0,00 | 0,281 | 0,006 | 0,975 |
| 6 imagens | 0,00 | 0,240 | 0,005 | 0,984 |
| 7 imagens | 0,00 | 0,192 | 0,004 | 0,987 |
| 8 imagens | 0,00 | 0,142 | 0,003 | 0,992 |
| 9 imagens | 0,02 | 0,143 | 0,003 | 0,993 |
| 10 imagens | 0,02 | 0,150 | 0,003 | 0,995 |

Fonte: Produção do próprio autor

No caso do classificador K-NN, a partir de duas imagens pode-se obter bons resultados, como pode ser visto na Tabela 21, mas os melhores resultados obtidos também ficaram entre quatro e cinco imagens. Com apenas duas imagens, este classificador já é mais eficiente que o classificador *Naive Bayes*. A partir desta quantidade, os resultados praticamente se repetem.

Tabela 21 - Classificador K-NN com variação da quantidade de imagens

| Quantidade | Tempo | FRR | FAR | ROC area |
|------------|-------|-------|-------|----------|
| 1 imagem | 0.02 | 1,000 | 0,020 | 0,490 |
| 2 imagens | 0,00 | 0,250 | 0,005 | 0,873 |
| 3 imagens | 0,00 | 0,282 | 0,006 | 0,849 |
| 4 imagens | 0,00 | 0,139 | 0,003 | 0,933 |
| 5 imagens | 0,00 | 0,138 | 0,003 | 0,929 |
| 6 imagens | 0,00 | 0,160 | 0,003 | 0,919 |
| 7 imagens | 0.05 | 0,179 | 0,004 | 0,914 |
| 8 imagens | 0,00 | 0,147 | 0,003 | 0,928 |
| 9 imagens | 0,00 | 0,145 | 0,003 | 0,930 |
| 10 imagens | 0,00 | 0,150 | 0,003 | 0,924 |

Fonte: Produção do próprio autor

Os resultados das análises realizadas com o classificador C4.5/J48 são apresentadas na Tabela 22. Nota-se mais uma vez que a partir de cinco imagens, os resultados obtidos são bem próximos. Com cinco imagens tem-se taxas FRR igual a 0,538, FAR igual a 0,011 e área ROC igual a 0,737 enquanto que com dez imagens a taxa FRR é igual a 0,429, FAR igual a 0,008 e área ROC igual a 0,800. A melhoria nos resultados com dez imagens não condiz com o uso do dobro de imagens. Neste algoritmo, em qualquer quantidade de imagens, os resultados são muito piores que os outros utilizados nas análises, na ordem de aproximadamente três

vezes menos preciso.

Tabela 22 - Classificador C4.5/J48 com variação da quantidade de imagens

| Quantidade | Tempo | FRR | FAR | ROC area |
|------------|-------|-------|-------|----------|
| 1 imagem | 2,15 | 1,000 | 0.02 | 0,478 |
| 2 imagens | 0,05 | 0,962 | 0.019 | 0,654 |
| 3 imagens | 0,02 | 0,622 | 0.012 | 0,700 |
| 4 imagens | 0,03 | 0,572 | 0.011 | 0,722 |
| 5 imagens | 0,05 | 0,538 | 0.011 | 0,737 |
| 6 imagens | 0,03 | 0,535 | 0.01 | 0,752 |
| 7 imagens | 0,05 | 0,495 | 0.01 | 0,773 |
| 8 imagens | 0,05 | 0,454 | 0.009 | 0,781 |
| 9 imagens | 0,05 | 0,438 | 0.009 | 0,797 |
| 10 imagens | 0,05 | 0,429 | 0.008 | 0,800 |

Fonte: Produção do próprio autor

O classificador *Random Forest* apresentou resultados parecidos com os outros classificadores, sendo que a partir de cinco imagens os resultados são bem próximos, tanto em relação com a taxa FRR quanto com FAR e área ROC, como pode ser visualizado na Tabela 23:

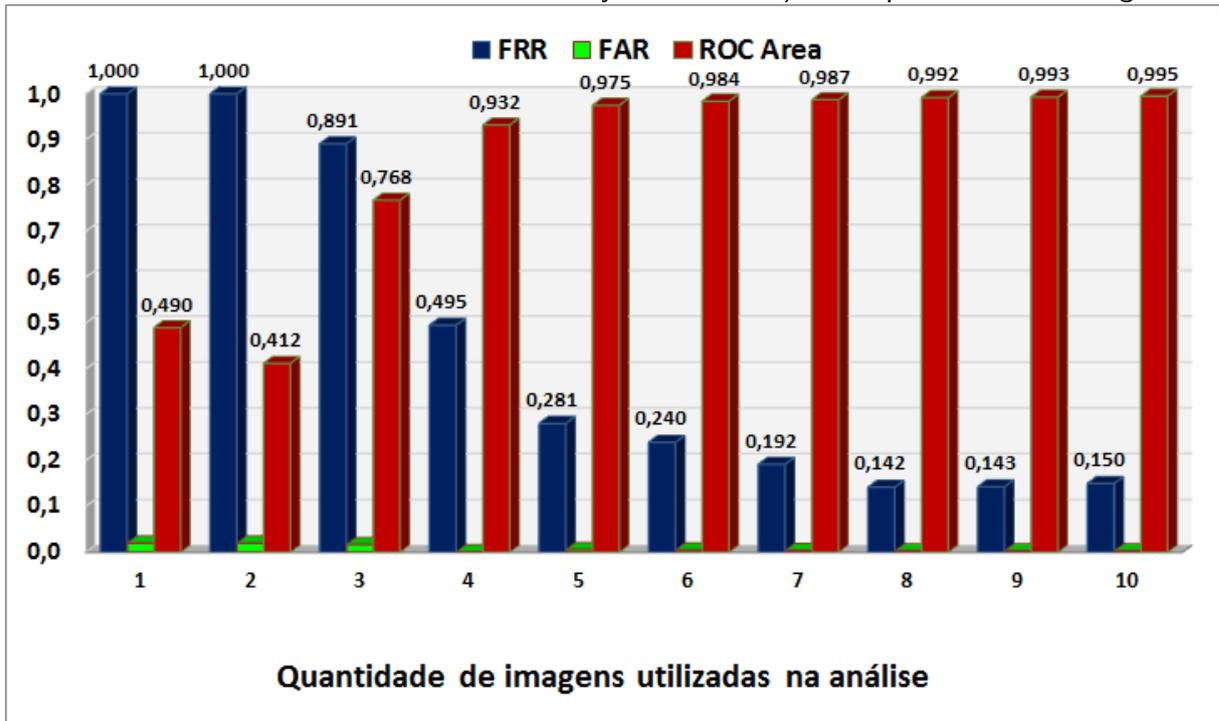
Tabela 23 - Classificador *Random Forest* com variação da quantidade de imagens

| Quantidade | Tempo | FRR | FAR | ROC area |
|------------|-------|-------|-------|----------|
| 1 imagem | 0,92 | 1,000 | 0.02 | 0,101 |
| 2 imagens | 0,33 | 0,606 | 0.012 | 0,960 |
| 3 imagens | 0,48 | 0,365 | 0.007 | 0,982 |
| 4 imagens | 0,62 | 0,250 | 0.005 | 0,988 |
| 5 imagens | 0,80 | 0,158 | 0.003 | 0,992 |
| 6 imagens | 0,80 | 0,176 | 0.003 | 0,993 |
| 7 imagens | 0,91 | 0,143 | 0.003 | 0,995 |
| 8 imagens | 1,26 | 0,135 | 0.003 | 0,995 |
| 9 imagens | 1,45 | 0,139 | 0.003 | 0,995 |
| 10 imagens | 0,84 | 0,127 | 0.002 | 0,996 |

Fonte: Produção do próprio autor

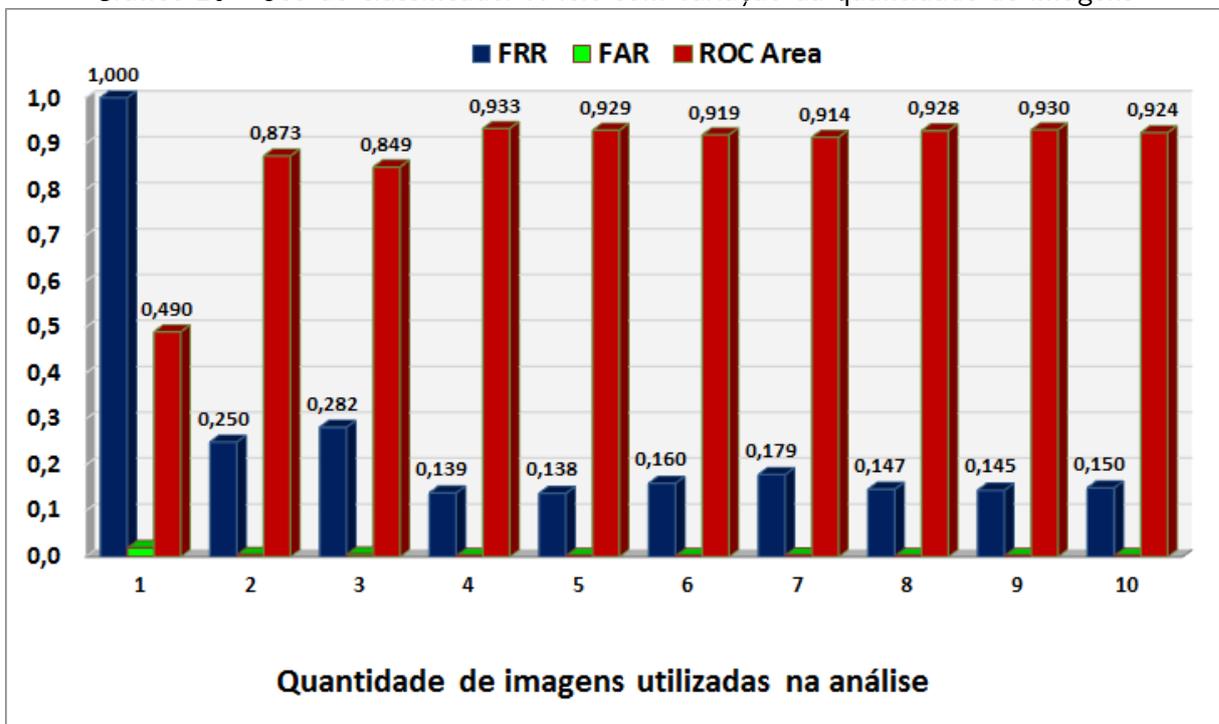
Os Gráficos 19, 20, 21 e 22 apresentam os resultados das Tabelas 20, 21, 22 e 23. Pode-se visualizar de forma mais clara a tendência de repetição de resultados a partir da análise de cinco imagens.

Com a aplicação de redes neurais artificiais não foi possível analisar uma única imagem no banco de dados pois o algoritmo de seleção de características CFS não efetuou reduções nos parâmetros de entrada, com isso a rede neural foi criada com 5632 atributos causando lentidão no processamento. Na prática a rede neural foi treinada por mais de 22 horas e não apresentou resultados. Foram então realizados testes com bancos de dados variando de duas a dez imagens e os resultados podem ser verificados na Tabela 24. Neste caso, os resultados obtidos mostram novamente que a partir de cinco imagens os resultados são satisfatórios,

Gráfico 19 - Uso do classificador *Naive Bayes* com variação da quantidade de imagens

Fonte: Produção do próprio autor

Gráfico 20 - Uso do classificador K-NN com variação da quantidade de imagens

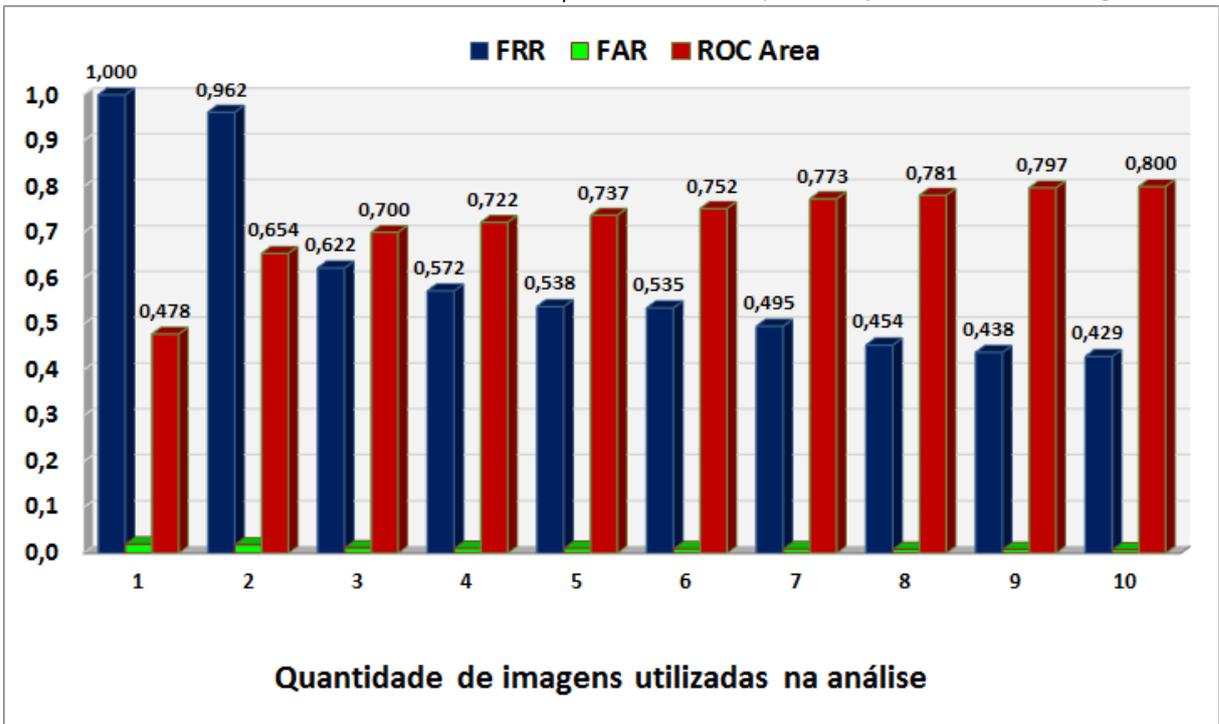


Fonte: Produção do próprio autor

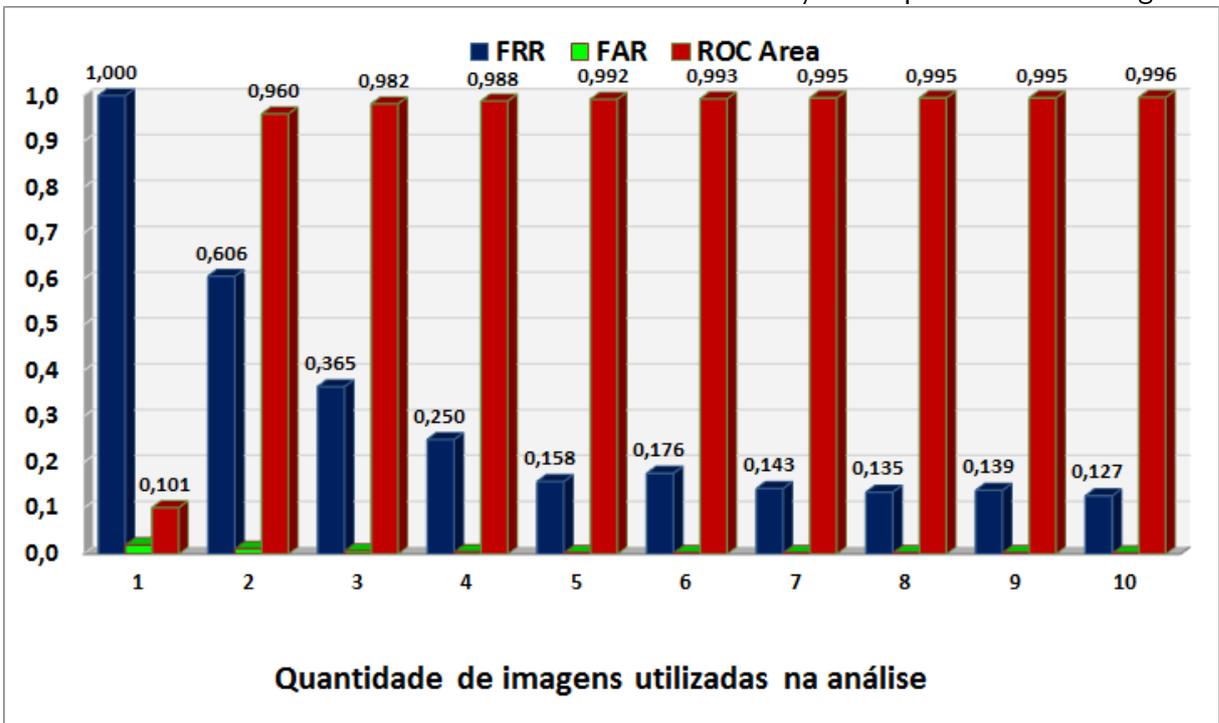
superando os melhores resultados alcançados com o algoritmo *Random Forest*.

O Gráfico 18 apresenta os resultados da Tabela 24. Pode-se visualizar de forma mais clara a tendência de repetição de resultados a partir da análise de cinco imagens.

Gráfico 21 - Uso do classificador C4.5/J48 com variação da quantidade de imagens



Fonte: Produção do próprio autor

Gráfico 22 - Uso do classificador *Random Forest* com variação da quantidade de imagens

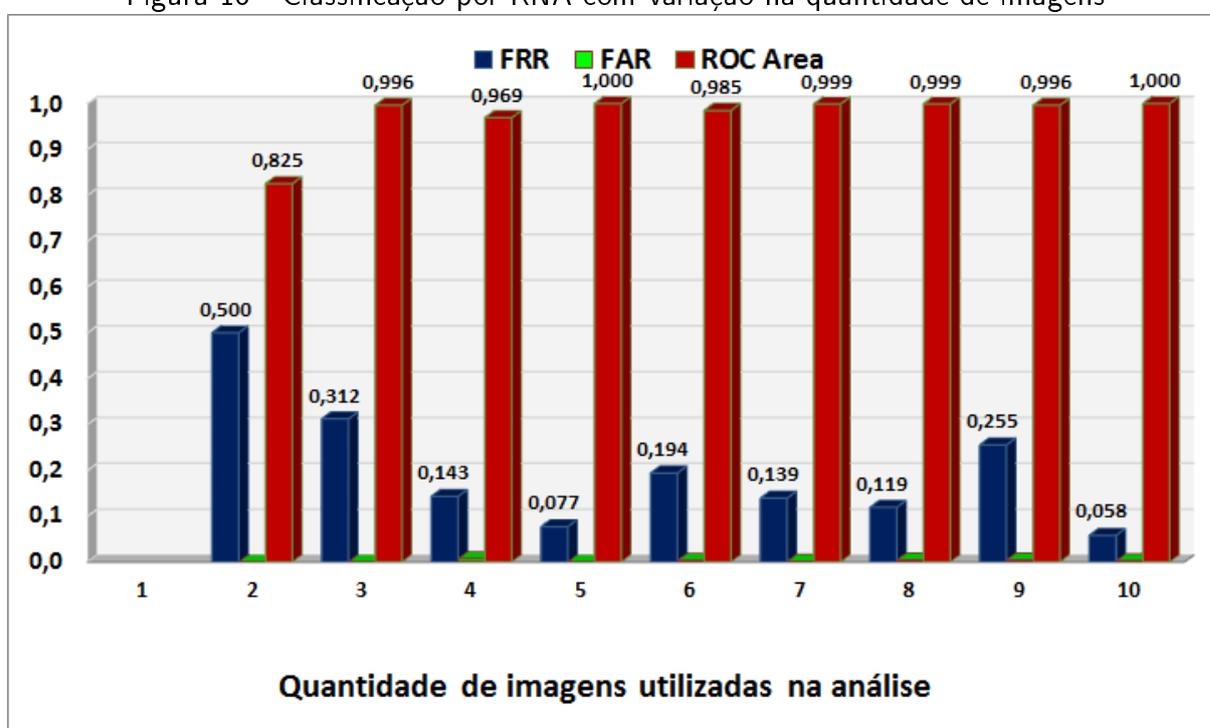
Fonte: Produção do próprio autor

Tabela 24 - Classificador MLP com variação da quantidade de imagens

| Quantidade | Tempo | FRR | FAR | ROC area |
|------------|--------|-------|-------|----------|
| 2 imagens | 21,57 | 0,500 | 0,000 | 0,825 |
| 3 imagens | 36,53 | 0,312 | 0,000 | 0,996 |
| 4 imagens | 29,68 | 0,143 | 0,007 | 0,969 |
| 5 imagens | 133,49 | 0,077 | 0,000 | 1,000 |
| 6 imagens | 40,36 | 0,194 | 0,003 | 0,985 |
| 7 imagens | 24,98 | 0,139 | 0,001 | 0,999 |
| 8 imagens | 88,30 | 0,119 | 0,004 | 0,999 |
| 9 imagens | 113,55 | 0,255 | 0,004 | 0,996 |
| 10 imagens | 98,36 | 0,058 | 0,002 | 1,000 |

Fonte: Produção do próprio autor

Figura 18 - Classificação por RNA com variação na quantidade de imagens



Fonte: Produção do próprio autor

5.10 ANÁLISE DE PERMANÊNCIA DOS DADOS

Uma das características que definem a qualidade de um sistema biométrico é a permanência dos dados. Como forma de se avaliar este parâmetro, foram capturadas imagens de 17 usuários um ano após a primeira captura (agosto de 2014 e agosto de 2015). Esta análise representa uma amostra de 32,7% do banco de imagens total que é composto por imagens de 52 usuários. Não foram obtidas imagens de todos os usuários pois as mesmas foram capturadas de alunos de uma faculdade e muitos já haviam terminado o curso, dificultando o acesso aos mesmos. No momento da captura das imagens, foram novamente levantados os dados de peso, pois a hipótese levantada é de que a quantidade de gordura nas mãos diferencia o padrão de

imagens geradas pelas veias, já que estão bem próximas à epiderme. Foram calculadas as taxas de variação de pesos e o Índice de Massa Corpórea (IMC) de cada pessoa para serem utilizados como parâmetros na comparação das imagens. Estes dados podem ser visualizados nas Tabelas 25 e 26.

Tabela 25 - Dados dos usuários avaliados

| Matrícula | Sexo | Altura (m) | Idade em 2014 | Peso (Kg) em 2014 | Peso (Kg) em 2015 | IMC em 2014 | IMC em 2015 |
|-----------|------|------------|---------------|-------------------|-------------------|-------------|-------------|
| 11214156 | M | 1,79 | 28 | 94 | 96 | 31,3 | 31,3 |
| 12216971 | M | 1,70 | 20 | 73 | 76 | 29,3 | 30,0 |
| 12216972 | M | 1,68 | 27 | 73 | 73 | 25,3 | 26,3 |
| 12216978 | M | 1,73 | 20 | 93 | 93 | 31,1 | 31,1 |
| 12216979 | M | 1,72 | 25 | 80 | 85 | 27,0 | 28,7 |
| 12216980 | M | 1,72 | 20 | 66 | 66 | 22,3 | 22,3 |
| 12216981 | M | 1,80 | 20 | 67 | 65 | 20,7 | 20,1 |
| 12216984 | M | 1,75 | 23 | 56 | 56 | 18,3 | 18,3 |
| 12216989 | F | 1,75 | 22 | 72 | 74 | 23,5 | 24,2 |
| 12217045 | M | 1,76 | 19 | 75 | 75 | 24,2 | 24,2 |
| 12217046 | M | 1,76 | 19 | 63 | 65 | 20,3 | 21,0 |
| 12217051 | M | 1,70 | 20 | 63 | 63 | 21,8 | 21,8 |
| 12217056 | M | 1,85 | 29 | 92 | 92 | 26,9 | 26,9 |
| 12217059 | M | 1,71 | 20 | 65 | 64 | 22,2 | 21,9 |
| 12217100 | M | 1,78 | 33 | 66 | 66 | 25,9 | 25,9 |
| 12217119 | M | 1,81 | 26 | 88 | 90 | 20,8 | 20,8 |
| 12217138 | M | 1,77 | 28 | 98 | 98 | 26,9 | 27,5 |

Fonte: Produção do próprio autor

Para as análises foram calculadas variações de imagens utilizando novamente os algoritmos SUAE e CFS. Como estes algoritmos são discriminadores de atributos entre imagens, foram criados bancos de dados de cada indivíduo a ser analisado contendo onze imagens, sendo 10 imagens do ano anterior nomeadas pela matrícula do usuário (todas as imagens tem o mesmo nome) e 1 imagem após um ano nomeada como teste, e o algoritmos então foram aplicados para se verificar quantos parâmetros entre estes conteúdos eram considerados iguais a ponto de poderem ser eliminados em processos de classificação, e quantos são os parâmetros diferentes entre os conjuntos. Na fase de classificação, os algoritmos foram utilizados para diminuir a quantidade de dados a serem classificados entre os 17 usuários, e os resultados foram satisfatórios, portanto, nesta etapa a ideia principal consiste em relacionar os parâmetros que são diferentes entre as dez imagens capturadas anteriormente com a imagem capturada após um ano. Após os testes, verifica-se que as variações são baixas, apresentadas na Tabela 26, pode-se verificar nos campos **CFS** e **SUAE** que os parâmetros obtidos são os mesmos, apesar da avaliação ser realizada por princípios matemáticos diferentes, os resultados se repetem,

provando assim que estes são os parâmetros que diferem as imagens durante o período de um ano. A menor variação foi de 4,81% e a maior variação foi de 6,45%. Nota-se que a maior variação em termos de atributos de imagem ocorreu no indivíduo com a maior variação do IMC (usuário que mais ganhou peso neste período avaliado).

Tabela 26 - Variações das imagens no período de um ano

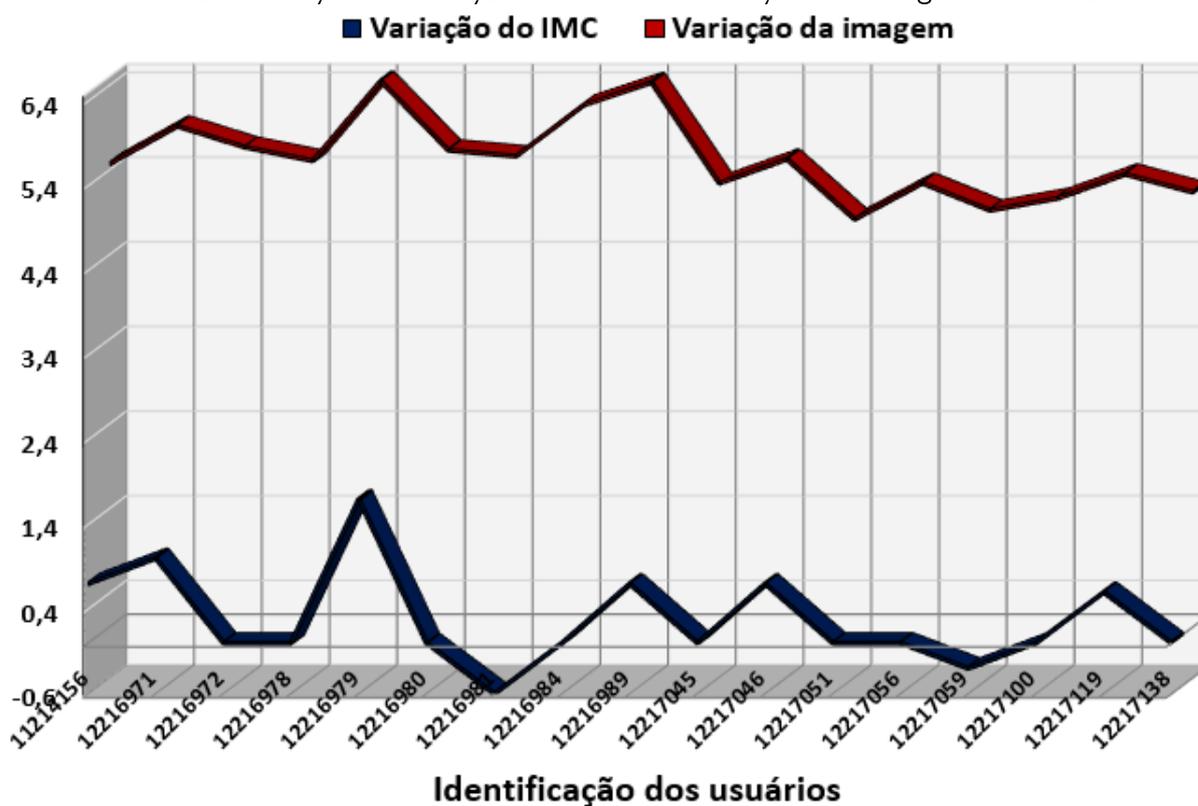
| Matrícula | Variação do IMC | IMC em 2014 | IMC em 2015 | CFS | SUAE | Variação da imagem |
|-----------|-----------------|-------------|-------------|-----|------|--------------------|
| 11214156 | 0,7 | 29,3 | 30,0 | 308 | 308 | 5,47% |
| 12216971 | 1,0 | 25,3 | 26,3 | 333 | 333 | 5,91% |
| 12216972 | 0,0 | 25,9 | 25,9 | 319 | 319 | 5,66% |
| 12216978 | 0,0 | 31,1 | 31,1 | 310 | 310 | 5,50% |
| 12216979 | 1,7 | 27,0 | 28,7 | 363 | 363 | 6,45% |
| 12216980 | 0,0 | 22,3 | 22,3 | 317 | 317 | 5,63% |
| 12216981 | -0,6 | 20,7 | 20,1 | 313 | 313 | 5,56% |
| 12216984 | 0,0 | 18,3 | 18,3 | 347 | 347 | 6,16% |
| 12216989 | 0,7 | 23,5 | 24,2 | 362 | 362 | 6,43% |
| 12217045 | 0,0 | 24,2 | 24,2 | 295 | 295 | 5,24% |
| 12217046 | 0,7 | 20,3 | 21,0 | 311 | 311 | 5,52% |
| 12217051 | 0,0 | 21,8 | 21,8 | 271 | 271 | 4,81% |
| 12217056 | 0,0 | 26,9 | 26,9 | 295 | 295 | 5,24% |
| 12217059 | -0,3 | 22,2 | 21,9 | 277 | 277 | 4,92% |
| 12217100 | 0,0 | 20,8 | 20,8 | 285 | 285 | 5,06% |
| 12217119 | 0,6 | 26,9 | 27,5 | 301 | 301 | 5,34% |
| 12217138 | 0,0 | 31,3 | 31,3 | 289 | 289 | 5,13% |

Fonte: Produção do próprio autor

Pode-se afirmar através da visualização do Gráfico 23 que representa os dados da Tabela 26, que há uma leve tendência de variação da imagem de acordo com a variação de peso. Estima-se com base nos dados da Tabela 26 que a imagem varia cerca de 1% a cada variação unitária do índice de massa corpórea do indivíduo. O que se pode notar é que as variações são muito baixas no período analisado.

As 17 imagens obtidas foram acrescentadas ao banco de imagens que contém originalmente 520 imagens, dessa forma apenas 17 usuários irão conter 11 imagens de cada, e os outros 35 usuários continuam contendo 10 imagens. A hipótese é de se classificar novamente os dados para avaliar se as imagens prejudicam a sensibilidade do método proposto. Após análise utilizando a mesma rede neural artificial, obteve-se como resultado os dados da Tabela 27. Pode-se verificar que a FRR foi igual a 0,110 e a FAR foi igual a 0,002, próximos dos valores de FRR igual a 0,058 e FAR igual a 0,002 obtidos anteriormente.

Gráfico 23 - Relação de variação do IMC com variação das imagens em um ano



Fonte: Produção do próprio autor

Tabela 27 - Resultados obtidos com acréscimo de 17 imagens

| Parâmetros <i>Curvelet</i> | Tempo | FRR | FAR | ROC area |
|----------------------------|-------|-------|-------|----------|
| 5 escalas, 8 ângulos | 30,45 | 0,110 | 0,002 | 0,997 |

Fonte: Produção do próprio autor

5.11 ANÁLISE DOS MÉTODOS DE SUAVIZAÇÃO DAS IMAGENS

Na fase de pré-processamento das imagens foram utilizados três diferentes algoritmos para suavização e melhoria do contraste. Como alguns autores de trabalhos comentados na revisão bibliográfica desta tese relataram que os métodos de suavização podem acabar gerando ruídos, prejudicando assim a identificação biométrica, foram realizados testes com todos os métodos utilizados através da classificação por redes neurais artificiais, pois este foi o método que gerou os melhores resultados neste trabalho. Para a realização deste teste, foram utilizadas características das imagens extraídas com a transformada de *Curvelet*, e os parâmetros utilizados foram de 5 escalas e 8 ângulos. A Tabela 28 apresenta os resultados obtidos. Nota-se que o método de suavização CLAHE escolhido foi o que realmente apresentou os melhores resultados de classificação.

Tabela 28 - Testes dos algoritmos de suavização de imagens

| | Sem equalização | | | EGH | | | MAIC | | | CLAHE | | |
|----------------------|-----------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| | FRR | FAR | ROC | FRR | FAR | ROC | FRR | FAR | ROC | FRR | FAR | ROC |
| <i>Naive Bayes</i> | 0,150 | 0,003 | 0,995 | 0,160 | 0,003 | 0,991 | 0,288 | 0,006 | 0,987 | 0,135 | 0,003 | 0,995 |
| K-NN | 0,150 | 0,003 | 0,928 | 0,150 | 0,003 | 0,924 | 0,298 | 0,006 | 0,848 | 0,140 | 0,003 | 0,924 |
| C4.5/J48 | 0,429 | 0,008 | 0,803 | 0,435 | 0,009 | 0,802 | 0,615 | 0,012 | 0,726 | 0,413 | 0,008 | 0,800 |
| <i>Random Forest</i> | 0,135 | 0,003 | 0,996 | 0,150 | 0,003 | 0,995 | 0,287 | 0,006 | 0,986 | 0,127 | 0,002 | 0,996 |
| RNA MLP | 0,077 | 0,001 | 1,000 | 0,115 | 0,002 | 0,998 | 0,308 | 0,005 | 0,992 | 0,038 | 0,001 | 0,999 |

Fonte: Produção do próprio autor

5.12 ANÁLISE COMPARATIVA COM RESULTADOS DE OUTROS AUTORES

Foram levantados os trabalhos comentados na revisão bibliográfica que apresentaram seus resultados de taxa FRR e FAR, pois estes são parâmetros comuns a trabalhos relacionados à biometria. A comparação dos resultados desta tese com diversos outros autores pode ser visualizada na Tabela 29. As técnicas utilizadas por cada autor foram explicadas na revisão bibliográfica do trabalho e os parâmetros utilizados na comparação (taxas FRR e FAR) são os mesmos apresentados por fabricantes de equipamentos comerciais como forma de afirmar que o sistema tem qualidade. Pode-se perceber que os resultados obtidos nesta tese são totalmente satisfatórios por se tratar de uma técnica original, superando os índices já conseguidos por outros autores.

Tabela 29 - Análise comparativa dos resultados de outros autores

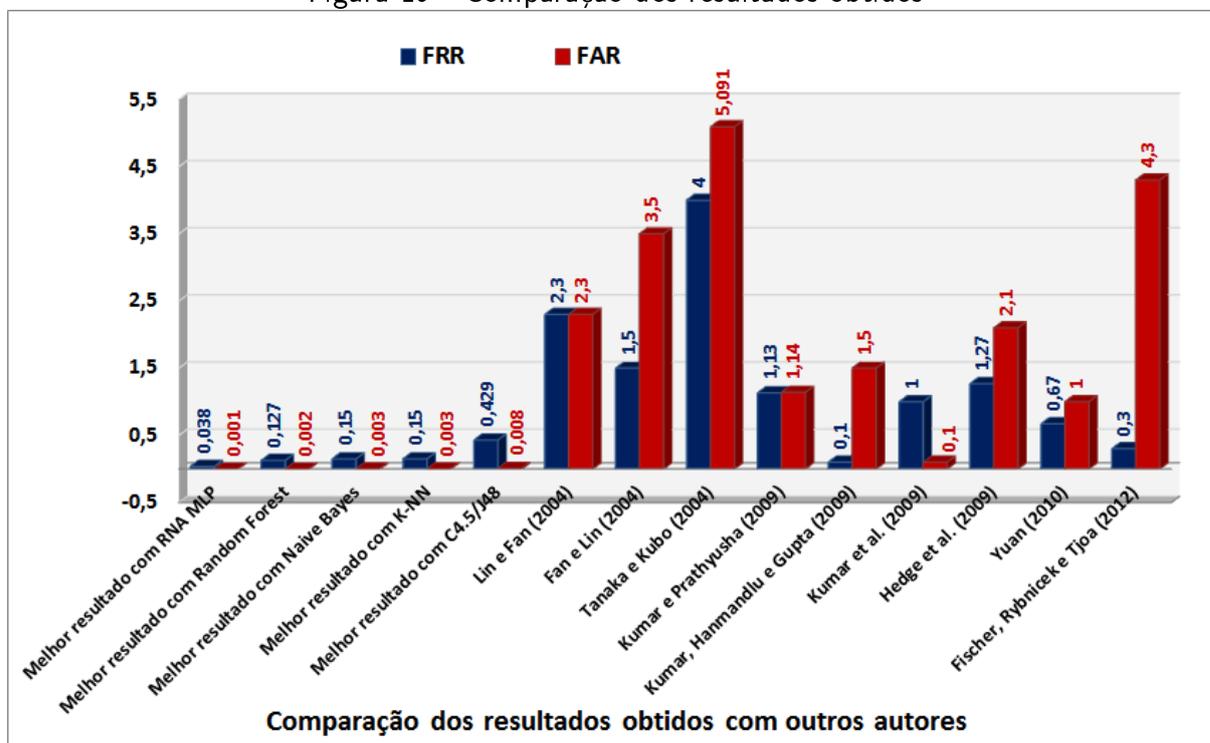
| <i>Autores</i> | FRR | FAR |
|--|------------|------------|
| Melhor resultado com RNA | 0,038 | 0,001 |
| Melhor resultado com <i>Random Forest</i> | 0,127 | 0,002 |
| Melhor resultado com <i>Naive Bayes</i> | 0,150 | 0,003 |
| Melhor resultado com K-NN | 0,150 | 0,003 |
| Melhor resultado com C4.5/J48 | 0,429 | 0,008 |
| (LIN; FAN, 2004) | 2,3 | 2,3 |
| (FAN; LIN, 2004) | 1,5 | 3,5 |
| (TANAKA; KUBO, 2004) | 4 | 5,091 |
| (KUMAR; PRATHYUSHA, 2009) | 1,14 | 1,14 |
| (KUMAR; HANMANDLU; GUPTA, 2009) | 0,1 | 1,5 |
| (KUMAR et al., 2009) | 1 | 0,1 |
| (HEGDE et al., 2009) | 1,27 | 2,1 |
| (YUAN, 2010) | 0,67 | 1 |
| (FISCHER; RYBNICEK; TJOA, 2012) | 0,3 | 4,3 |

Fonte: Produção do próprio autor

O Gráfico 19 abaixo apresenta os resultados da Tabela 29 em ordem cronológica e pode-se verificar que os resultados obtidos com o algoritmo proposto nesta tese são melhores que os já

apresentados por outros autores. Apesar da alta quantidade de trabalhos relatados na revisão bibliográfica, a grande maioria não apresenta seus resultados numéricos para que pudesse ser feita uma comparação, apenas comentam que obtiveram bons resultados.

Figura 19 - Comparação dos resultados obtidos



Fonte: Produção do próprio autor

5.13 ANÁLISE COMPARATIVA COM OUTRAS TÉCNICAS BIOMÉTRICAS

O algoritmo proposto nesta tese para identificação biométrica baseado no reconhecimento dos padrões de veias das mãos apresenta bons resultados quando comparado aos resultados de autores do mesmo tema. Para comparar se esta metodologia é válida, nesta seção foi realizada a comparação dos resultados obtidos com outras técnicas biométricas utilizadas comercialmente. Como os algoritmos destas técnicas são normalmente ocultados e os procedimentos para se chegar a tais resultados são diferentes dos utilizados nesta tese, a comparação é realizada utilizando os mesmos parâmetros comuns (métricas), que neste caso são as taxas FAR e FRR obtidas. A Tabela 30 apresenta os resultados deste trabalho e os resultados das técnicas biométricas de outros autores que utilizaram o reconhecimento do padrão de textura da íris, da impressão digital, de reconhecimento facial e da geometria das mãos. Não foram encontrados trabalhos sobre reconhecimento de assinatura, de retina, de DNA e de reconhecimento da voz com as taxas FAR e FRR para que pudesse ser realizada a comparação dos resultados. Pode-se verificar através dos resultados apresentados na Tabela 30 que os resul-

tados obtidos nesta tese são compatíveis com os resultados de outras técnicas biométricas, superando todos os trabalhos analisados nos critérios comparados.

Tabela 30 - Análise comparativa dos resultados de outros sistemas biométricos

| Padrão Biométrico | Autores | FRR | FAR |
|--|--|------------|------------|
| Padrão de veias das mãos | Melhor resultado com RNA | 0,038 | 0,001 |
| | Melhor resultado com <i>Random Forest</i> | 0,127 | 0,002 |
| | Melhor resultado com <i>Naive Bayes</i> | 0,150 | 0,003 |
| | Melhor resultado com K-NN | 0,150 | 0,003 |
| | Melhor resultado com C4.5/J48 | 0,429 | 0,008 |
| Reconhecimento de íris | (SINGH, 2014) | 2,5 | 1,67 |
| | (ABHISHEK; SUMA, 2014) | 8,6 | 6,5 |
| | (DARABKH; AL-ZUBI; JALUDI, 2014) | 0,322 | 0,039 |
| | (KUMAR; ASATI, 2014) | 0,12 | 3,93 |
| | (DARABKH et al., 2014) | 0,29 | 0,0411 |
| Reconhecimento de impressão digital | (BABATUNDE et al., 2014) | 0,49 | 0,59 |
| | (ABHISHEK; SUMA, 2014) | 6,7 | 8,0 |
| | (RAJAN; SUDHA; KUMAR, 2013) | 0,7571 | 0,0139 |
| | (ESAN; NGWIRA; OSUNMAKINDE, 2013) | 0,98 | 0,001 |
| | (LI; KOT, 2013) | 0,4 | 0,1 |
| Reconhecimento de face | (SPREEUWERS et al., 2014) | 4 | 0,1 |
| | (WIJAYA; UCHIMURA; KOUTAKI, 2011) | 0,08 | 0,1 |
| | (AZIZ et al., 2009) | 0,044 | 0,023 |
| | (CHONG; KIONG; LETCHUMANAN, 2009) | 0,068 | 0,088 |
| | (PARK et al., 2006) | 1,5 | 0,01 |
| Reconhecimento da geometria da mão | (WANG; CHEN; SHIH, 2009) | 5,8974 | 0,004 |
| | (SANCHES; ANTUNES; CORREIA, 2007) | 0,80 | 0,31 |
| | (MOHAMMED et al., 2009) | 5,7692 | 0,0035 |
| | (KUMAR et al., 2003) | 8,34 | 5,29 |
| | (ÖDEN et al., 2001) | 1 | 1 |

Fonte: Produção do próprio autor

6 CONCLUSÕES

Para a aquisição das imagens, o protótipo composto por câmera de alta definição modificada para que pudessem ser capturadas imagens somente no espectro de luz infravermelho próximo se mostrou eficaz mas foram necessárias modificações (instalação de pinos) pois os usuários tiveram dificuldades no correto posicionamento das mãos. O sistema de iluminação baseado em quatro conjuntos lineares compostos por 10 LEDs infravermelhos cada, sendo 5 LEDs com pico de emissão em $850nm$ e 5 LEDs com pico de emissão em $940nm$, dispostos de forma alternada na parte superior do protótipo incidindo luz a 45 graus em relação a este topo, diretamente sobre a mão posicionada sobre a base do protótipo em todas as direções, e ainda um conjunto de LEDs na mesma posição da câmera de forma a iluminar a parte dorsal superior da mão, gerou imagens uniformes, sem pontos de luz com alto ou baixo contraste. Por se tratar de um sistema original, os resultados obtidos foram satisfatórios, geraram imagens com bom contraste em relação à distinção entre a mão e as veias.

Foram adquiridas 520 imagens de 52 pessoas, sendo 49 homens e 3 mulheres, com média etária de 26 anos, dez imagens de cada pessoa, e as imagens são da parte dorsal da mão direita. Na fase de classificação nota-se que esta quantidade foi suficiente para a avaliação do sistema proposto, pelos resultados obtidos.

Após a captura das imagens, a normalização do banco de dados foi realizado extraíndo-se a região de interesse ROI como sendo um quadrado de 900×900 *pixels*, composto pela maior porção possível da parte dorsal da mão sem a composição de bordas ou de juntas dos dedos. Esta resolução foi escolhida para que a imagem tivesse uma boa qualidade, mas propõe-se como trabalho futuro a diminuição da resolução como forma de obter imagens menores, resultando assim em maior velocidade de processamento do sistema. A seguir, foi aplicado o método de equalização adaptativa local do histograma, pois este apresentou os melhores resultados quando comparado ao método de histograma global e de mapeamento e ajuste de intensidade de cinza, e este método tem por finalidade o melhoramento do contraste na fase de pré-processamento da imagem, além de se evitar que variações de iluminação provenientes do próprio ambiente ou de fontes externas no momento da aquisição de imagens possam interferir no processo de classificação.

Posteriormente, as imagens tiveram suas características extraídas pela transformada de *Curvelet* na função “*wrapping*” e as matrizes geradas foram concatenadas em uma matriz linha para formação de um vetor digital de características individuais das pessoas. Estes vetores foram gerados utilizando-se o algoritmo *Local Binary Pattern* (LBP). A transformada de *Curvelet* na função “*wrapping*” permite o ajuste de parâmetros e foram testadas as variações de escalas de 1 até 5, e variações de ângulo entre 8 ou 16. O parâmetro de escala igual a 5 e de

ângulo igual a 16 gerou os melhores resultados nas classificações dos dados. Na digitalização dos dados, foi aplicado o algoritmo LBP e os parâmetros utilizados foram $P=8$ e $R=2$, o que representa o uso de 8 *pixels* de vizinhança analisados em um raio de 2 *pixels*.

Os arquivos gerados pelo *software Matlab*[®] tem extensão do tipo *.mat*. Para a análise dos dados na plataforma WEKA, os arquivos foram convertidos para a extensão *.arr.f*. Para isto, todos os arquivos foram abertos no próprio *software Matlab*[®], copiados e colados no *software Excel*. A partir deste, o arquivo foi salvo com a extensão *.csv*, no entanto o arquivo é salvo com ponto e vírgula entre cada atributo e este formato não é reconhecido pela plataforma WEKA. Para se resolver este problema, o arquivo *.csv* foi aberto pelo bloco de notas do sistema operacional Windows[®] para se realizar a troca de ponto e vírgula por vírgula, e salvo novamente com a extensão *.csv*. Na plataforma WEKA, estes arquivos foram abertos e salvos com a extensão *.arr.f* para início dos testes.

As análises de identificação foram realizadas com o uso de cinco diferentes classificadores, a seguir: Classificador *Naive Bayes* baseado em predição probabilística, Classificador IBK baseado em aprendizagem por regressão linear, conhecido popularmente como técnica de “*lazy learning*”, dois algoritmos baseados em árvores de decisão sendo o primeiro C4.5 (na plataforma WEKA o mesmo recebe o nome de algoritmo J48) e o segundo algoritmo conhecido como *Random Forest*, e um classificador baseado em redes neurais artificiais *Multilayer perceptron*. Os classificadores foram testados utilizando o método de validação cruzada, e as informações foram separadas por 10 *folds* sendo que 10% dos dados foram utilizados para treino e 90% dos dados foram utilizados para teste. Os testes realizados em todos os bancos de dados construídos mostram que o algoritmo *Random Forest* apresenta os melhores resultados quando estes são analisados em sua totalidade, ou seja, 5632 atributos para cada imagem. A rede neural artificial foi aplicada mas o tempo de processamento para treinamento da rede superou 22 horas, tornando a técnica inviável para aplicação em sistemas comerciais.

Ainda foram utilizados dois algoritmos para seleção de características, sendo o primeiro SUAEE, baseado na correlação da função de avaliação heurística e o segundo CFS na seleção de atributos pelo conceito da entropia dos dados, como forma de aumentar a precisão dos classificadores. O primeiro algoritmo coloca os atributos em ordem de variância, e os dados a serem descartados foram removidos manualmente. O algoritmo CFS já faz a análise permitindo que o resultado seja salvo somente com os atributos que tem boa variância entre os usuários. Os testes realizados mostram que o algoritmo CFS é o mais eficiente para este uso, e os atributos foram reduzidos de forma a permitir a aplicação da rede neural artificial, indicando que este é o melhor algoritmo a ser usado na classificação dos dados.

Como foram capturadas 10 imagens de cada usuário, foram realizados testes com bancos de dados variando de uma até 10 imagens para cada usuário no intuito de verificar quantas

imagens (mínimo possível para tornar o sistema mais rápido) são necessárias para uma boa classificação. Os testes mostraram que a partir de cinco imagens analisadas por usuário, os resultados são bem próximos, e a partir desta quantidade pode-se considerar desnecessária a captura de mais imagens.

Levando-se em consideração todos os tempos envolvidos entre extração de região de interesse, equalização do histograma, extração das características por transformada de *Curvelet*, binarização das subimagens e concatenação das matrizes em vetores pelo uso do algoritmo LBP, e ainda aplicação dos algoritmos de seleção e classificação dos dados por Redes Neurais Artificiais MLP, o processo leva cerca de $2,37s$ para obtenção do melhor resultado (FRR igual a 0,038, FAR igual a 0,001 e ROC igual a 0,999). Para a análise efetuada com o algoritmo *Random Forest* que apresentou o segundo melhor resultado (FRR igual a 0,127, FAR igual a 0,002 e ROC igual a 0,996) este tempo total é de $31ms$. Levando-se em consideração os tempos de análise, recomenda-se o uso da Rede Neural Artificial MLP em instalações que necessitem de um alto grau de segurança, pois os resultados foram cerca de três vezes melhores quando comparados ao uso do algoritmo *Random Forest*, no entanto, se a instalação tiver baixo grau de segurança como por exemplo o controle de acesso de usuários em uma academia, este último algoritmo também pode ser utilizado pois sua velocidade de identificação é 76 vezes mais rápido que o algoritmo anterior.

Foram analisadas 17 imagens capturadas um ano após a construção do banco de imagens original e realizadas análises de comparação entre estas como forma de verificar se existe permanência dos dados. A hipótese levantada é de que a variação de peso dos usuários pudesse prejudicar a qualidade do classificador, e os resultados de comparação com o uso dos algoritmos SUAE e CFS mostraram que a variação nas imagens no período de um ano não ultrapassa 7%, não afetando assim a sensibilidade do sistema adotado, e que existe uma tendência de variação nas imagens de acordo com a variação de massa corpórea de cada indivíduo avaliado.

Todos os resultados apresentados foram baseados nas métricas utilizadas por outros autores como a taxa de falsos positivos FAR e taxa de falsos negativos FRR para que pudessem ser realizadas comparações com resultados já obtidos em métodos similares, e as taxas apresentadas nesta tese são melhores do que as já apresentadas em outros trabalhos, e em termos de área ROC como parâmetro de qualidade do classificador utilizado, o valor igual a 0,999 conseguido pelo uso da rede neural artificial representa o melhor resultado possível (100% de precisão, e 0% de falsos negativos e positivos apresentaria ROC igual a 1), mostrando que o sistema tem alta sensibilidade, mesmo com o uso de somente cinco imagens por usuário.

APÊNDICE A – Trabalho publicado

2014 First International Conference on Systems Informatics, Modelling and Simulation

A Low Cost System for Dorsal Hand Vein Patterns Recognition Using Curvelets

Ricardo Janes, Augusto Ferreira Brandão Júnior
Dep. of Engineering, Energy and Electrical Automation
 Universidade de São Paulo - POLI/USP
 São Paulo - Brazil
 ricardo.janes@usp.br, brandao@pea.usp.br
 http://www.pea.usp.br

Abstract—Biometric identification systems based on the recognition of the hands vein pattern are better than the other systems such as fingerprint identification, face, iris, retina, and hand geometry features for using not visible images to the eye, having high acceptability to users and do not require physical contact. This paper presents an identification system based on the dorsal hand vein pattern recognition, using a low cost camera to capture images with near-infrared (NIR), curvelet transforms for feature detection of images and random forest classification method. The proposed method was tested on a database of 1240 images captured by the authors and the system results presented classification about recognition with low Equal Error Rate (EER)

Keywords—Vein recognition; Vein pattern; Biometric identification; Hand Vein; Curvelets transform.

I. INTRODUCTION

Advanced security systems increasingly require strict control of physical and logical access of its users. The identification with the use of magnetic cards, cards with barcodes, or cards via radio communication technology using PIN (Personal Identification Number) are used in security systems but do not guarantee that the user is the owner of this card in use. One way to ensure identification is the use of biometrics, which is defined as the measurement of human characteristics. Biometrics can be defined as the physiological or behavioral characteristics that identify a person.

The main physiological biometric techniques are reading the patterns of fingerprint, facial recognition, pattern recognition of retinal veins, hand geometry and iris texture analysis. Behavioral biometrics include standard static and dynamic signature, voice pattern and keystroke dynamics and all these characteristics, both biological and behavioral, should have the following properties in order to be used as biometrics: universality (everyone in the world should have the feature), permanency (this feature should remain lifelong), collectability (should be a feature that can be read by some process), acceptability (people must accept to undergo the process of reading the feature), avoidance (the system should interfere as little as possible) and uniqueness

(feature must be unique for each person) [1].

All these methods have been intensively studied and the results showed several deficiencies regarding guarantees for identifying people. Multimodal methods were created in an attempt to improve results and can actually reach them [2], [3], but in many cases end up adding the failures of individual techniques such as poor quality of the captured images, noises from the environment where the installed equipment, noise caused by the biometric sensor itself used and orientation of the face or hand in capturing the image, increasing the cost of implementation and increasing the processing time. Biometric techniques based on face, iris or fingers were intensively studied and developed [4]–[6].

Biometric systems based on hand vein pattern is relatively recent compared to the systems mentioned above, since their study by MacGregor and Weldford in 1991 [7], [8], and began to become popular from the 2000s when the Fujitsu Company presented their research results and showed that only six people have similar patterns of veins in a population of one million people, thus proving that this is a feature that can be used [9].

Two different methods of identification with different light sources are used [10], NIR (Near Infrared Light) and FIR (Far Infrared Light). For capturing images, NIR works on the principle that the hemoglobin in the blood absorbs infrared light of wavelength near to the spectrum of visible light, whereas the bones, muscles and nerves of the hands suffer no part of this light stimulation. Based on this principle, using a special camera able to capture NIR images only of the light spectrum between 600 nm and 1100 nm is possible to capture images of the hands, whether the palm, the dorsal part of the hand or wrist with a high contrast between the structures and veins, the veins appear dark in this case by having absorbed NIR light.

For systems that use FIR, the basic principle of operation is based on the fact that human veins generally has a higher temperature compared to other structures of the hand, and using a thermal imaging camera in the visible light spectrum is possible to have the identification of these veins, showing the brighter in the acquired image [11]. This

system has shortcomings when used in open areas, because all the heat radiated into the environment can cause noise in the captured images.

The purpose of our work is to present a biometric identification system based on image capture based on NIR with low cost, using a conventional camera model ST-CAM001 for the Cyber Comp modified to be able to perform the capture of images. Several tests were performed before image acquisition of setting a database because it comes from a camera adapted to capture infrared light, the quality of the captured images could provide low quality directly affects final results of the research [12], [13].

To this project, proposals were heading in different lighting, different levels of illumination and arrangements that would provide the user with a better hand positioning equipment in order to ensure a good quality image.

II. PROPOSED SYSTEM

In our proposal, we use the following steps to correct identification of the person:

- Image acquisition with low cost camera;
- Image Enhancement (noise reduction);
- Region of interest extraction (ROI);
- Pattern of veins extraction;
- Training System / Matching.

A. Recognition of the pattern

In Fig.1, is presented the registration flowchart of the new users and the method of identification. The project is based on a low-cost device, so the camera is not chosen a specific NIR camera for applications where we want to capture only the light from an image in the infrared spectrum. For this, we selected a conventional camera model ST-CAM001 for the Cyber Comp with 470k resolution pixel, at a cost of approximately \$ 10. Research on specific NIR cameras in Brazil showed us costs of approximately \$ 500 to \$ 1000, depending on model. Since this is a conventional camera, its use is capturing images in the visible light spectrum and to eliminate any kind of light, for example infrared and ultraviolet.

Our first step was to remove the infrared filter which was located on the camera lens just above the image pickup sensor for the camera to allow the passage of this type of light, and adapt a high pass filter, blocking the visible light to the eye thus allowing only the passage of infrared light.

In Fig.2 (a) is presented the modified camera and in the center of Fig.2 (b) is presented the CMOS sensor. The Fig.3 (a) show inside the housing of the camera lens where the infrared filter was installed (at center) and Fig.3 (b) show

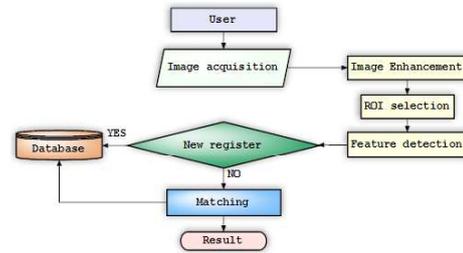


Figure 1. Registration flowchart of new users

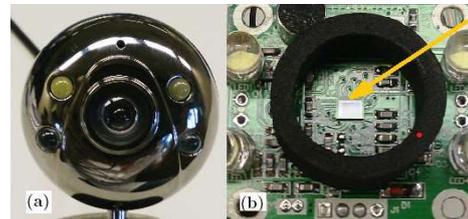


Figure 2. Modified camera (a) and CMOS sensor (b)

the removed filter from the camera in order to allow the passage of this type of light.

In order to capture the images, we created a prototype (Fig.4) for housing the camera and facilitate the understanding of the user for the correct positioning of the hands. We create a base for supporting the hands without the need to touch, simply by appropriately bringing the hand to this base. Just below the base we did an arrangement of LEDs (Light emitting diode) with light radiating in the infrared spectrum IR and an electronic circuit to control the emitted light by the LEDs.

First of all, we use two different types, the first radiating peak at 850 nm and the second radiating peak at 940 nm in order to verify what device would generate an image with

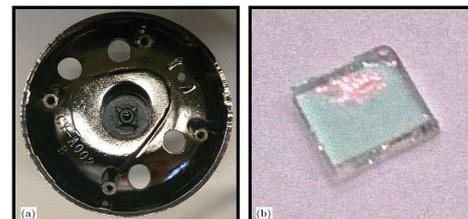


Figure 3. Lens camera (a) and removed infrared filter(b)

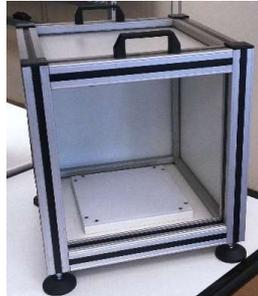


Figure 4. Prototype design

more contrast and definition. After these tests, we chose the 850 nm model.

B. Image Acquisition

We installed a plastic base on LEDs and realized that the images were distinctly lighter at the regions of the LEDs. To prevent this problem, a white filter was installed with the intention of spreading the light emitted toward the hand, and the results were satisfactory. The LEDs were arranged on a plate in the palm and dorsal of the hand region, no matter the region of the fingers as one of the stages of the project is to define a region of interest (ROI) and at this stage the fingers would be eliminated. In Fig.5 (a) is presented the open base with LEDs inside and the Fig.5 (b) show the closed base with the diffusion white filter and a hand correctly positioned.

Our equipment is implemented with a base for positioning of the hand. As we make the acquisition of images, we found that most users would not know how to put your hand on the device, properly position the hand, and should support the hand at the base of the equipment. To minimize this problem, we installed a board with a photo next to the device, with an image of a hand properly positioned in the equipment to facilitate the use.

Compounds also installed four sets of ten LEDs at the top of our prototype, positioning the light with direct hand-incidence as can be seen in the Fig.6.

The Fig.7 show the position of the LED array installed on top of the device, focusing light in the forward direction by hand. With this arrange we have indirect light through the user's hand and direct light applied over the hand. Independent electronic circuits were constructed to control the brightness adjust. For the entire process of capturing an image, fifty infrared LEDs were used: ten LEDs at the base of the device used to light through the hand, and forty LEDs on the top cover, forming four sets installed at right, left, front and bottom of the device. In Fig.8 is shown a set of captured images during the process of adjusting brightness

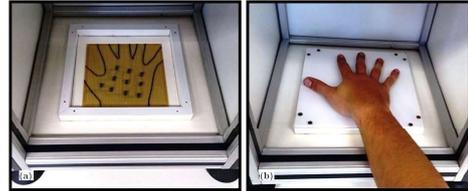


Figure 5. Region of image capture

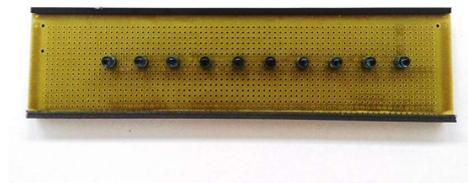


Figure 6. Set of LEDs

of each LED array, looking for the best performance of the device.

C. Image Enhancement

The first step in our project is to convert the image to gray-scale. Although we installed the filter to prevent light in the visible spectrum to arrive at the camera sensor may still be levels that will be removed in this step. The results were very subtle and can be seen at the Fig.9 (b), and can be compared with the original image presented in Fig.9 (a), almost that showing the captured image has no component of light in the visible spectrum. The next step is to enhance the contrast of the captured image equalizing the histogram to reduce the inhomogeneity of illumination. The results are

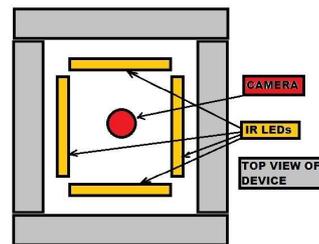


Figure 7. Top view of device

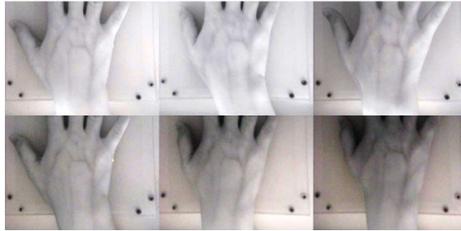


Figure 8. Set of captured images

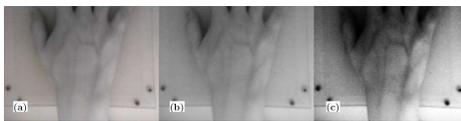


Figure 9. Image enhancement

shown at Fig.9 (c). All procedures were Performed using Matlab[®] software.The results of histogram equalization are shown in Fig.10.

D. Region of interest (ROI) extraction

The region of interest was defined experimentally by media, extracting the largest possible area of the dorsal side of the hand, and it was extracted by software in fixed positions, width and height constant in the x and y axis. The data to be extracted will be obtained from this region. The Fig.11 (a) show the selected area to be extracted as a ROI, and the Fig.11 (b) show the ROI extracted.The Fig.12 show the input image in MATLAB[®] software (processing). The Fig.13 show only the display with the results of the first scale and the first angle. it's important to comment that in our study were determined four scale parameters and eight angular parameters, so this figure represents only one of the items discussed. The Fig.14 show the coefficients extracted from one of cells. Not all screens with coefficients generated in the extraction of image characteristics were

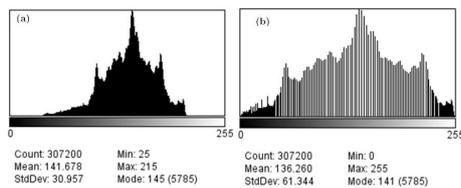


Figure 10. Histogram equalization

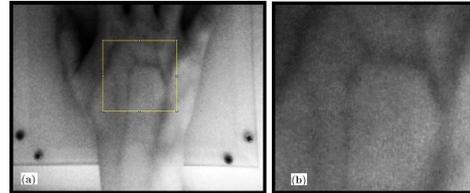


Figure 11. Region of interest - ROI

presented.

E. Feature detection

The curvelet transform is shown as the most appropriate feature extraction anisotropic biometric images with angles, lines and points [13]–[15]. The 2D Fast Fourier Transform (FFT) must be applied to the image before the implementation of the curvelet transform, because the 2D frequency plane is divided into wedges that are nothing more than the results of partitioning the Fourier plane in radial division and angular division. Concentric circles are responsible for decomposing the image into multiple scales defined by j and angular divisions defined by l .

In the spatial domain each wedge corresponds to a given curvelet at scale and angle. The values of the curvelet coefficients are determined in relation to alignment with the actual image, the more accurate the alignment of a curvelet with a curved image, the higher its value coefficient [16]. The curvelet transform of a function f is expressed as shown in Eq.1.

$$c(j, l, k) = \langle f, \varphi_{j,l,k} \rangle \quad (1)$$

Where $\varphi_{(j,l,k)}$ is the curvelet, $j, l \in k$ are the scale parameters, directions and position, respectively [17]. In this work, the discrete curvelet transform was applied to four scale parameters and the angular parameter having value eight.

F. Matching

To verify the performance of data taken after using the curvelet transform descriptors and characteristics, we used the Random Forest classifier, implemented in the WEKA platform (Waikato Environment for Knowledge Analysis).

The Random Forest classifier was selected for this task by presenting good results in image classification [18]. The Random Forest classifier is a decision tree where each grows using some sort of randomization tree.

This algorithm has a high ability to process large amounts

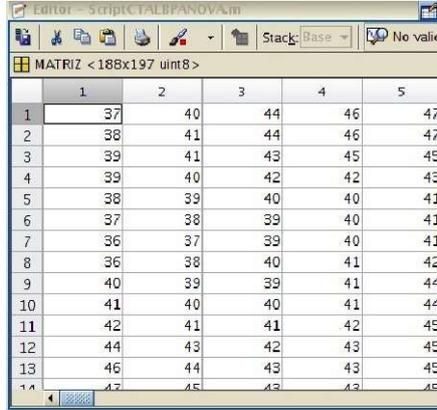


Figure 12. Region of interest ROI matrix on Matlab® software

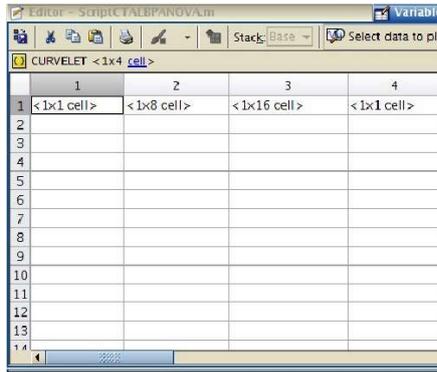


Figure 13. Results of the first scale parameter and first angle parameter

of data with high speed in the decision based on where each will give a vote trees workout step indicates that the decision on which class belongs the data analyzed, and the object will be classified according with the largest number of these decisions trees. In this step, the method of rotation (n- fold cross validation) was applied to the value n=10. This method uses 90% of the training data and the remaining 10% of the data for test step.

III. RESULTS

The Tab. I show the comparison between our proposed method and the method proposed and commented by [19], [20]. It's possible to verify in the table that our method

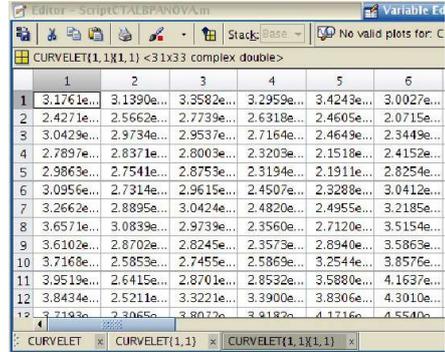


Figure 14. Extracted coefficients from the ROI

TABLE I
THE EER COMPARISON WITH OTHER METHODS

| | EER |
|-------------------------------------|--------|
| Our method | 3.15 % |
| Curvature | 3.86 % |
| Line-shaped matching | 4.25% |
| Line tracking | 6.14 % |
| Structural minutiae matching | 9.50 % |

outperforms the other four methods in terms of EER.

We acquired five images of each user, with a total of 248 users, generating a database of 1240 images. The process described in this paper was applied to the entire database, and the results after tests showed the index EER (Equal Error Rate) of our work was estimated at 3.15% using the ROC (Receiver Operating Characteristics) curve, which was low compared with the literature about correct identification of system users, using a low cost system.

When we made the capture of images, we store user data such as age, weight, gender, ethnicity and use of hands (right or left hand) to perform analysis on a future project about the existence of some relationship with these values and false rejection and false acceptances generated in order to enhance the system.

IV. CONCLUSIONS

In this paper, we present a method of biometric identification using the hands vein pattern. No works that used exactly the same procedures in the analysis of images from the dorsal part of the hand were found.

The curvelet transform coefficient generates many data and to improve the speed of the system, it is proposed

to use tools that aims to reduce or vectoring the data before carrying out classification, by techniques such as LBP (Local Binary Patterns), PCA (Principal Components Analysis) or technical ANOVA (Analysis of Variance) in future work. The index EER (Equal Error Rate) of our work was estimated at 3.15%.

REFERENCES

- [1] A. K. Jain, R. Bolle, and S. Pakanti. *Biometrics Personal Identification in Networked Society*. Boston. Kluwer Academic Publishers Norwell, MA, USA. 1998.
- [2] H. Korves, L. Nael, B. Ulery, and D. Masi. Multi-biometric Fusion: From Research to Operations, *Sigma*, Mitretek Systems, pp. 39-48. Summer 2005.
- [3] Shahin, M.K., Badawi, A.M., Rasmy, M.E.. A Multimodal Hand Vein, Hand Geometry, and Fingerprint Prototype Design for High Security Biometrics. *Proc.IEEE Biomedical Engineering Conference (CIBEC08)*, Dec. 2008, pp 1-6, doi: 10.1109/CIBEC.2008.4786038.
- [4] J. G. Daugman, *Biometric Personal Identification System Based on Iris Analysis*, U.S. Patent 5, 291, 560, Mar. 1, 1994. U.S. Pat.Off., Washington, DC.
- [5] Y. Tong, F. W. Wheeler, X. Liu. Improving biometric identification through quality-based and fingerprint biometric fusion.. *Proc. IEEE Computer Vision and Pattern Recognition Workshops (CVPRW)*, Jun 2010, pp. 56-60, doi: 10.1109/CVPRW.2010.5543233.
- [6] S. Mau, F. Dagostar, I. Cullinan, A. Bigdelli, B.C. Lovell. A Face Biometric Benchmarking Review and Characterisation.. *Computer Vision Workshops (ICCV Workshops)*, Nov. 2011, pp. 2120-2127, doi:10.1109/ICCVW.2011.6130510.
- [7] P. MacGregor, R. Welford, *Veincheck: Imaging for Security and Personnel Identification*, *Advanced Imaging*, vol. 6, no.7, 1991, pp. 52-56.
- [8] P. MacGregor, R. Welford, *Veincheck Lends a Hand for High Security*, *Sensor Review*, vol. 12 .Jss. 3, 1992, pp. 19-23., doi: 10.1108/eb007880.
- [9] Fujitsu-Laboratories-Ltd. Fujitsu Laboratories Develops Technology for Worlds First Contactless Palm Vein Pattern Biometric Authentication System, March 31, 2003, <http://www.fujitsu.com/global/news/pr/archives/month/2003/20030331-05.html>
- [10] W. Lingyu, G. Leedham. Near and Far- Infrared Imaging for Vein Pattern Biometrics. *Proc. IEEE Video and Signal Based Surveillance (AVSS 06)*, Nov. 2006, pp. 52. doi: 10.1109/AVSS.2006.80.
- [11] J. Mckyska, X. Font-Aragones, M. Faundez-Zanui, R. Hernandez-Mingorance, A. Morales, M.A. Ferrer-Ballester. Thermal Hand Image Segmentation for Biometric Recognition. *Proc. IEEE Security Technology (ICCST)*, Oct. 2011. pp. 1-5. doi: 10.1109/CCST.2011.6095877.
- [12] M. Mansoor, S.N. Sravani, S.Z. Naqvi, I. Badshah, M. Saleem.Real-time low cost infrared vein imaging system. *Proc. IEEE International Conference on Signal Processing, Image Processing and Pattern Recognition (ICSIPR)*, Feb. 2013. pp. 117-121. doi: 10.1109/IC-SIPR.2013.6497970.
- [13] J. Starck, F. Murtagh, E. Candes, and D. Donoho. Gray and Color Image Contrast Enhancement by the Curvelet Transform. *IEEE Trans. Image Processing*, 2003, vol. 12, no. 6, pp. 706-717. doi: 10.1109/TIP.2003.813140.
- [14] J. Starck, E. Candes, and D. Donoho. The Curvelet Transform for Image Denoising. *IEEE Trans. Image Processing*, 2002, vol. 11, no. 6, pp. 670-684. doi: 10.1109/TIP.2002.1014998.
- [15] Z. Zhang, S. Ma, X. Han. Multiscale Feature Extraction of Finger-Vein Patterns Based on Curvelets. *Proc. IEEE Pattern Recognition, 2006 (ICPR 2006)*, Aug., 2006, pp. 145-149. doi: 10.1109/ICPR.2006.848.
- [16] E. J. Candes, D. L. Donoho. *Curvelets - Surprisingly Effective Non-adaptive Representation for Objects with Edges*, In Vanderbilt University Press,Nashville,TN,2000.
- [17] X. Wu, J. Zhao. Curvelet Feature Extraction for Face Recognition and Facial Expression Recognition. *Proc. IEEE Sixth International Conference on Natural Computation*, Aug. 2010. pp. 1212-1216. doi: 10.1109/ICNC.2010.5583642.
- [18] J. Han, Y. Liu, X. Sun. A scalable random forest algorithm based on MapReduce. *Proc. IEEE International Conference on Software Engineering and Service Science (ICSESS2013)*, May. 2013, pp. 849-852. doi: 10.1109/ICSESS.2013.6615438.
- [19] N. Miura, A. Nagasaka, T. Miyatake. Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification. *Proc. Machine Vision and Applications - Springer-Verlag*, Jul. 2004. pp. 194-203. doi: 10.1007/s00138-004-0149-2.
- [20] N. Miura, A. Nagasaka, T. Miyatake. Extraction of finger-vein patterns using maximum curvature points in image profiles. *Proc. IEICE - Transactions on Information and Systems*, Aug. 2007, pp. 1185-1194. vol. E90-D Issue 8. doi: 10.1093/ietisy/e90-d.8.1185.

REFERÊNCIAS

- ABHISHEK; SUMA, 2014 ABHISHEK, A.; SUMA, H. Comparison of biosignal electrocardiography (ecg), fingerprint and iris as biometrics authentication tool. **Biomedical Engineering and Sciences (IECBES), 2014 IEEE Conference on.** p. 303–308, Dec 2014. DOI: 10.1109/IECBES.2014.7047508.
- ACHERMANN; BUNKE, 1996 ACHERMANN, B.; BUNKE, H. Combination of face classifiers for person identification. **Pattern Recognition, 1996., Proceedings of the 13th International Conference on.** v. 3, p. 416–420 vol.3, Aug 1996. DOI: 10.1109/ICPR.1996.546981.
- AENDENROOMER; HUANG, 2007 AENDENROOMER, A. J. R.; HUANG, S. Dynamic flash-memory allocation for smartcards: how to cope with limited space (in a short life). **Industrial Informatics, 2007 5th IEEE International Conference on.** v. 2, p. 835–840, June 2007. DOI: 10.1109/INDIN.2007.4384882.
- AHONEN et al., 2004 AHONEN, T. et al. Face recognition based on the appearance of local regions. **Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on.** v. 3, p. 153–156 Vol.3, Aug 2004. DOI: 10.1109/ICPR.2004.1334491.
- ALEJO; RODRIGUEZ; KEMPER, 2015 ALEJO, W.; RODRIGUEZ, D.; KEMPER, G. A biometric method based on the matching of dilated and skeletonized ir images of the veins map of the dorsum of the hand. **Latin America Transactions, IEEE (Revista IEEE America Latina)**, v. 13, n. 5, p. 1438–1445, May 2015. DOI: 10.1109/TLA.2015.7112000.
- ALSHU'EILI; GUPTA; MUKHOPADHYAY, 2011 ALSHU'EILI, H.; GUPTA, G.; MUKHOPADHYAY, S. Voice recognition based wireless home automation system. **Mechatronics (ICOM), 2011 4th International Conference On.** p. 1–6, May 2011. DOI: 10.1109/ICOM.2011.5937116.
- ALTMAN, 1992 ALTMAN, N. S. An introduction to kernel and nearest-neighbor nonparametric regression. **The American Statistician**, v. 46, n. 3, p. 175–185, 1992. DOI: 10.1080/00031305.1992.10475879.
- ALZUBI; ISLAM; ABBOD, 2011 ALZUBI, S.; ISLAM, N.; ABBOD, M. Multiresolution analysis using wavelet, ridgelet, and curvelet transforms for medical image segmentation. **Journal of Biomedical Imaging**, New York, NY, United States, Hindawi Publishing Corp., v. 2011, p. 4:1–4:18, jan. 2011. 18 p. DOI: 10.1155/2011/136034.
- AZIZ et al., 2009 AZIZ, K. et al. Face detection using radial basis function neural networks with variance spread value. **Soft Computing and Pattern Recognition, 2009. SOCPAR '09. International Conference of.** p. 399–403, Dec 2009. DOI: 10.1109/SoCPaR.2009.84.

BABATUNDE et al., 2014 BABATUNDE, I. et al. Experimental study of thumbprint-based authentication framework for atm machines. **Science and Information Conference (SAI)**, 2014. p. 505–514, Aug 2014. DOI: 10.1109/SAI.2014.6918235.

BALTI; SAYADI; FNAIECH, 2012 BALTI, A.; SAYADI, M.; FNAIECH, F. Improved features for fingerprint identification. **Electrotechnical Conference (MELECON), 2012 16th IEEE Mediterranean**. p. 878–883, March 2012. DOI: 10.1109/MELCON.2012.6196569.

BEBIS; DEACONU; GEORGIPOULOS, 1999 BEBIS, G.; DEACONU, T.; GEORGIPOULOS, M. Fingerprint identification using delaunay triangulation. **Information Intelligence and Systems, 1999. Proceedings. 1999 International Conference on**. p. 452–459, 1999. DOI: 10.1109/ICIIS.1999.810315.

BEYGELZIMER; KAKADE; LANGFORD, 2006 BEYGELZIMER, A.; KAKADE, S.; LANGFORD, J. Cover trees for nearest neighbor. **Proceedings of the 23rd International Conference on Machine Learning**. p. 97–104, 2006. DOI: 10.1145/1143844.1143857.

BIN et al., 2009 BIN, Q. et al. The anti-spoofing study of vein identification system. **Computational Intelligence and Security, 2009. CIS '09. International Conference on**. v. 2, p. 357–360, Dec 2009. DOI: 10.1109/CIS.2009.144.

BÔ, 1995 BÔ, J. R. M. e. **Automação Residencial - Conceitos e Aplicações**. 2ª edição. ed. [S.l.]: Educere, 1995. 200 p.

BOLZANI, 2004 BOLZANI, C. A. M. **Residências Inteligentes: Domótica, Redes Domésticas e Automação Residencial**. 1ª edição. ed. [S.l.]: Livraria da Física, 2004. 332 p.

BOSPHORUS, 2010 BOSPHORUS Hand Database. Disponível em : <BOSPHORUS Hand Database>. Acesso em: 26 jun. 2014.

BREIMAN, 2001 BREIMAN, L. Random forests. **Machine Learning**, Kluwer Academic Publishers, v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324.

BROMME, 2003 BROMME, A. A classification of biometric signatures. **Multimedia and Expo, 2003. ICME '03. Proceedings. 2003 International Conference on**. v. 3, p. III–17–20 vol.3, July 2003. DOI: 10.1109/ICME.2003.1221237.

BUILDINGS, 2014 Buildings - Citicorp Center. Disponível em : <<http://www.buildings.com.br/edificio/1806-citicorp-center>>. Acesso em: 13 ago. 2014.

CANDÈS, 1999 CANDÈS, D. D. Curvelets: a surprisingly effective nonadaptive representation of objects with edges. **Curve and Surface Fitting: Saint-Malo**, Nashville, Vanderbilt University Press, Jan 1999.

CAPPELLI et al., 2006 CAPPELLI, R. et al. Performance evaluation of fingerprint verification systems. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 28, n. 1, p. 3–18, Jan 2006. DOI: 10.1109/TPAMI.2006.20.

CARDOSO; AO, 2008 CARDOSO, R.; AO, A. Artificial neural network application to a building hybrid illumination system. **Industrial Electronics, 2008. ISIE 2008. IEEE International Symposium on**. p. 866–871, June 2008. DOI: 10.1109/ISIE.2008.4677011.

CARDOSO, 2008 CARDOSO, R. R. **Análise do desempenho energético de sistemas baseados em iluminação híbrida integrada na automação predial em edifícios comerciais utilizando a neurocomputação**. 2008. v. 1. Tese (Tese de Doutorado) — Universidade de Sao Paulo, Programa de Pós Graduação em Engenharia Eletrica - POLI, 2008.

CARDOSO; BRANDÃO JR, 2007 CARDOSO, R. R.; BRANDÃO JR, A. F. Aplicação de fso - free space optics na automação predial. **RTI - Redes, Telecon e Informática**, São Paulo, Aranda, v. 7, n. 81, p. 72–81, jun. 2007. 10 p.

CASIA, 2010 CASIA Palmprint Image Database. Disponível em : <<http://www.biometrics.idealtest.org/dbDetailForUser.do?id=5>>. Acesso em: 19 jun. 2014.

CHONG; KIONG; LETCHUMANAN, 2009 CHONG, L. G.; KIONG, L. C.; LETCHUMANAN, C. Two-factor face authentication: topographic independent component analysis (tica) and multispace random projection (mrp). **Soft Computing and Pattern Recognition, 2009. SOCPAR '09. International Conference of**. p. 756–761, Dec 2009. DOI: 10.1109/SoC-PaR.2009.153.

CRISAN; TARNOVAN; CRISAN, 2007 CRISAN, S.; TARNOVAN, I.; CRISAN, T. A low cost vein detection system using near infrared radiation. **Sensors Applications Symposium, 2007. SAS '07. IEEE**. p. 1–6, Feb 2007. DOI: 10.1109/SAS.2007.374359.

CROSS; SMITH, 1995 CROSS, J.; SMITH, C. Thermographic imaging of the subcutaneous vascular network of the back of the hand for biometric identification. **Security Technology, 1995. Proceedings. Institute of Electrical and Electronics Engineers 29th Annual 1995 International Carnahan Conference on**. p. 20–35, Oct 1995. DOI: 10.1109/CCST.1995.524729.

CUI; XUE, 2009 CUI, B.; XUE, T. Design and realization of an intelligent access control system based on voice recognition. **Computing, Communication, Control, and Management, 2009. CCCM 2009. ISECS International Colloquium on**. v. 1, p. 229–232, Aug 2009. DOI: 10.1109/CCCM.2009.5270462.

CURVELET, 2007 Curvelet Transform Software. Disponível em: <<http://www.curvelet.org>>. Acesso em: 05 abr. 2014.

DARABKH; AL-ZUBI; JALUDI, 2014 DARABKH, K.; AL-ZUBI, R.; JALUDI, M. New recognition methods for human iris patterns. **Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2014 37th International Convention on**. p. 1187–1191, May 2014. DOI: 10.1109/MIPRO.2014.6859748.

DARABKH et al., 2014 DARABKH, K. et al. An efficient method for feature extraction of human iris patterns. **Multi-Conference on Systems, Signals Devices (SSD), 2014 11th International**. p. 1–5, Feb 2014. DOI: 10.1109/SSD.2014.6808803.

DAUGMAN, 2001 DAUGMAN, J. High confidence recognition of persons by iris patterns. **Security Technology, 2001 IEEE 35th International Carnahan Conference on**. p. 254–263, Oct 2001. DOI: 10.1109/.2001.962841.

DAUGMAN, 2002 DAUGMAN, J. How iris recognition works. **Image Processing. 2002. Proceedings. 2002 International Conference on**. v. 1, p. 1–33–1–36 vol.1, 2002. DOI: 10.1109/ICIP.2002.1037952.

DAUGMAN, 2007 DAUGMAN, J. New methods in iris recognition. **Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on**, v. 37, n. 5, p. 1167–1175, Oct 2007. DOI: 10.1109/TSMCB.2007.903540.

DAVIS; GOADRICH, 2006 DAVIS, J.; GOADRICH, M. The relationship between precision-recall and roc curves. **Proceedings of the 23rd International Conference on Machine Learning**. p. 233–240, 2006. DOI: 10.1145/1143844.1143874.

DETTORI; SEMLER, 2007 DETTORI, L.; SEMLER, L. A comparison of wavelet, ridgelet, and curvelet-based texture classification algorithms in computed tomography. **Computers in Biology and Medicine**, v. 37, n. 4, p. 486 – 498, 2007. DOI: <http://dx.doi.org/10.1016/j.compbiomed.2006.08.002>. Wavelet-based Algorithms for Medical Problems.

DIAS, 2009 DIAS, W. S. B. Luiz Antonio dos. **Biometria experimental**. 1ª edição. ed. [S.l.]: UFV, 2009. 408 p.

TECHMUNDO, 2012 Elaine Martins - Porque uma lâmpada de LED é mais econômica. Disponível em: <<http://www.tecmundo.com.br/led/34046-por-que-uma-lampada-de-led-e-mais-economica-.htm>>. Acesso em: 13 ago. 2014.

ELTOUKHY; FAYE; SAMIR, 2010 ELTOUKHY, M. M.; FAYE, I.; SAMIR, B. B. A comparison of wavelet and curvelet for breast cancer diagnosis in digital mammogram. **Computers in Biology and Medicine** ", v. 40, n. 4, p. 384 – 391, 2010. DOI: <http://dx.doi.org/10.1016/j.compbiomed.2010.02.002>.

ESAN; NGWIRA; OSUNMAKINDE, 2013 ESAN, O.; NGWIRA, S.; OSUNMAKINDE, I. Bi-modal biometrics for financial infrastructure security. **Information Security for South Africa**, 2013. p. 1–8, Aug 2013. DOI: 10.1109/ISSA.2013.6641045.

FAN; LIN, 2004 FAN, K.-C.; LIN, C.-L. The use of thermal images of palm-dorsa vein-patterns for biometric verification. **Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on**. v. 4, p. 450–453 Vol.4, Aug 2004. DOI: 10.1109/ICPR.2004.1333799.

NETWORKWORLD, 2012 FF Staff Attorney Jennifer Lynch. Disponível em: <<http://canaltech.com.br/noticia/seguranca>>. Acesso em: 10 ago. 2014.

FISCHER; RYBNICEK; TJOA, 2012 FISCHER, M.; RYBNICEK, M.; TJOA, S. A novel palm vein recognition approach based on enhanced local gabor binary patterns histogram sequence. **Systems, Signals and Image Processing (IWSSIP), 2012 19th International Conference on**. p. 429–432, April 2012.

FORUM BIOMETRIA, 2014 Forum Biometria - Fraudes no sistema biométrico das auto escolas. Disponível em : <<http://www.forumbiometria.com/noticias/35-geral/195-trio-e-presosuspeito-de-fraude-em-autoescola-na-grande-sao-paulo.html>>. Acesso em: 08 ago. 2014.

FRIEDMAN; BENTLEY; FINKEL, 1977 FRIEDMAN, J. H.; BENTLEY, J. L.; FINKEL, R. A. An algorithm for finding best matches in logarithmic expected time. **ACM Trans. Math. Softw.**, New York, NY, USA, ACM, v. 3, n. 3, p. 209–226, set. 1977. 18 p. DOI: 10.1145/355744.355745.

GONZALEZ; WOODS, 2001 GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 2nd. ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2001.

GU; CERCONE, 2006 GU, Z.; CERCONE, N. Naive bayes modeling with proper smoothing for information extraction. **Fuzzy Systems, 2006 IEEE International Conference on**. p. 393–400, 2006. DOI: 10.1109/FUZZY.2006.1681742.

GUIA DO CFTV, 2012 GuiadoCFTV - Portal de Informações Técnicas Sobre Sistemas de CFTV, Segurança Eletrônica, Redes e Tecnologias.. Disponível em: <<http://www.guiadocftv.com.br/>>. Acesso em: 13 ago. 2014.

GUO; HALL, 1992 GUO, Z.; HALL, R. W. Fast fully parallel thinning algorithms. **CVGIP-Comput. Vision Graphics Image Process: Image Understanding**, 55. p. 317–328, 1992.

HALL, 1999 HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. 1999. Tese (Doutorado).

- HAN, 2005 HAN, J. **Data Mining: Concepts and Techniques**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2005.
- HAWKES; CLAYDEN, 1993 HAWKES, P.; CLAYDEN, D. Veincheck research for automatic identification of people. p. 52–56, Sep 1993.
- HAYKIN, 2001 HAYKIN, S. **Redes Neurais - 2ed.** [S.l.]: BOOKMAN COMPANHIA ED, 2001.
- HEGDE et al., 2009 HEGDE, C. et al. Authentication of damaged hand vein patterns by modularization. **TENCON 2009 - 2009 IEEE Region 10 Conference**. p. 1–6, Jan 2009. DOI: 10.1109/TENCON.2009.5395822.
- HONG et al., 2009 HONG, J. et al. Vein pattern extraction based on the position-gray-profile curve. **Image and Signal Processing, 2009. CISP '09. 2nd International Congress on**. p. 1–4, Oct 2009. DOI: 10.1109/CISP.2009.5302650.
- HUANG et al., 2003 HUANG, L.-L. et al. Gradient feature extraction for classification-based face detection. **Pattern Recognition**, v. 36, n. 11, p. 2501 – 2511, 2003. DOI: [http://dx.doi.org/10.1016/S0031-3203\(03\)00130-4](http://dx.doi.org/10.1016/S0031-3203(03)00130-4).
- PHILIPS, 2014 HUE Lamps Philips. Disponível em : <<http://www.usa.philips.com/e/hue/hue.html>>. Acesso em: 29 jun. 2014.
- IM et al., 2000 IM, S.-K. et al. Improved vein pattern extracting algorithm and its implementation. **Consumer Electronics, 2000. ICCE. 2000 Digest of Technical Papers. International Conference on**. p. 2–3, June 2000. DOI: 10.1109/ICCE.2000.854470.
- INSANKEOVILAY; PRASARN; CHOOMCHUAY, 2011 INSANKEOVILAY, S.; PRASARN, P.; CHOOMCHUAY, S. Fingerprint matching with cross correlation and minutiae scores. **Biomedical Engineering International Conference (BMEiCON), 2011**. p. 174–177, Jan 2011. DOI: 10.1109/BMEiCon.2012.6172045.
- IBI, 1987 Intelligent Building Definitions. Disponível em: <<http://www.ibuilding.gr/definitions.html>>. Acesso em: 27 mar. 2014.
- JAIN et al., 2004 JAIN, A. et al. Biometrics: a grand challenge. **Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on**. v. 2, p. 935–942 Vol.2, Aug 2004. DOI: 10.1109/ICPR.2004.1334413.
- JANES, 2009 JANES, R. **Estudo sobre sistemas de segurança em instalações elétricas automatizadas**. 2009. 121 p. Dissertação (Dissertação de Mestrado) — Universidade de São Paulo - Escola Politécnica, São Paulo, 2009.

JANES; BRANDÃO JR, 2014 JANES, R.; BRANDÃO JR, A. F. A low cost system for dorsal hand vein patterns recognition using curvelets. **1st International Conference on Systems Informatics, Modelling and Simulation, SIMS2013 (SIMS2014)**. abr. 2014.

JANES; BRANDÃO JR; DIAS, 2010 JANES, R.; BRANDÃO JR, A. F.; DIAS, E. M. A study on the available biometric technologies used in order to control security in physical access. **WSEAS Trans. Sys. Ctrl.**, Stevens Point, Wisconsin, USA, World Scientific and Engineering Academy and Society (WSEAS), v. 5, n. 6, p. 393–402, jun. 2010. 10 p.

JANES et al., 2008 JANES, R. et al. Selecting a biometric technology for application in access control. **12th WSEAS International Conference on Systems**. p. 161–168, 2008.

JIAO et al., 2007 JIAO, C. et al. Gab: graph augmented bayes classifier. **Fuzzy Systems and Knowledge Discovery, 2007. FSKD 2007. Fourth International Conference on**. v. 1, p. 608–612, Aug 2007. DOI: 10.1109/FSKD.2007.340.

JOARDAR; CHATTERJEE; RAKSHIT, 2015 JOARDAR, S.; CHATTERJEE, A.; RAKSHIT, A. A real-time palm dorsa subcutaneous vein pattern recognition system using collaborative representation-based classification. **Instrumentation and Measurement, IEEE Transactions on**, v. 64, n. 4, p. 959–966, April 2015. DOI: 10.1109/TIM.2014.2374713.

JÚNIOR, 2013 JÚNIOR, A. B. C. **Manual de prevenção e combate a incêndios**. 15ª edição. ed. São Paulo: SENAC, 2013. 247 p.

KABACINSKI; KOWALSKI, 2011 KABACINSKI, R.; KOWALSKI, M. Vein pattern database and benchmark results. **Electronics Letters**, v. 47, n. 20, p. 1127–1128, September 2011. DOI: 10.1049/el.2011.1441.

KOVACS, 2002 KOVACS, Z. **Redes Neurais Artificiais**. [S.l.]: LIVRARIA DA FISICA, 2002.

KRAUTHGAMER; LEE, 2004 KRAUTHGAMER, R.; LEE, J. R. Navigating nets: simple algorithms for proximity search. **Proceedings of the Fifteenth Annual ACM-SIAM Symposium on Discrete Algorithms**. p. 798–807, 2004.

KUMAR; ASATI, 2014 KUMAR, A.; ASATI, A. Iris based biometric identification system. **Audio, Language and Image Processing (ICALIP), 2014 International Conference on**. p. 260–265, July 2014. DOI: 10.1109/ICALIP.2014.7009797.

KUMAR; HANMANDLU; GUPTA, 2009 KUMAR, A.; HANMANDLU, M.; GUPTA, H. On-line biometric authentication using hand vein patterns. **Computational Intelligence for Security and Defense Applications, 2009. CISDA 2009. IEEE Symposium on**. p. 1–7, July 2009. DOI: 10.1109/CISDA.2009.5356554.

KUMAR et al., 2009 KUMAR, A. et al. Biometric authentication based on infrared thermal hand vein patterns. **Digital Image Computing: Techniques and Applications, 2009. DICTA '09**. p. 331–338, Dec 2009. DOI: 10.1109/DICTA.2009.63.

KUMAR; PRATHYUSHA, 2009 KUMAR, A.; PRATHYUSHA, K. Personal authentication using hand vein triangulation and knuckle shape. **Image Processing, IEEE Transactions on**, v. 18, n. 9, p. 2127–2136, Sept 2009. DOI: 10.1109/TIP.2009.2023153.

KUMAR et al., 2003 KUMAR, A. et al. Personal verification using palmprint and hand geometry biometric. In: **Audio- and Video-Based Biometric Person Authentication. Audio- and Video-Based Biometric Person Authentication**. [S.l.]: Springer Berlin Heidelberg, 2003. (Lecture Notes in Computer Science, v. 2688), p. 668–678.

LI; KOT, 2013 LI, S.; KOT, A. Fingerprint combination for privacy protection. **Information Forensics and Security, IEEE Transactions on**, v. 8, n. 2, p. 350–360, Feb 2013. DOI: 10.1109/TIFS.2012.2234740.

LI; SAVVIDES, 2013 LI, Y.-H.; SAVVIDES, M. An automatic iris occlusion estimation method based on high-dimensional density estimation. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 35, n. 4, p. 784–796, April 2013. DOI: 10.1109/TPAMI.2012.169.

LIN; FAN, 2004 LIN, C.-L.; FAN, K.-C. Biometric verification using thermal images of palm-dorsa vein patterns. **Circuits and Systems for Video Technology, IEEE Transactions on**, IEEE, v. 14, n. 2, p. 199–213, Feb 2004. DOI: 10.1109/TCSVT.2003.821975.

LOGITECH, 2014 Logitech HD Webcam C525. Disponível em : <<http://www.logitech.com/pt-br/product/7794?crd=34>>. Acesso em: 29 jul. 2014.

MACGREGOR; WELFORD, 1991 MACGREGOR, P.; WELFORD, R. Veincheck: imaging for security and personnel identification. p. 52–56, 1991.

MACGREGOR; WELFORD, 1992 MACGREGOR, P.; WELFORD, R. Veincheck lends a hand for high security. p. 19–23, 1992.

MALKI; SPAANENBURG, 2010 MALKI, S.; SPAANENBURG, L. Cbas: a cnn-based biometrics authentication system. **Cellular Nanoscale Networks and Their Applications (CNNA), 2010 12th International Workshop on**. p. 1–6, Feb 2010. DOI: 10.1109/CNNA.2010.5430267.

MAMMASS, 2011 MAMMASS, H. Implementation of smart card personalization software. **Multimedia Computing and Systems (ICMCS), 2011 International Conference on**. p. 1–7, April 2011. DOI: 10.1109/ICMCS.2011.5945701.

MANDAL; WU; YUAN, 2009 MANDAL, T.; WU, Q. J.; YUAN, Y. Curvelet based face recognition via dimension reduction. **Signal Processing**, v. 89, n. 12, p. 9, 2009. DOI: 10.1016/j.sigpro.2009.03.007. Special Section: Visual Information Analysis for Security.

MATYAS V.; RIHA, 2003 MATYAS V., J.; RIHA, Z. Toward reliable user authentication through biometrics. **Security Privacy, IEEE**, v. 1, n. 3, p. 45–49, May 2003. DOI: 10.1109/MSECP.2003.1203221.

MEHNERT; CROSS; SMITH, 1992 MEHNERT, A. J.; CROSS, J.; SMITH, C. Veincheck lends a hand for high security. **Research Report, Australian Institute of Security and Applied Technology**. p. 19–23, 1992.

MILLER; MILLER, 2014 MILLER, R.; MILLER, M. R. **Ar Condicionado e Refrigeração**. 2nd edition. ed. [S.l.]: LTC, 2014. 586 p.

MIRMOHAMADSADEGHI; DRYGAJLO, 2011 MIRMOHAMADSADEGHI, L.; DRYGAJLO, A. Palm vein recognition with local binary patterns and local derivative patterns. **Biometrics (IJCB), 2011 International Joint Conference on**. p. 1–6, Oct 2011. DOI: 10.1109/IJCB.2011.6117804.

MOHAMMED et al., 2009 MOHAMMED, G. et al. A new localization method for iris recognition based on angular integral projection function. **Education Technology and Computer Science, 2009. ETCS '09. First International Workshop on**. v. 3, p. 316–320, March 2009. DOI: 10.1109/ETCS.2009.596.

MONTEBELLER, 2006 MONTEBELLER, S. J. **Estudo sobre o emprego de dispositivos sem fios - wireless na automação do ar condicionado e de outros sistemas prediais**. 2006. 129 p. Dissertação (Dissertação de Mestrado) — Universidade de São Paulo - Escola Politécnica, São Paulo, 2006.

NANNI; BRAHNAM; LUMINI, 2012 NANNI, L.; BRAHNAM, S.; LUMINI, A. A very high performing system to discriminate tissues in mammograms as benign and malignant. **Expert Syst. Appl.**, Tarrytown, NY, USA, Pergamon Press, Inc., v. 39, n. 2, p. 1968–1971, fev. 2012. 4 p. DOI: 10.1016/j.eswa.2011.08.050.

NAROTE et al., 2006 NAROTE, S. et al. An automated segmentation method for iris recognition. **TENCON 2006. 2006 IEEE Region 10 Conference**. p. 1–4, Nov 2006. DOI: 10.1109/TENCON.2006.344211.

ÖDEN et al., 2001 ÖDEN, C. et al. Hand recognition using implicit polynomials and geometric features. In: **Audio- and Video-Based Biometric Person Authentication. Audio- and Video-Based Biometric Person Authentication**. [S.l.]: Springer Berlin Heidelberg, 2001. (Lecture Notes in Computer Science, v. 2091), p. 336–341.

OJALA; PIETIKAINEN; MAENPAA, 2002 OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 24, n. 7, p. 971–987, Jul 2002. DOI: 10.1109/TPAMI.2002.1017623.

PARK et al., 2006 PARK, C. et al. Multi-modal human verification using face and speech. **Computer Vision Systems, 2006 ICVS '06. IEEE International Conference on**. p. 54–54, Jan 2006. DOI: 10.1109/ICVS.2006.45.

PARTHIBAN et al., 2014 PARTHIBAN, K. et al. Finger vein extraction and authentication based on gradient feature selection algorithm. **Applications of Digital Information and Web Technologies (ICADIWT), 2014 Fifth International Conference on the**. p. 143–147, Feb 2014. DOI: 10.1109/ICADIWT.2014.6814681.

PINHEIRO, 2008 PINHEIRO, J. M. **Biometria nos Sistemas Computacionais - Você é a Senha**. 1ª edição. ed. Rio de Janeiro: Ciência Moderna, 2008. 208 p.

PINHEIRO, 2010 PINHEIRO, J. M. **ABNT NBR 17240:2010**: Sistemas de detecção e alarme de incêndio - projeto, instalação, comissionamento e manutenção de sistemas de detecção e alarme de incêndios. [S.l.]: ABNT NBR, novembro 2010. 54 p. v. 1.

PINTO; MORAES; BRANDÃO JR, 2000 PINTO, J. R.; MORAES, C. C. de; BRANDÃO JR, A. F. Electrical energy conservation in a commercial building with systems automation. In: **Advances in Networked Enterprises. Advances in Networked Enterprises**. [S.l.]: Springer US, 2000. (IFIP - The International Federation for Information Processing, v. 53), p. 439–447. DOI: 10.1007/9780387355290_42.

PINTO; MORAES; BRANDÃO JR, 2000 PINTO, J. R.; MORAES, C. C. de; BRANDÃO JR, A. F. Electrical energy conservation in a commercial building with systems automation. 1aed. Boston - USA: Kluwer Academic Publishers, p. 439–447, 2000.

PLAMONDON; PARIZEAU, 1988 PLAMONDON, R.; PARIZEAU, M. Signature verification from position, velocity and acceleration signals: a comparative study. **Pattern Recognition, 1988., 9th International Conference on**. p. 260–265 vol.1, Nov 1988. DOI: 10.1109/ICPR.1988.28218.

PRUDENTE, 2011 PRUDENTE, F. **Automação Predial e Residencial - Uma Introdução**. 1ª edição. ed. [S.l.]: LTC, 2011. 228 p.

UFRJ - BIOMETRIA DA MÃO, 2009 Rafael Senra Caraméz. Disponível em: <<http://www.lcg.ufrj.br/Members/rafael>>. Acesso em: 10 ago. 2014.

RAJAN; SUDHA; KUMAR, 2013 RAJAN, R.; SUDHA, N.; KUMAR, P. O-f estimation based on curved gabor filter for fingerprint image enhancement. **Advanced Computing**

(ICoAC), 2013 **Fifth International Conference on**. p. 405–412, Dec 2013. DOI: 10.1109/ICoAC.2013.6921985.

RASHID et al., 2008 RASHID, R. et al. Security system using biometric technology: design and implementation of voice recognition system (vrs). **Computer and Communication Engineering, 2008. ICCCE 2008. International Conference on**. p. 898–902, May 2008. DOI: 10.1109/ICCCE.2008.4580735.

IPOG, 2013 Revista online Especialize - IPOG. Disponível em : <<http://www.ipog.edu.br>>. Acesso em: 29 jun. 2014.

RICE, 1994 RICE, A. A quality approach to biometric imaging. **Image Processing for Biometric Measurement, IEE Colloquium on**. p. 4/1–4/5, Apr 1994.

RICE, 1987 J. RICE. **Apparatus for the identification of individuals**. out. 13 1987. US Patent 4,699,149.

SALZBERG, 1994 SALZBERG, S. C4.5: programs for machine learning by j. ross quinlan. morgan kaufmann publishers, inc., 1993. **Machine Learning**, Kluwer Academic Publishers, v. 16, n. 3, p. 235–240, 1994. DOI: 10.1007/BF00993309.

SANCHES; ANTUNES; CORREIA, 2007 SANCHES, T.; ANTUNES, J.; CORREIA, P. A single sensor hand biometric multimodal system. **Signal Processing Conference, 2007 15th European**. p. 30–34, Sept 2007.

SANCHEZ-REILLO, 2000 SANCHEZ-REILLO, R. Hand geometry pattern recognition through gaussian mixture modelling. **Pattern Recognition, 2000. Proceedings. 15th International Conference on**. v. 2, p. 937–940 vol.2, 2000. DOI: 10.1109/ICPR.2000.906228.

SANCHIT et al., 2011 SANCHIT et al. Biometric identification through palm and dorsal hand vein patterns. **EUROCON - International Conference on Computer as a Tool (EUROCON), 2011 IEEE**. p. 1–4, April 2011. DOI: 10.1109/EUROCON.2011.5929297.

SILVA; SILVA, 2008 SILVA, J. de; SILVA, A. C. G. C. **Refrigeração e climatização para técnicos e engenheiros**. 1ª edição. ed. Rio de Janeiro: Ciência Moderna, 2008. 360 p.

SINGH, 2014 SINGH, N. An improved algorithm for efficient iris based system. **Control, Instrumentation, Communication and Computational Technologies (IC-CICCT), 2014 International Conference on**. p. 604–607, July 2014. DOI: 10.1109/IC-CICCT.2014.6993033.

SPREEUWERS et al., 2014 SPREEUWERS, L. et al. Fixed far vote fusion of regional facial classifiers. **Biometrics Special Interest Group (BIOSIG), 2014 International Conference of the**. p. 1–4, Sept 2014.

STARCK; CANDÈS; DONOHO, 2002 STARCK, J.-L.; CANDÈS, E.; DONOHO, D. The curvelet transform for image denoising. **Image Processing, IEEE Transactions on**, v. 11, n. 6, p. 670–684, Jun 2002. DOI: 10.1109/TIP.2002.1014998.

SUEN; ZHANG, 1984 SUEN, C.; ZHANG, T. A fast parallel algorithm for thinning digital patterns. **Communications of the ACM**, 27(3). p. 236–239, Mar 1984.

SWAIN; BALLARD, 1991 SWAIN, M.; BALLARD, D. Color indexing. **International Journal of Computer Vision**, Kluwer Academic Publishers, v. 7, n. 1, p. 11–32, 1991. DOI: 10.1007/BF00130487.

TANAKA; KUBO, 2004 TANAKA, T.; KUBO, N. Biometric authentication by hand vein patterns. **SICE 2004 Annual Conference**. v. 1, p. 249–253 vol. 1, Aug 2004.

TANG; HUANG; WANG, 2012 TANG, Y.; HUANG, D.; WANG, Y. Hand-dorsa vein recognition based on multi-level keypoint detection and local feature matching. **Pattern Recognition (ICPR), 2012 21st International Conference on**. p. 2837–2840, Nov 2012.

THOMASSON; BALDI, 1997 THOMASSON, J.-P.; BALDI, L. Smartcards: portable security. **Innovative Systems in Silicon, 1997. Proceedings., Second Annual IEEE International Conference on**. p. 259–265, Oct 1997. DOI: 10.1109/ICISS.1997.630268.

TOH et al., 2005 TOH, K.-A. et al. Identity verification through palm vein and crease texture. In: **Advances in Biometrics. Advances in Biometrics**. [S.l.]: Springer Berlin Heidelberg, 2005. (Lecture Notes in Computer Science, v. 3832), p. 546–553. DOI: 10.1007/11608288_73.

TSE, 2014 TSE - Recadastramento Biométrico. Disponível em : <<http://www.tre-sp.jus.br/eleitor/recadastramento-biometrico-1>>. Acesso em: 08 ago. 2014.

UHLMANN, 1991 UHLMANN, J. K. Satisfying general proximity / similarity queries with metric trees. **Information Processing Letters**, v. 40, n. 4, p. 175 – 179, 1991. DOI: [http://dx.doi.org/10.1016/0020-0190\(91\)90074-R](http://dx.doi.org/10.1016/0020-0190(91)90074-R).

VANDERGHEYNST; GOBBERS, 2002 VANDERGHEYNST, P.; GOBBERS, J.-F. Directional dyadic wavelet transforms: design and algorithms. **Image Processing, IEEE Transactions on**, v. 11, n. 4, p. 363–372, Apr 2002. DOI: 10.1109/TIP.2002.999670.

VIGLIAZZI, 2006 VIGLIAZZI, D. **Biometria - Medidas de Segurança**. 2ª edição. ed. [S.l.]: Visual Books, 2006.

WANG et al., 2007 WANG, J.-G. et al. Fusion of palmprint and palm vein images for person recognition based on "laplacianpalm"feature. **Computer Vision and Pattern Recognition, 2007. CVPR '07. IEEE Conference on**. p. 1–8, June 2007. DOI: 10.1109/CVPR.2007.383386.

WANG; CHEN, 2011 WANG, J.-W.; CHEN, T.-H. Building palm vein capturing system for extraction. **Systems Engineering (ICSEng), 2011 21st International Conference on**. p. 311–314, Aug 2011. DOI: 10.1109/ICSEng.2011.61.

WANG et al., 2006 WANG, K. et al. The study of hand vein image processing method. **Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on**. v. 2, p. 10197–10201, 2006. DOI: 10.1109/WCICA.2006.1713997.

WANG et al., 2006 WANG, K. et al. Hand vein recognition based on multi supplemental features of multi-classifier fusion decision. **Mechatronics and Automation, Proceedings of the 2006 IEEE International Conference on**. p. 1790–1795, June 2006. DOI: 10.1109/ICMA.2006.257486.

WANG; LEEDHAM, 2006 WANG, L.; LEEDHAM, G. Gray-scale skeletonization of thermal vein patterns using the watershed algorithm in vein pattern biometrics. **Computational Intelligence and Security, 2006 International Conference on**. v. 2, p. 1597–1602, Nov 2006. DOI: 10.1109/ICCIAS.2006.295332.

WANG; LEEDHAM, 2006 WANG, L.; LEEDHAM, G. Near- and far- infrared imaging for vein pattern biometrics. **Video and Signal Based Surveillance, 2006. AVSS '06. IEEE International Conference on**. p. 52–52, Nov 2006. DOI: 10.1109/AVSS.2006.80.

WANG; LEEDHAM; CHO, 2007 WANG, L.; LEEDHAM, G.; CHO, S. Y. Infrared imaging of hand vein patterns for biometric purposes. **Computer Vision, IET, IET**, v. 1, n. 3-4, p. 113–122, December 2007. DOI: 10.1049/iet-cvi:20070009.

WANG; CHEN; SHIH, 2009 WANG, W.-C.; CHEN, W.-S.; SHIH, S.-W. Biometric recognition by fusing palmprint and hand-geometry based on morphology. **Acoustics, Speech and Signal Processing, 2009. ICASSP 2009. IEEE International Conference on**. p. 893–896, April 2009. DOI: 10.1109/ICASSP.2009.4959728.

WANG; LI; CUI, 2010 WANG, Y.; LI, K.; CUI, J. Hand-dorsa vein recognition based on partition local binary pattern. **Signal Processing (ICSP), 2010 IEEE 10th International Conference on**. p. 1671–1674, Oct 2010. DOI: 10.1109/ICOSP.2010.5656717.

WANG; WU, 2011 WANG, Y.; WU, S. Development of a solar led illumination control system based on variable universe adaptive fuzzy pid controller. **Power and Energy Engineering Conference (APPEEC), 2011 Asia-Pacific**. p. 1–4, March 2011. DOI: 10.1109/APPEEC.2011.5749162.

WATANABE; TANAKA; IWATA, 2006 WATANABE, S.; TANAKA, T.; IWATA, E. Biometric authentication using phase only correlation with compensation algorithm for rotation. **SICE-ICASE, 2006. International Joint Conference**. p. 3711–3715, Oct 2006. DOI: 10.1109/SICE.2006.315023.

WIJAYA; UCHIMURA; KOUTAKI, 2011 WIJAYA, I.; UCHIMURA, K.; KOUTAKI, G. Human face security system using alternative linear discriminant analysis based classifier. **Frontiers of Computer Vision (FCV), 2011 17th Korea-Japan Joint Workshop on**. p. 1–6, Feb 2011. DOI: 10.1109/FCV.2011.5739706.

WITTEN; FRANK, 2005 WITTEN, I. H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques, Second Edition (Morgan Kaufmann Series in Data Management Systems)**. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2005.

XIAOXIA, 2004 XIAOXIA, L. **Numerical Analysis and Experimental Research on Laser induced Thermal Effect in Bio-tissues**. 2004. Tese (PhD Thesis) — Tianjin University, China.

YANG; LIU; LIU, 2010 YANG, L.; LIU, X.; LIU, Z. A skeleton extracting algorithm for dorsal hand vein pattern. **Computer Application and System Modeling (ICCASM), 2010 International Conference on**. v. 13, p. V13–92–V13–95, Oct 2010. DOI: 10.1109/IC-CASM.2010.5622671.

YU; LIU, 2003 YU, L.; LIU, H. Feature selection for high-dimensional data: a fast correlation-based filter solution. p. 856–863, 2003.

YUAN, 2010 YUAN, X. Biometric verification using hand vein-patterns. **Wireless Communications, Networking and Information Security (WCNIS), 2010 IEEE International Conference on**. p. 677–681, June 2010. DOI: 10.1109/WCINS.2010.5541865.

YÜKSEL; AKARUN; SANKUR, 2010 YÜKSEL, A.; AKARUN, L.; SANKUR, B. Biometric identification through hand vein patterns. **Emerging Techniques and Challenges for Hand-Based Biometrics (ETCHB), 2010 International Workshop on**. p. 1–6, Aug 2010. DOI: 10.1109/ETCHB.2010.5559295.

ZHANG; HU, 2010 ZHANG, H.; HU, D. A palm vein recognition system. **Intelligent Computation Technology and Automation (ICICTA), 2010 International Conference on**. v. 1, p. 285–288, May 2010. DOI: 10.1109/ICICTA.2010.425.

ZHAO et al., 2005 ZHAO, J. et al. Lbp discriminant analysis for face verification. **Computer Vision and Pattern Recognition - Workshops, 2005. CVPR Workshops. IEEE Computer Society Conference on**. p. 167–167, June 2005. DOI: 10.1109/CVPR.2005.580.

ZHAO et al., 2013 ZHAO, Q. et al. A generative model for fingerprint minutiae. **Biometrics (ICB), 2013 International Conference on**. p. 1–8, June 2013. DOI: 10.1109/ICB.2013.6613020.

ZHAO; WANG; WANG, 2007 ZHAO, S.; WANG, Y.; WANG, Y. Extracting hand vein patterns from low-quality images: a new biometric technique using low-cost devices. **Image and**

Graphics, 2007. **ICIG 2007. Fourth International Conference on**. p. 667–671, Aug 2007. DOI: 10.1109/ICIG.2007.97.

ZHAO; WANG, 2008 ZHAO, S.; WANG, Y.-D. Biometric identification based on low-quality hand vein pattern images. **Machine Learning and Cybernetics, 2008 International Conference on**. v. 2, p. 1172–1177, July 2008. DOI: 10.1109/ICMLC.2008.4620581.

ZHOU; KUMAR, 2010 ZHOU, Y.; KUMAR, A. Contactless palm vein identification using multiple representations. **Biometrics: Theory Applications and Systems (BTAS), 2010 Fourth IEEE International Conference on**. p. 1–6, Sept 2010. DOI: 10.1109/BTAS.2010.5634470.

ZUIDERVELD, 1994 ZUIDERVELD, K. Graphics gems iv. In: . San Diego, CA, USA: Academic Press Professional, Inc., 1994. cap. Contrast Limited Adaptive Histogram Equalization, p. 474–485.