

UNIVERSIDADE FEDERAL DO PARANÁ

LUIZ EDUARDO DE CHRISTO

SISTEMA BIOMÉTRICO MULTIMODAL DE VERIFICAÇÃO DE  
IDENTIDADE BASEADO NA GEOMETRIA DA MÃO E VEIAS  
DA PALMA

CURITIBA  
2017



LUIZ EDUARDO DE CHRISTO

SISTEMA BIOMÉTRICO MULTIMODAL DE VERIFICAÇÃO DE  
IDENTIDADE BASEADO NA GEOMETRIA DA MÃO E VEIAS  
DA PALMA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Visão Computacional, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Alessandro Zimmer

CURITIBA  
2017

---

C556s

Christo, Luiz Eduardo de  
Sistema biométrico multimodal de verificação de identidade baseado na geometria da mão e veias da palma / Luiz Eduardo de Christo. – Curitiba, 2017.  
77 f. : il. color. ; 30 cm.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2017.

Orientador: Alessandro Zimmer.

1. Biometria. 2. Sistema biométrico, 3. Geometria da mão. I. Universidade Federal do Paraná.  
II. Zimmer, Alessandro. III. Título.

CDD: 006.3

---



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
Setor TECNOLOGIA  
Programa de Pós Graduação em ENGENHARIA ELÉTRICA  
Código CAPES: 40001016043P4

### TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **LUIZ EDUARDO DE CRISTO**, intitulada: "**SISTEMA BIOMÉTRICO MULTIMODAL DE VERIFICAÇÃO DE IDENTIDADE BASEADO NA GEOMETRIA DA MÃO E VEIAS DA PALMA**", após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 18 de Agosto de 2017.

ALESSANDRO ZIMMER  
Presidente da Banca Examinadora (UFPR)

GIDEON VILLAR LEANDRO  
Avaliador Interno (UFPR)

LUIZ HENRIQUE ASSUMPÇÃO LOLIS  
Avaliador Interno (UFPR)

MARCELO RUDEK  
Avaliador Externo (PUC/PR)



## RESUMO

Este trabalho apresenta um sistema multibiométrico capaz de trabalhar com imagens da palma de mão tiradas sem contato com uma superfície. Ato o qual dificulta consideravelmente o processamento, pois as variações de uma imagem da mesma pessoa podem ser significativas. Uma solução para a redução dessa variação foi proposta e aplicada. O Sistema implementado abstrai todas as etapas do processamento biométrico bem como fornece para o usuário um método para cada etapa em separado: preparação das imagens, passando pela extração das características, processamento (aplicação de filtros), normalização e fusão. As biometrias utilizadas para a identificação compreendem características da geometria da mão bem como características de textura das veias das palmas. Para os dados da geometria, um algoritmo para detecção das pontas dos dedos e também dos vales foi proposto e a partir daí foi possível extrair outras características geométricas. As características de textura das veias palmares foram extraídas a partir de uma região de interesse com base no ponto de centro de massa da mão. O descritor de textura escolhido foi o *Histogram of Gradients*. De posse de todos os dados biométricos, a fusão foi feita em nível de características. Para a classificação optou-se pelas Máquinas de Vetores de Suporte. A base de dados escolhida para o desenvolvimento do projeto foi a *CASIA Multi-Spectral Palmprint Image Database V1.0*. Foram utilizadas as imagens do espectro de 940nm por permitirem a visualização das veias da mão. O resultado obtido para a biometria da geometria da mão foi uma EER (*Equal Error Rate*) de 4,77%, para a biometria das veias da palma a EER foi de 3,11% e alterando o valor de limiar alcançou-se uma FAR de 0,50% e uma FRR(*False Rejection Rate*) de 4,82%. Para a fusão das duas biometrias o resultado final foi uma EER de 2,33% com uma FAR(*False Aception Rate*) de 1,30% e uma FRR de 4,27%.

**Palavras-chaves:** biometria, geometria da mão, veias palmares, biometria multimodal, sistema biométrico, máquina de vetores de suporte, *histogram of gradients*.



## ABSTRACT

This project was developed aiming the implementation of a multibiometric system capable to handle hand palm images acquired using a touchless approach. This considerable increases the difficult of the image processing task due to the fact that the images from the same person may vary significantly. solution for this was proposed and applied. The application developed abstracted was the steps from the image processing as well provides the user a method for each of these steps: initial image preparation, through the feature extraction, processing and fusion, ending with the classification, are all accessible in only one place, thus making the researcher's task a lot easier and faster. The biometric features used for identification include hand geometry features as well palm vein textures. For the hand geometry data, an algorithm for finger tips and hand valleys was proposed and from there was possible to extract a handful of other features related to the geometry of the hand. The hand palm veins' texture features were extracted from a rectangle generated based on the hand's center of mass. The texture descriptor chosen was the *Histogram of Gradients*. In possession with all the biometric data, the fusion was done on feature level. Support Vector Machine technique was used for the classification. The database chosen for the development of this project was the *CASIA Multi-Spectral Palmprint Image Database V1.0*. The images used corresponds to the 940nm spectrum due to allowing the visualization of the hand palm's veins. The achieved result for the hand geometry was an EER of 4,77%, for the palm veins an EER of 3,11% and changing the threshold value a FAR of 0,50% and a FRR of 4,82% were achieved. For the fusion of both biometrics systems the final result was an EER of 2,33% with a FAR of 1,30% and a FRR of 4,27%.

**Keywords:** biometry, hand geometry, palm veins, multimodal biometry, biometric system, support vector machines, *histogram of gradients*.



## SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	DEFINIÇÃO DO PROBLEMA .....	17
1.2	MOTIVAÇÃO E JUSTIFICATIVA.....	17
1.3	OBJETIVOS.....	18
1.3.1	Objetivo Geral.....	18
1.3.2	Objetivos Específicos.....	19
1.4	ESTRUTURA DA DISSERTAÇÃO .....	19
2.	FUNDAMENTAÇÃO TEÓRICA.....	20
2.1	BIOMETRIA .....	20
2.1.1	Componentes de um sistema biométrico .....	21
2.1.2	Verificação x Identificação .....	22
2.1.3	Performance de um sistema biométrico .....	23
2.1	BIOMETRIA MULTIMODAL .....	26
2.1.1	Fusão no Nível do Sensor .....	26
2.1.2	Fusão no Nível dos Atributos.....	27
2.1.3	Fusão no Nível do <i>Rank</i> .....	28
2.1.4	Fusão no Nível de Pontuação .....	28
2.2	PROCESSAMENTO DE IMAGENS .....	29
2.2.1	Histograma.....	30
2.2.2	Binarização .....	30
2.2.3	Detecção de Bordas .....	32
2.2.4	Extração de contorno.....	33
2.3	MÁQUINAS DE VETORES SUPORTE(SVM).....	34
2.3.1	A biblioteca de funções LIBSVM .....	37
2.4	PADRÕES DE PROJETO .....	38
2.4.1	O Padrão <i>Facade</i> .....	39
2.4.2	O Padrão <i>FactoryMethod</i> .....	39
2.4.3	O Padrão <i>Singleton</i> .....	40
2.4.3	O Padrão <i>Strategy</i> .....	41
2.5	HISTOGRAMA DE GRADIENTES ORIENTADOS ( <i>HOG</i> ).....	42
2.6	ESTADO DA ARTE .....	43
3.	MATERIAIS E MÉTODOS.....	46
3.1	BANCO DE DADOS.....	48
3.2	GEOMETRIA DA MÃO .....	48
3.2.1	Ponto de referência.....	49
3.2.2	Detecção de vales e pontas dos dedos.....	51
3.2.3	Comprimento da palma e linhas base.....	54
3.2.4	Comprimentos dos dedos.....	55
3.2.5	Larguras dos dedos.....	55
3.2.6	Distâncias do centro de massa até pontas e vales.....	56
3.2.7	Limitações do Algoritmo de detecção de curvas.....	57
3.3	VEIAS DA PALMA.....	59
3.4	O SISTEMA <i>BIOMETRICSLAB</i> .....	61
3.5	NORMALIZAÇÃO DOS DADOS .....	62
4.	RESULTADOS.....	63
4.1	GEOMETRIA DA MÃO COM NORMALIZAÇÃO POR REGIÕES.....	64
4.2	VEIAS DA PALMA DA MÃO .....	66
4.3	FUSÃO DA GEOMETRIA COM AS VEIAS DA PALMA DA MÃO.....	67

<b>5. CONCLUSÃO .....</b>	<b>70</b>
<b>5.1 CONTRIBUIÇÕES .....</b>	<b>70</b>
<b>5.2 TRABALHOS FUTUROS.....</b>	<b>71</b>
<b>6. REFERÊNCIAS.....</b>	<b>73</b>

## LISTA DE FIGURAS

Figura 1. Componentes de um sistema biométrico.....	22
Figura 2. Gráfico Detection Error Tradeoff. Fonte: JAIN (2004) .....	24
Figura 3. FAR x FRR e ERR. Fonte: O Autor. ....	25
Figura 4. Curva ROC. Fonte: O Autor. ....	26
Figura 5. Formato RGB de 3 bytes. Fonte: O Autor. ....	29
Figura 6. Histograma de imagem colorida. Fonte: O Autor. ....	30
Figura 7. Aplicação da binarização. Fonte: O Autor .....	32
Figura 8. do filtro de Canny. Fonte: O Autor. ....	33
Figura 9. Separação em hiperplanos. Fonte: O Autor.....	35
Figura 10. Margens de um classificador. Fonte: O Autor.....	36
Figura 11. Matriz de scores geradas pelo SVM. Fonte: O Autor .....	38
Figura 12. Diagrama UML do padrão Facade: Fonte: BISHOP, 2013.....	39
Figura 13. Diagrama UML do padrão Factory Method: Fonte: BISHOP, 2013.....	40
Figura 14. Diagrama UML do padrão Singleton: Fonte: BISHOP, 2013. ....	41
Figura 15. Diagrama UML do padrão Strategy: Fonte: BISHOP, 2013.....	41
Figura 16. Máscaras unidimensionais para cálculo de gradiente de um pixel.. Fonte: O Autor. ....	42
Figura 17. Os blocos e células utilizados no HOG. Fonte: Intel.....	43
Figura 18. HOG aplicado em uma imagem.....	43
Figura 19. Processamento de imagem da Binarização até detecção dos vales e pontas. Fonte: O Autor.....	47
Figura 20. Características utilizadas. Fonte: O autor. ....	47
Figura 21. Centro de massa da mão. Fonte: O Autor.....	50
Figura 22. Método DOS+. Fonte BOREKI, 2003.....	51
Figura 23. Regiões de extração de pontas e vales. Fonte: O Autor. ....	52
Figura 24. Resultado final da detecção das pontas e vales. Fonte: O Autor.....	53
Figura 25. Resultado final das linhas base. Fonte: O Autor. ....	54
Figura 26. : Comprimentos dos dedos. Fonte: O Autor.....	55
Figura 27. Larguras dos dedos. Fonte: O Autor. ....	56
Figura 28. Todas as características da geometria da mão extraídas. Fonte: O Autor. .....	57
Figura 29. Problema de aquisição: distância do centro de massa até o polegar. Fonte: O Autor.....	58
Figura 30. Problema com posicionamento. Fonte: O Autor.....	58
Figura 31. Problema com posicionamento. Fonte: O Autor.....	58
Figura 32. Region of Interest (ROI). Fonte: O Autor. ....	59
Figura 33. Blocos e células da HOG. Fonte: O Autor.....	60
Figura 34. Processamento das veias da palma. Fonte: O Autor. ....	60
Figura 35. Descritor HOG aplicado. Fonte: O Autor. ....	60
Figura 36. O sistema BiometricsLab. Fonte: O Autor.....	62
Figura 37. Curvas FAR e FRR com EER para Geometria da mão. Fonte: O Autor...64	64
Figura 38. Curva ROC para Geometria da mão. Fonte: O Autor. ....	65
Figura 39. Curvas FAR e FRR com EER para veias da palma da mão. Fonte: O Autor.....	66
Figura 40. Curva ROC para veias da palma da mão. Fonte: O Autor. ....	67
Figura 41. Curvas FAR e FRR com EER para veias da palma da mão e geometria da mão com fusão por características. Fonte: O Autor.....	68

Figura 42. Curva ROC para veias da palma da mão e geometria da mão com fusão por características. Fonte: O Autor. ....68

## LISTA DE TABELAS

Tabela 1. Trabalhos relacionadas a biometria da geometria da mão.....	45
Tabela 2. Trabalhos relacionados a biometria das veias.....	46
Tabela 3. Características extraídas da Geometria da mão.....	49
Tabela 4. Quadro resumo dos resultados obtidos.....	70

## LISTA DE SIGLAS

C# - C Sharp – Linguagem de Programação orientada a objetos

DOS – Difference of Slopes

EER – Equal Error Rate

FAR - False Acceptance Rate

FRR – False Rejection Rate

HOG – Histogram of Oriented Gradients

LBP - Local Binary Pattern

LDA – Linear Discriminant Analysis

LDP - Local Derivative Patterns

ROC – Receiver Operating Characteristic

ROI – Region of Interest

SIFT - Scale Invariant Feature Transform

SVM – Support Vector Machines

## INTRODUÇÃO

O desenvolvimento de novas tecnologias para armazenar e manipular dados no meio digital fez com que surgisse uma demanda por mecanismos mais elaborados no que diz respeito a garantia da segurança no acesso de tais operações. Os mecanismos mais comuns são o uso de senhas e *tokens*. Porém, esses têm-se mostrado insuficientes para garantir a integridade do processo de identificação do usuário, seja porque o mesmo não segue uma boa política de segurança ou pela evolução das técnicas de ataque.

Diante disso, a necessidade de sistemas mais elaborados para proteção ao acesso, tanto a dados quanto a ambientes, tornou-se maior. É possível aumentar a segurança com a utilização da biometria.

Biometria é a ciência de estabelecer a identidade de um indivíduo com base em atributos físicos, químicos ou comportamentais da pessoa (JAIN, et al., 2007). Através dela é que se torna possível a construção dos sistemas biométricos, os quais tornam o processo de identificação do indivíduo mais seguro.

Os métodos tradicionais usados para estabelecer a identidade de um indivíduo citados (senhas e *tokens*) podem ser perdidos, compartilhados ou roubados. Como a biometria utiliza características biológicas intrínsecas ao indivíduo ajuda a melhorar consideravelmente a segurança no processo de identificação do mesmo.

Os sistemas biométricos foram desenvolvidos para dificultar o acesso indevido. Os métodos tradicionais de se estabelecer a identidade de um indivíduo citados (senhas e *tokens*) podem ser perdidos, compartilhados ou roubados. Como a biometria utiliza características biológicas intrínsecas ao indivíduo isso ajuda a melhorar consideravelmente a segurança no processo de identificação do mesmo.

## 1.1 DEFINIÇÃO DO PROBLEMA

Independente de qual seja o mecanismo de segurança utilizado, sempre surgirá pelo menos um método de ataque para explorar suas fraquezas e dependendo dessas ser bem sucedido ou não. A senha de um usuário pode ser facilmente quebrada se este não possui uma boa política de segurança em relação a ela. A biometria também pode ser contornada como por exemplo os dedos feitos de goma (MATSUMOTO ET AL., 2002) e moldes da mão (CHEN et al., 2005).

Em regra, quanto mais sensível a informação a ser guardada maior e mais intrincado é o sistema de segurança que a protege, tornando assim mais difícil a tarefa de burlá-lo. Uma opção para conseguir aumentar o nível de segurança é a aplicação de um sistema biométrico multimodal para a verificação / validação do usuário.

A multibiometria propõe o uso de características extraídas de duas ou mais biometrias, podendo ser da mesma parte do corpo (como por exemplo: geométrica da mão + veias + digitais e reconhecimento de face + íris) ou não (como forma de andar e orelha). Porém, quanto mais distintas as características mais complexo se torna o processo de fusão das mesmas. Além disso, todas essas possíveis combinações afetam outros pontos, como custo e facilidade de utilização.

Esse trabalho também propõe um método robusto para lidar com o processamento de características da geometria da mão extraídas sem o auxílio de um suporte fixo, ou seja, *touchless*.

## 1.2 MOTIVAÇÃO E JUSTIFICATIVA

A mão de uma pessoa é capaz de fornecer diversos tipos de biometria: geometria dos dedos, geometria da palma, linhas da palma, textura das veias, etc. Fato esse que torna o custo de sistemas multibiométricos baseados no conjunto de características da mão mais baixo, pois com um equipamento apenas é possível realizar todos o processo de reconhecimento biométrico. Diferente por exemplo de um sistema biométrico multimodal que utilize impressão digital e reconhecimento de

íris (PALANIKUMAR et al., 2013). Essa, mesmo sendo a biometria mais confiável torna o custo do sistema mais elevado (LE-QING; SAN-YUAN, 2010).

Além disso, o conjunto de características da mão torna o reconhecimento robusto o suficiente em caso de indivíduos com limitações, por exemplo: deformidades seja ela causada por questões genéticas ou por uma acidente. Ao passo que um sistema biométrico baseado na impressão digital pode ser inaplicável ao tipo de usuário mencionado acima.

Para o presente projeto optou-se pela implementação de um sistema baseado nas características da geometria da mão e da textura das veias e espera-se que a fusão dessas duas características seja suficiente de modo que forneça um resultado confiável sem a adição de outro tipo de biometria.

O sistema biométrico baseado nas veias foi escolhido em detrimento de outro tipo de biometria pelo fato de ser a única biometria da mão que se encontra dentro do corpo e por consequência não é facilmente copiada (FISCHER et al., 2012). E juntamente com a biometria baseada na geometria da mão possui um padrão estável ao longo da vida adulta (NATIONAL BIOMETRIC SECURITY PROJECT, 2008).

Por fim, o sistema criado concentra todas as operações de processamento de imagens, normalização, extração e fusão em um só lugar. Além de prover funções reutilizáveis para sistemas futuros, facilitará a vida de pesquisadores porque em um só sistemas eles tem opção de executar todo o processamento.

## 1.3 OBJETIVOS

### 1.3.1 Objetivo Geral

O objetivo geral inicialmente proposto é um método biométrico multimodal capaz de verificar a identidade do indivíduo através do seguinte conjunto das biometrias extraídas da mão: a geometria da mão e as veias da

palma utilizando fusão em nível de características e máquinas de vetor suporte para aprendizagem.

### 1.3.2 Objetivos Específicos

Dentro do contexto em que se pretende implementar, os objetivos específicos deste trabalho são:

- Criar um algoritmo robusto e abrangente (eficiente para imagens de outros bancos de dados além do utilizado) para extração das características das imagens;
- Concentrar em um só lugar o processamento de imagens, extração e fusão das características da mão;
- Implementar um algoritmo para normalização das características que forneça resultados bons para a biometria da geometria da mão adquirida com dispositivos *touchless*.
- Utilizar Histograma de Gradientes Orientados para a descrição de textura das veias da palma.
- Criar algoritmos com intuito de otimizar o espaço de características, sendo capaz de extrair redundâncias e melhorar o resultado da classificação.
- Analisar os resultados e comparar com trabalhos anteriores.

## 1.4 ESTRUTURA DA DISSERTAÇÃO

Os cinco capítulos desta dissertação estão estruturados conforme a seguinte ordem:

1. Introdução: o primeiro capítulo provê a contextualização do trabalho, a definição do problema, a motivação e os objetivos a serem alcançados;
2. Fundamentação teórica: discorre sobre todos os conceitos relacionados a implementação do projeto. Começando por biometria, passando por sistemas biométricos, processamento de imagens, aprendizagem de máquinas e por fim padrões de projeto;
3. Materiais e Métodos: descreve como o sistema foi construído, o funcionamento do algoritmo de detecção de vales e pontas dos dedos, características geométricas extraídas, funcionamento do histograma de gradientes e a classificação utilizando as máquinas de vetores de suporte ;
4. Resultados e discussão: apresenta os experimentos realizados, a melhora alcançada entre cada um deles e também os gráficos com suas respectivas considerações.
5. Conclusão: o último capítulo apresenta as conclusões e sugestões para trabalhos futuros visando aprimorar o que foi apresentado.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 BIOMETRIA

Biometria é a ciência de estabelecer a identidade de um indivíduo com base em atributos físicos, químicos ou comportamentais da pessoa (JAIN, et al., 2007). Através dela é que se torna possível a construção dos sistemas biométricos, os quais tornam o processo de identificação do indivíduo mais seguro.

Um sistema biométrico é definido como um sistema de reconhecimento de padrões que opera adquirindo dados biométricos de um indivíduo, extraindo um conjunto de características desses dados e comparando-os com um modelo em

uma base de dados (JAIN, et al., 2007). Como esses dados são únicos e inerentes ao indivíduo, a invasão de um sistema torna-se uma tarefa mais difícil.

### 2.1.1 Componentes de um sistema biométrico

Segundo JAIN (2007) Um sistema biométrico é composto por quatro módulos:

- sensor;
- avaliador de qualidade do dados extraídos e extrator de características;
- comparador e tomador de decisão;
- base de dados.

O módulo sensor é responsável pela aquisição dos dados brutos do indivíduo. É um módulo de extrema importância, pois os dados obtidos através dele são o cerne de qualquer sistema biométrico. Uma interface de aquisição (câmera, *scanner*, etc.) de dados de má qualidade, gerará dados ruins (presença elevada de ruídos, baixa resolução, etc) e portanto uma alta taxa de erro de aquisição. Como consequência disso, uma baixa aceitação do usuário do sistema biométrico.

Após a extração dos dados biométricos feita pelo sensor, os mesmos são avaliados para determinar se possuem a qualidade necessária para prosseguir com o processamento. Geralmente esses dados são sujeitos a um algoritmo de melhora (realce) para aumentar essa qualidade.

As características extraídas são comparadas junto a padrões pré-existentes com o objetivo de gerar pontos de correspondência. Esses pontos de correspondência podem ser regulados pela qualidade dos dados biométricos extraídos. Esse módulo também toma decisões com base nos pontos de correspondência para validar a identidade do indivíduo.

Por fim, a base de dados funciona como um repositório de informações biométricas de inúmeras pessoas. Os dados obtidos através do sensor podem ser armazenados juntamente com outras informações, como por exemplo: nome, um número de identificação pessoal, etc.

A figura 1 retrata os componentes mencionados acima.

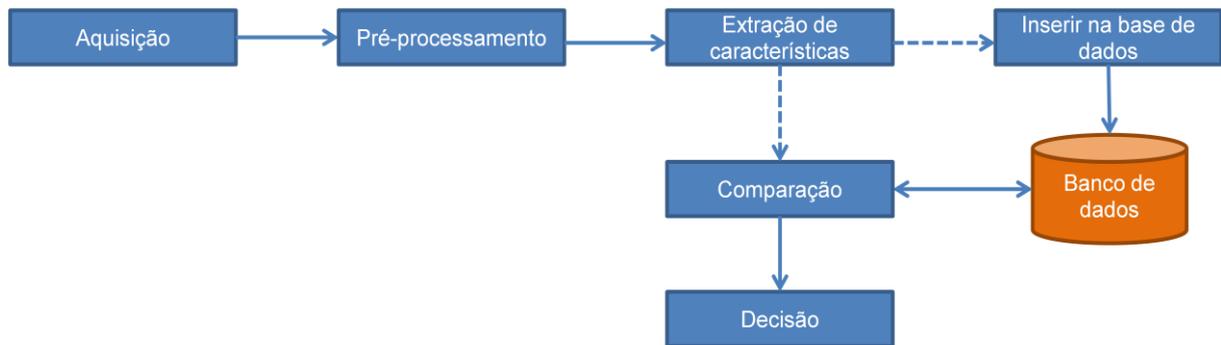


Figura 1. Componentes de um sistema biométrico.

### 2.1.2 Verificação x Identificação

Dependendo da aplicação, um sistema biométrico pode operar no modo de verificação ou no modo de identificação (JAIN, et al., 2007).

No modo de verificação, o sistema biométrico valida a identidade da pessoa comparando os dados coletados pelo sensor com um *template* na base de dados referente à mesma. O indivíduo informa ao sistema um dado como nome de usuário, *personal identification number (PIN)*, dentre outros e o sistema faz uma comparação um-para-um com os dados biométricos coletados e com os dados da base dados com o objetivo de verificar se a pessoa em questão é quem alega ser. A verificação é usada para prevenir que múltiplas pessoas usem a mesma identidade.

Já na identificação, ao invés de ter-se uma relação um-para-um, o sistema busca reconhecer o indivíduo percorrendo todos os registros da base dados procurando por uma correspondência. Diferente da verificação, a identificação funciona apenas com os dados biométricos, sem o uso de senhas, *PINs*, etc e tem como objetivo evitar que uma única pessoa utilize múltiplas identidades. Por fim, a verificação é chamada de reconhecimento positivo e a identificação reconhecimento negativo.

### 2.1.3 Performance de um sistema biométrico

Devido a inúmeros fatores como por exemplo: ruídos externos, sensores defeituosos, variações na interação do usuário com o sensor, dentre outros, raramente uma leitura biométrica do usuário encontrará uma correspondência exata na base de dados, ou seja, variações sempre existirão, seja em posicionamento, fatores externos, aspectos físicos dentre outros.

Essa variabilidade no conjunto de características biométricas de um indivíduo é chamada de variação intra-classe. A variação do conjunto de características proveniente de dois indivíduos diferentes é chamada de inter-classe (JAIN, et al., 2007). Um conjunto de características confiável possui uma baixa variação intra-classe e uma alta variação inter-classe.

O grau de similaridade entre dois conjuntos de características biométricas é definido através de uma pontuação de comparação. A pontuação de ocorrência de similaridade é chamada de autêntica se o resultado da comparação entre duas amostras da mesma característica biométrica pertencem à mesma pessoa. Caso as amostras comparadas sejam de dois indivíduos diferentes a pontuação de comparação é chamada de impostora. Uma pontuação impostora que exceda um limite  $\alpha$  resulta em uma falsa ocorrência, ao passo que uma pontuação autêntica que não ultrapasse o limite  $\alpha$  resulta em uma falsa rejeição (ou falsa não ocorrência) (JAIN, et al., 2007).

Outros conceitos fundamentais são: *False Accept Rate (FAR)*, *False Reject Rate (FRR)* e *Genuine Accept Rate (GAR)*. O primeiro é definido como o percentual de pontuação impostora que excede o limite  $\alpha$ . De modo análogo, o *FRR* é definido que o percentual da pontuação autêntica que está abaixo do limite  $\alpha$ . O último, *GAR*, é definido como o percentual de pontuação autêntica que excede o limite  $\alpha$ . Disso, pode-se concluir:

$$GAR = 1 - FRR. \quad (1)$$

A variação dos valores de  $\alpha$  para *FAR* e para *FRR* pode ser visualizada em um gráfico que plota as curvas de *FAR* e *FRR* para cada valor de  $\alpha$ . Esse gráfico é chamado de *Detection Error Tradeoff (DET)*. A figura 2 exemplifica tal gráfico.

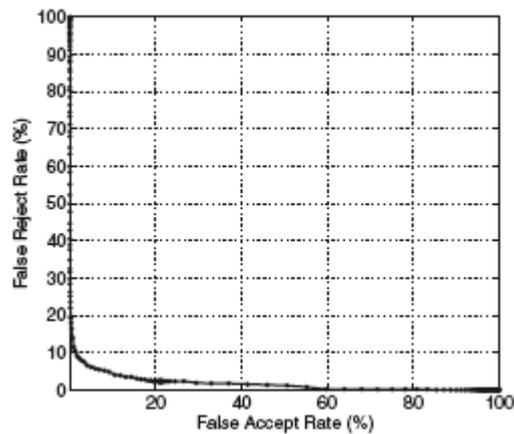


Figura 2. Gráfico Detection Error Tradeoff. Fonte: JAIN (2004)

Outras duas medidas para avaliar o desempenho de um sistema biométrico são a EER e o valor *d-prime*.

O EER é o ponto na curva DET onde se encontram a FAR e a FRR. Quanto menor for o valor do EER melhor é o desempenho do sistema (JAIN, et al., 2007).

A outra medida, o valor *d-prime* é definido como a distância entre as médias da distribuição de probabilidade dos valores autênticos e impostores. É dada pela equação 2:

$$d' = \frac{|\mu_{genuine} - \mu_{impostor}|}{\sqrt{\frac{1}{2}(\sigma_{genuine}^2 + \sigma_{impostor}^2)}} \quad (2)$$

Onde  $\mu$  representa a média e  $\sigma$  o desvio padrão para os valores genuínos e impostores. Quanto maior for o valor de  $d'$ , melhor será a performance do sistema.

A figura 3 exibe um gráfico FAR x Limiar e FRR x Limiar. O ponto onde se encontram é a EER.

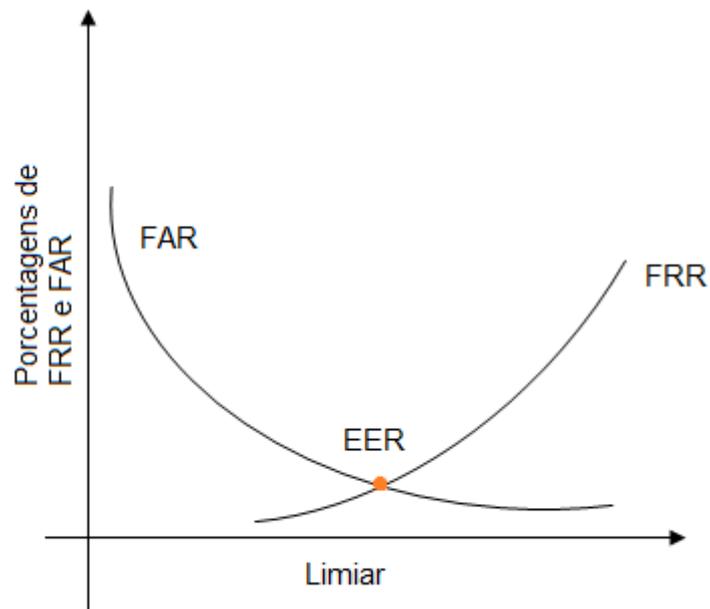


Figura 3. FAR x FRR e ERR. Fonte: O Autor.

Uma alternativa para o DET com o propósito de analisar o desempenho de um sistema biométrico, também muito utilizada, é a curva ROC (*Receiver Operating Characteristic*). Segundo (YANO, 2011) ela representa a relação entre as já mencionadas FRR e FAR. A principal diferença entre este e o já mencionado DET é que no último ambos os eixos são não lineares e construídos a partir dos desvios padrões da FRR e da FAR. Na curva ROC esses dois valores são inversamente proporcionais, o que resulta em um gráfico retratado na figura 4.

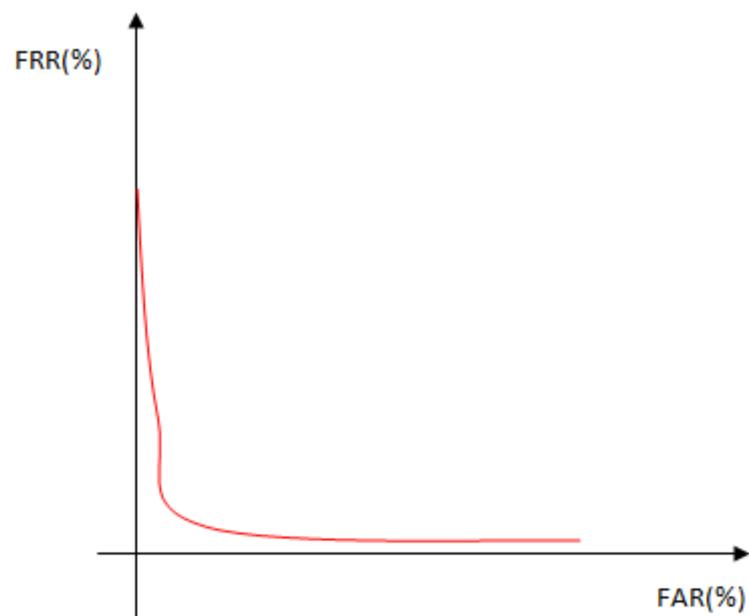


Figura 4. Curva ROC. Fonte: O Autor.

## 2.1 BIOMETRIA MULTIMODAL

Como o próprio nome já indica, o termo biometria multimodal ou multibiometria indica a utilização de mais de uma biometria para o desenvolvimento de um sistema.

Essas múltiplas fontes de dados são combinadas, produzindo assim um resultado único. O processo responsável por juntar todas essas informações é chamado de fusão. Antes de adentrar nos diferentes tipos de fusão e suas características convém ressaltar algumas das vantagens dos sistemas multibiométricos em relação aos sistemas biométricos (JAIN et al., 2006):

- sistemas multibiométricos tem desempenho significativamente superior, pelo fato de combinarem mais uma biometria;
- em algumas situações, a diversificação de fontes de dados melhora o espaço de atributos e reduz limitações de usuários;
- o número de usuários é mais amplo, pois provê alternativas para aqueles que possuem limitações, tornando possível sua utilização;
- aumenta a segurança reduzindo a probabilidade de fraudes;
- é tolerante a falhas, pois caso um sensor falhe ainda existem outros.

Existem outras vantagens mas as elencadas acima já tornam claro porque escolher a utilização de um sistema multibiométrico em detrimento de um sistema biométrico. A seguir os níveis de fusão serão elencados e descritos.

### 2.1.1 Fusão no Nível do Sensor

Esse tipo de fusão baseia-se na combinação de dados brutos de diferentes fontes de informação biométrica. Essa combinação é pode ser feita tanto com o uso

de operações aritméticas como também de operações que utilizam métodos estatísticos.

A Fusão em nível de sensor geralmente é aplicada em uma mesma biometria. Um exemplo de uso é o sensor de alguns *notebooks* que captam a impressão digital fazendo o uso da técnica de combinação em mosaico para captura de múltiplas amostras.

### 2.1.2 Fusão no Nível dos Atributos

A Fusão em nível de atributos consiste em combinar as características extraídas, provenientes de naturezas diferentes, em um único vetor. Logo, para cada indivíduo do sistema existirá um vetor de características atribuído a ele. Algumas desvantagens desse método de fusão são:

- As características podem ser incompatíveis e portanto necessário normalizá-las, o que poderá ocasionar um custo computacional extra;
- Muitas vezes o tamanho dos vetores é variável ou não tem um espaço definido;
- o tamanho do vetor resultante pode ter uma dimensão muita alta.

Diante disso faz-se necessário o uso de normalização dos dados adquiridos para os mesmos estejam em um mesmo espaço. Para um conjunto de características mais próximas podem ser utilizadas técnicas de normalização mais simples (como divisão por um atributo) e quanto mais dispersas forem as características mais robusta deve ser a normalização, por exemplo: *Z-Score* ou *MinMax* (AKSOY, HARALICK; 2000).

### 2.1.3 Fusão no Nível do *Rank*

Essa fusão só é aplicada em sistemas de identificação. É feito um *ranking* dos usuários cadastrados no sistema e a identidade a ser avaliada é associada com a probabilidade do primeiro indivíduo do *ranking*.

Algumas das técnicas empregadas são(HO et al., 1994):

- regra do E ou do OU, onde E confirma a identidade do indivíduo caso todos os algoritmos de comparação retornem verdadeiro ou OU caso apenas um deles retorne verdadeiro;
- voto majoritário: o resultado é dado com base na maioria dos algoritmos de comparação;
- voto majoritário ponderado: cada classificador recebe um peso e o resultado final é dado através da soma ponderada das saídas dos algoritmos.

### 2.1.4 Fusão no Nível de Pontuação

A pontuação é obtida através do nível de semelhança entre uma referência biométrica e um vetor de atributos. Essa pontuação é gerada por diferentes algoritmos comparativos e então consolidadas, produzindo assim uma decisão.

Essa é uma das fusões mais complexas de se realizar. Isso se dá pelo fato da saída dos algoritmos de classificação poderem produzir saídas em escalas numéricas diferentes ou também pelo fato de que alguns algoritmos produzem uma saída com base em correspondência ao passo que outros em não correspondência (JAIN et al., 2006).

Para contornar tal problema utilizam-se técnicas para estimar as probabilidades a posteriori de cada classe dado o padrão de entrada. A saída de cada classificador, ou seja, sua pontuação é considerada como um função de

probabilidade somada de um erro. A partir dessas pontuações é possível estimar-se as probabilidades a posteriori.

## 2.2 PROCESSAMENTO DE IMAGENS

Uma das partes mais importantes do projeto foi o pré-processamento das imagens. Sem essa etapa o projeto não seria possível. É Nessa etapa onde diversos filtros são aplicados com o objetivo de melhorar a imagem, retirando ou amenizando ruídos para que o processamento da mesma se torne possível, apresentado dessa forma um bom resultado final.

Uma imagem digital é uma matriz de *pixels* e esses por sua vez compostos por *bytes*. Um pixel pode ser composto por 1 *bit* e até por 32 *bits* (MICROSOFT MSDN). Depende da profundidade das cores contidas na imagem. Os *pixels* das imagens do presente projeto contêm 24 *bits*, que representam 3 canais de cores de 8 *bits*: vermelho, verde e azul (*Red, Green and Blue – RGB*). Ou seja, para cada pixel processado essa tríade de cores é analisada. Após a aplicação do filtro de binarização os *pixels* passam a ter apenas 1 bit: ou preto (valor inteiro 0) ou branco (valor inteiro 1). Outro exemplo: após o filtro de *Grayscale* o pixel passar a ter 1 *byte* de tamanho sendo 0 o valor para preto e 255 para branco. A Figura 5 é uma abstração do formato *RGB*:

RED								GREEN								BLUE							
23	22	21	20	19	18	17	16	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
7	6	5	4	3	2	1	0	7	6	5	4	3	2	1	0	7	6	5	4	3	2	1	0

Figura 5. Formato RGB de 3 bytes. Fonte: O Autor.

## 2.2.1 Histograma

Antes de adentrar no conceito de qualquer filtro, faz-se necessário introduzir o conceito de histograma, pois ele é a base de inúmeras técnicas de processamento de imagens.

O histograma de uma imagem é um gráfico bidimensional dividido em colunas, que representa a distribuição ou frequência de determinada cor na imagem, ou seja, a quantidade de pixels para cada cor encontrada na imagem. Normalmente utilizam-se os valores *RGB* (*Red-Green-Blue*) de cada pixel para construção do histograma. Um exemplo de histograma pode ser visualizado na figura 6.

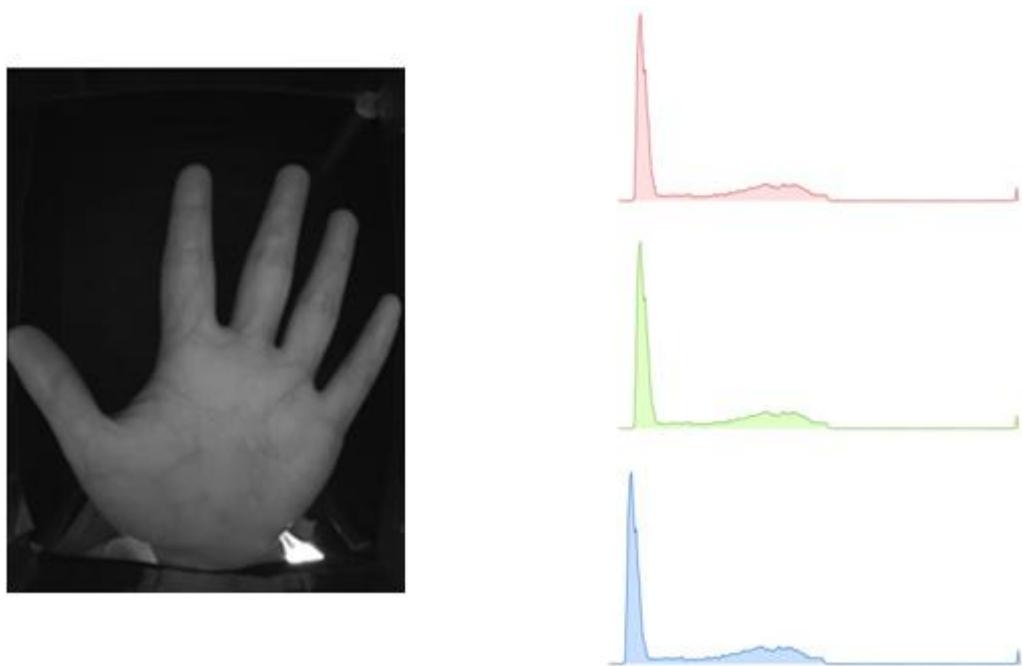


Figura 6. Histograma de imagem colorida. Fonte: O Autor.

## 2.2.2 Binarização

A Binarização (*Thresholding*) ou Limiarização é uma técnica de segmentação de imagens amplamente utilizada devido a sua simplicidade de implementação,

propriedades intuitivas e velocidade computacional (GONZALEZ; WOODS, 2008).

A técnica parte do princípio básico de separar um (ou mais) objeto de um fundo escuro de um modo que a intensidade dos pixels do objeto e do fundo sejam agrupadas em domínios diferentes (GONZALEZ; WOODS, 2008). Para isso um valor de limiar é escolhido para separar esses domínios. A equação 3 modela esse comportamento:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) > T \\ 0 & \text{se } f(x, y) \leq T \end{cases} \quad (3)$$

No presente projeto optou-se por utilizar a limiarização de Otsu (OTSU, 1979), pois diante da diversidade de variações de luz e outros fatores na imagem essa técnica calcula qual o melhor valor de limiar a ser utilizado.

A técnica de Otsu consiste em aproximar o histograma de uma imagem com a utilização de duas funções Gaussianas, escolhendo o limiar com o objetivo de minimizar a variação intra-classes. Essa variação é calculada pela equação 4:

$$\sigma_w^2(t) = \omega_0(t)\sigma_0^2(t) + \omega_1(t)\sigma_1^2(t) \quad (4)$$

Onde  $\omega_0$  e  $\omega_1$  são os pesos das probabilidades de duas classes deparadas pelo limiar  $t$  e  $\sigma_0^2$  e  $\sigma_1^2$  são as variâncias dessas duas classes.

Abaixo a figura 7 ilustra um exemplo de binarização com uma das imagens utilizada no projeto.

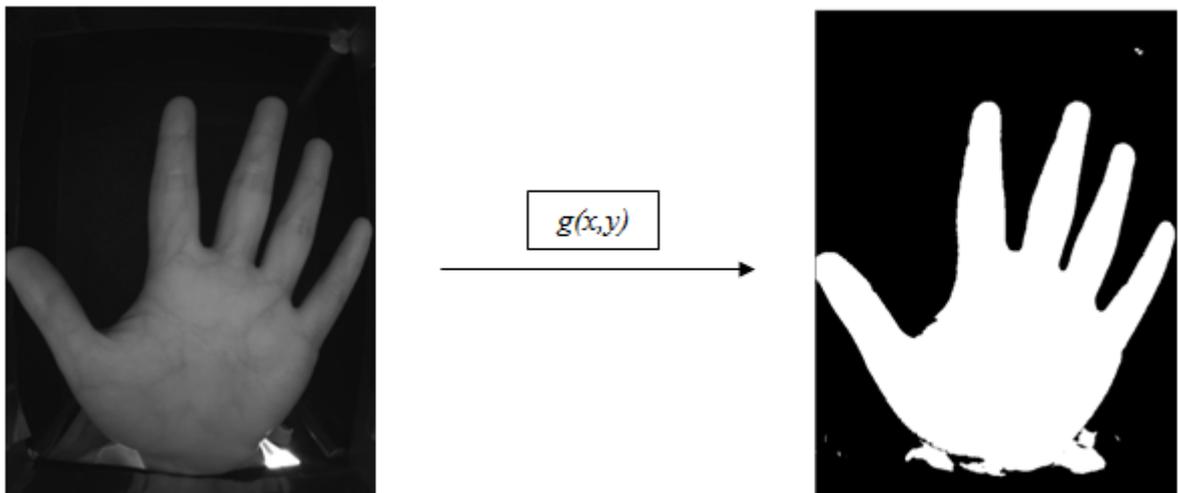


Figura 7. Aplicação da binarização. Fonte: O Autor

### 2.2.3 Detecção de Bordas

O princípio básico da detecção de bordas é baseado na detecção (local) abrupta de mudança da intensidade da cor. Uma das maneiras de obter uma região candidata a borda e a direção da mesma em uma determinada localização da imagem é o gradiente da função  $f$  definido como (GONZALEZ; WOODS, 2008):

$$\nabla f = \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (5)$$

E a direção do vetor gradiente é dada por:

$$\alpha(x, y) = \tan^{-1} \left[ \frac{g_y}{g_x} \right] \quad (6)$$

Dentre os vários métodos existentes o que apresentou o melhor resultado foi do método de *Canny* (CANNY, 1988). O algoritmo de *Canny* consiste nos seguintes passos: (GONZALEZ; WOODS, 2008):

1. Suavizar a imagem de entrada com um filtro Gaussiano;
2. Calcular a magnitude do gradiente;
3. Aplicar supressão em volta do ótimo local com matriz de orientações.
4. Escolher dois valores de limiar e análise de conectividade para juntar a bordas.

Abaixo na figura 8 é possível verificar o filtro de *Canny* aplicado a uma imagem binarizada:

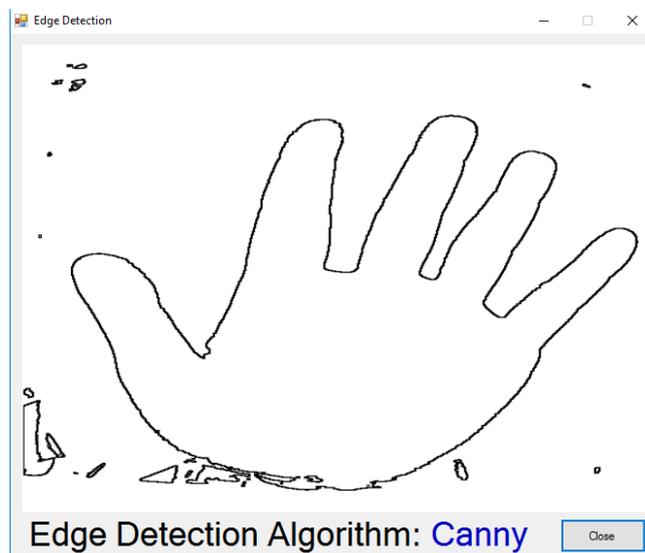


Figura 8. do filtro de Canny. Fonte: O Autor.

É possível notar que a imagem ainda contém diversos ruídos. Logo, faz-se necessário continuar o processamento para que os mesmos sejam atenuados. A última etapa é extrair da imagem a única parte que interessa: o contorno da mão. Para isso o último filtro de extração de contorno é aplicado.

#### 2.2.4 Extração de contorno

Até aqui os filtros utilizados forneceram informações como bordas e regiões

distintas. Mas nenhum deles foi capaz de fornecer maiores detalhes acerca dos dados extraídos. E é justamente onde entra o último filtro: *blob filtering*.

Uma *blob* é uma região da imagem com características específicas. Neste projeto utilizou-se um filtro de largura e altura para os blobs, eliminando assim todos os elementos da imagem menores que esses parâmetros.

O *blob* é obtido através da aplicação do método de Laplace na função Gaussiana (WITKIN, 1983), representada pela equação 7.

$$g(x, y, t) = \frac{1}{2\pi t} e^{-\frac{x^2+y^2}{2t}} \quad (7)$$

Onde os parâmetros  $x$  e  $y$  são as coordenadas da imagem de entrada e  $t$  representa a escala desejada aplicada sobre a imagem de entrada, resultando na forma:

$$L(x, y, t) = g(x, y, t) * f(x, y) \quad (8)$$

Por fim, o resultado do operador Laplaciano, descrito pela equação 9, é calculado o qual terá respostas positivas e negativas, detectando dessa forma os *blobs* (WITKIN, 1983).

$$\nabla^2 L = L_{xx} + L_{yy} \quad (9)$$

## 2.3 MÁQUINAS DE VETORES SUPORTE(SVM)

A máquina de vetores suporte (*Support Vector Machines – SVM*) é uma técnica de aprendizagem de máquinas baseada na Teoria de Aprendizado Estatístico de Vladimir Vapnik (VLAPNIK, 1995). Essa técnica vem chamando a atenção devido aos bons resultados obtidos, e até mesmo superando técnicas tradicionais de aprendizado como por exemplo as Redes Neurais Artificiais (RNAs) em aplicações como categorização de textos (HEARST et al., 1998), detecção de faces (HEARST et al., 1998) e problemas de Bioinformática (ZIEN et al., 2000).

A técnica apresenta características como boa capacidade de generalização, é robusto mesmo para problemas de grande porte (grandes dimensões), convexidade da função objetivo e uma base teórica bem definida e embasada na Matemática e na Estatística (SMOLA et al., 1996b).

Outra ponto a favor da utilização do uso do SVM ao invés de outras técnicas de aprendizagem já consagradas é o fato de o SVM ser computacionalmente mais leve mesmo quando o conjunto de dados de entrada tem uma tamanho significativo (SURALKAR et al., 2012).

O SVM matematicamente é uma função de otimização quadrática, a qual divide o espaço em regiões através de um hiperplano. Cada uma dessas regiões contém as características separadas.

A ideia básica é achar um hiperplano capaz de separar os dados multidimensionais em duas classes perfeitamente separáveis. Porém em problemas do mundo real, dificilmente os dados são linearmente separáveis. (BOSWELL, 2002). Essa definição pode ser observada na Figura 9 abaixo:

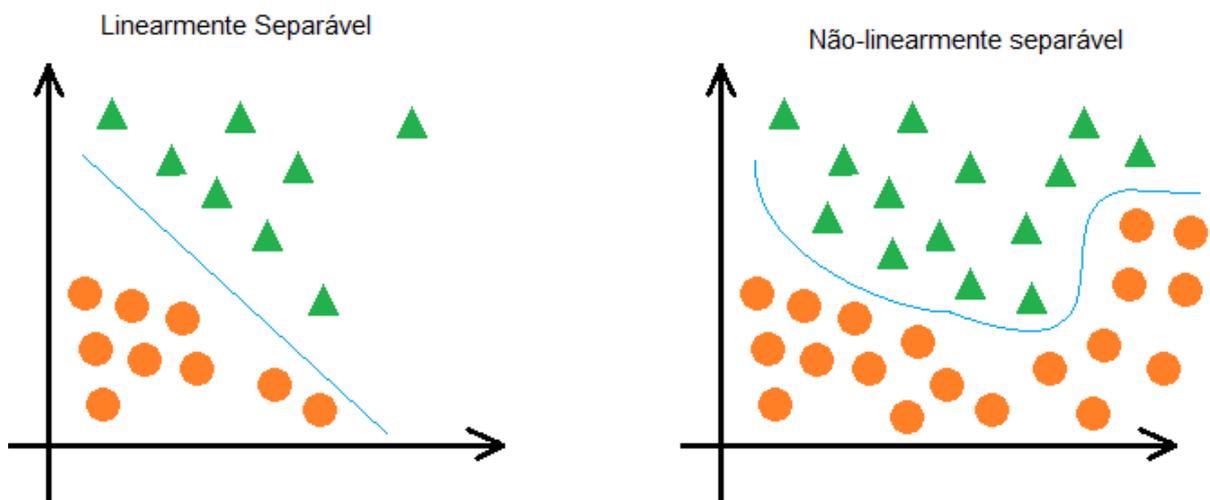


Figura 9. Separação em hiperplanos. Fonte: O Autor.

Para resolver o esse problema, a técnica lança esses dados em um espaço com dimensões maiores onde então é possível separá-los em classes. Esse espaço é chamado hiperplano e é definido pela seguinte equação (MÜLLER et al., 2001):

$$f(x) = w \cdot x + b \quad (10)$$

A equação acima divide o espaço em duas regiões distintas:  $f(x) > 0$  e  $f(x) < 0$ . Então uma função sinal definida como  $s(x) = \text{sign}(f(x))$  é empregada para obter as classificações:

$$s(x) = \text{sign}(f(x)) = \begin{cases} +1 & \text{se } w \cdot x + b > 0 \\ -1 & \text{se } w \cdot x + b < 0 \end{cases} \quad (11)$$

Outro Conceito fundamental é o de margem. A margem de um classificador é a menor distância encontrada entre os dados do conjunto de treinamento e o hiperplano que separa esses dados em classes. A figura 10 ilustra esse conceito.

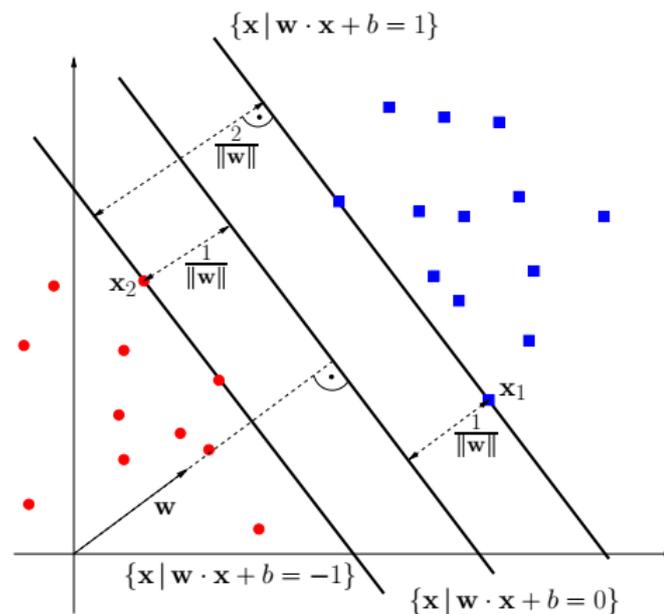


Figura 10. Margens de um classificador. Fonte: O Autor.

O conceito de margem é definido matematicamente como:

$$\rho = \min_i y_i f(x_i) \quad (12)$$

Os vetores suporte são os vetores que estão mais próximos da margem. Ele sozinhos determinam o hiperplano ótimo (SMOLA et al., 1996b).

Quando o problema exige o uso de mais de duas classes (multiclasses) a solução é reduzir o problema para vários problemas de classificação binária. Duas estratégias são usadas para alcançar o comportamento mencionado: *one-versus-all* e *one-versus-one*. Essa, constrói um classificador para cada par de classes e a classificação é realizada pela estratégia de votação pela maioria onde cada classificador vota em uma ou outra classe e no final a classe com maior número de votos é a classificada. Aquela, tem tantos classificadores quanto o número de classes. Ao longo do treinamento uma das classes existentes é fixada e as demais consideradas como outra classe (redução a um problema binário). O valor de saída será o classificador com maior *score*.

### 2.3.1 A biblioteca de funções LIBSVM

A biblioteca LIBSVM foi utilizada no *Matlab* para o processamento dos dados de aprendizagem. Primeiro um arquivo de treinamento deve ser processado. Em seguida um arquivo de testes. Neste projeto foram utilizadas seis amostras (imagem da palma da mão), cinco foram utilizadas para treinamento e uma para testes para cada indivíduo, totalizando 600 amostras.

O arquivo de entrada deve estar no seguinte formato:

```
rótulo: 1:valor 2: valor 3: valor...n:valor.
```

Como por exemplo:

```
001 1:3271.8800 2:285.5612 3:97.0818
002 1:3475.0000 2:275.1363 3:78.5875
003 1:3459.8782 2:288.4009 3:71.8379
004 1:2741.1090 2:244.1803 3:75.6899
```

Após os arquivos serem processados (treinamento e testes) uma saída é gerada na variável *decvalues* (uma matriz 100 x 100 no caso) do *Matlab*. Essa matriz contém os *scores* calculados pelo *SVM* de pertinência à classe. A matriz

utilizada para cálculo e geração das curvas de resposta: FAR, FRR e ROC. A Figura 9 mostra um exemplo dos dados de saída do SVM:

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	-3.6329	-7.1854	-10.9243	-5.6537	-8.3919	-9.7506	-7.0445	-8.1752	-5.5400	-7.4816	-4.3637	-10.4745	-6.
2	-7.8455	0.0812	-11.3799	-11.0889	-3.7264	-6.3896	-5.1539	-9.8260	-7.6250	-7.1836	-2.4283	-9.3390	-8.
3	-6.4093	-8.3887	-1.4047	-6.3338	-6.6356	-6.8606	-4.0583	-10.1844	-4.8381	-6.7173	-5.3845	-5.7447	-6.
4	-5.2393	-8.2445	-7.6190	-2.9227	-8.4026	-9.1492	-7.9676	-5.6098	-5.5106	-6.6894	-6.7523	-7.0393	-6.
5	-7.2524	-6.8011	-7.5688	-7.0017	-3.4144	-6.6931	-6.3540	-7.2948	-6.2315	-7.2127	-6.0047	-5.6875	-7.
6	-8.5377	-6.4869	-6.6889	-7.6144	-5.5884	-1.4402	-4.7479	-9.5437	-8.3076	-4.5996	-8.5278	-3.5631	-7.
7	-6.7733	-4.9110	-5.5191	-7.8910	-5.4911	-4.6043	-1.1649	-12.4406	-8.3951	-5.5630	-6.6263	-6.7181	-8.
8	-6.4829	-6.4279	-8.8287	-7.5342	-6.8872	-6.1656	-5.6768	-3.0309	-6.6441	-7.3762	-8.7656	-4.0493	-5.
9	-4.2886	-8.9568	-4.0664	-4.9302	-6.1819	-8.7339	-6.2448	-9.6640	-1.0193	-3.3596	-7.2362	-7.0910	-7.
10	-4.4632	-7.4260	-5.9696	-6.1556	-5.4703	-6.3087	-4.6748	-9.4283	-6.0673	-2.0741	-5.7482	-6.2463	-6.
11	-4.4739	-5.2895	-7.8333	-7.8996	-3.6351	-7.1656	-2.6321	-10.8845	-6.6913	-6.4686	-1.5909	-8.8857	-6.
12	-9.5244	-9.1712	-12.4817	-9.3077	-8.8476	-5.8303	-11.3992	-6.7571	-7.8682	-10.1473	-17.0078	-0.6353	-8.

Figura 11. Matriz de scores geradas pelo SVM. Fonte: O Autor

## 2.4 PADRÕES DE PROJETO

Um software implementado com base em Padrões de Projeto (*Design Patterns*) é sinônimo de qualidade pois foi construído segundo princípios que possibilitam que o software seja reutilizável e robusto. Mesmo a primeira impressão sendo a de que isso torna o software mais complexo, após o domínio dos padrões de projeto aplicados o que ocorre é o inverso, pois um software bem construído é muito mais fácil de manter e reutilizar (SHALLOWAY; TROTT, 2004).

Esses padrões são divididos em três classes: criacionais, estruturais e de comportamento. O primeiro diz respeito sobre como criar e prover objetos. O segundo fornece padrões sobre como os objetos serão interligados entre si. O último descreve padrões de como os objetos devem se comportar para realizar as tarefas incumbidas a eles.

Os Padrões de Projeto utilizados na implementação do software fruto deste projeto foram 4: *Facade*, *FactoryMethod*, *Singleton* e *Strategy*. Cada um deles será brevemente explicado a seguir.

### 2.4.1 O Padrão *Facade*

O papel deste padrão é fornecer uma única classe que contém diversas outras classes que interagem entre si e desse modo ocultando toda a complexidade dessa interação (GAMMA et al., 2010).

Os detalhes da implementação não são visíveis aos usuários. Caso algum método oculto pela abstração seja requerido é possível disponibilizá-lo através da interface da classe *Facade*.

A figura 12 mostra um diagrama de classes que representa o este padrão:

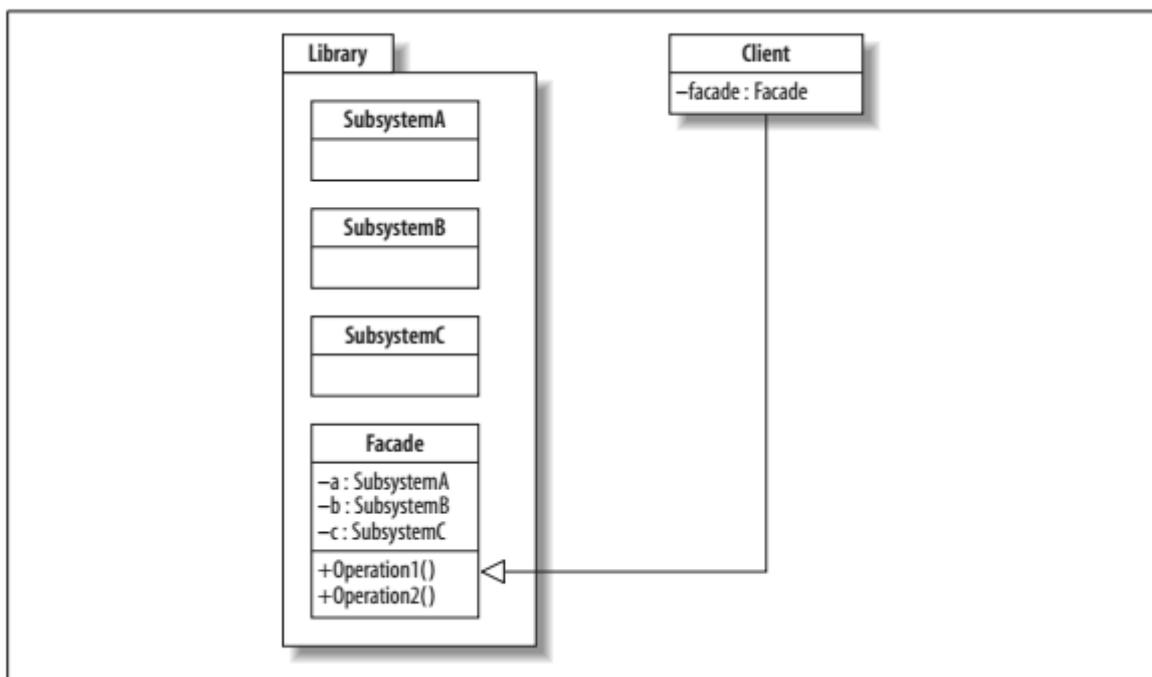


Figura 12. Diagrama UML do padrão Facade: Fonte: BISHOP, 2013.

### 2.4.2 O Padrão *FactoryMethod*

O padrão *FactoryMethod* encapsula a criação de objetos retirando da classe que deseja utilizar o objeto esta responsabilidade (GAMMA et al., 2010).

Além de outros benefícios. Isso faz com que caso ocorra uma mudança no construtor da classe, a alteração no código seja realizada apenas em um ponto e não em cada classe que faz o uso do objeto.

A Figura 13 ilustra esse conceito através de um diagrama de classes.

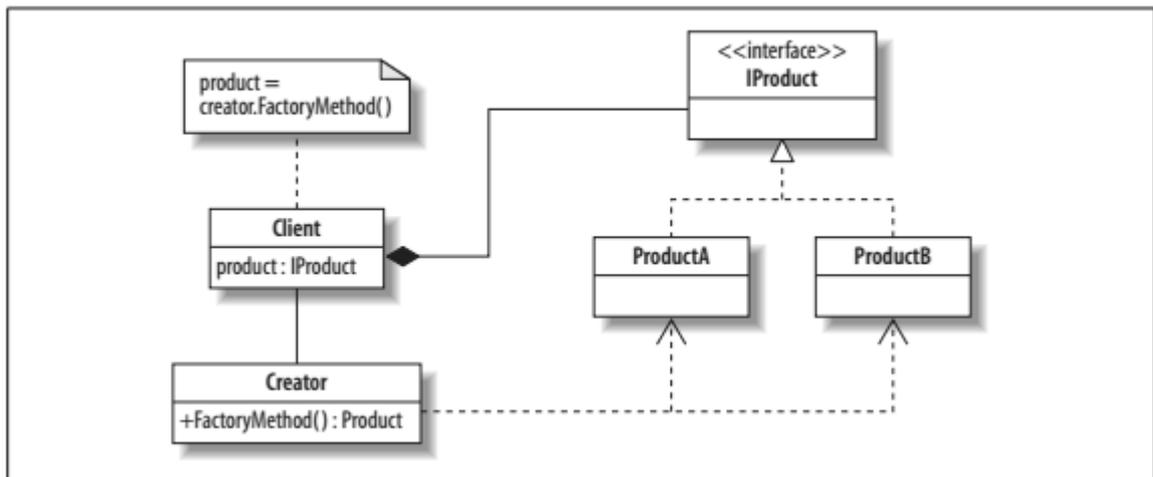


Figura 13. Diagrama UML do padrão Factory Method: Fonte: BISHOP, 2013.

### 2.4.3 O Padrão *Singleton*

Esse padrão garante que apenas uma instância da classe existirá e o acesso a ela será feito através de um único ponto global. E essa responsabilidade é da classe, não do cliente (BISHOP, 2007).

Isso faz com que a classe seja instanciada uma única vez ao longo da execução do sistema e desse modo todas as chamadas a ela serão direcionadas a um único objeto. Também, essa instância só será criada quando o uso da classe for necessário (BISHOP, 2007).

O diagrama de classes do padrão *Singleton* é representado na Figura 14.

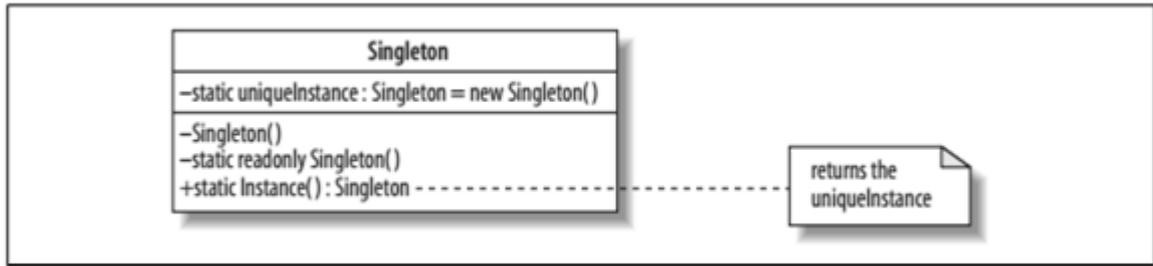


Figura 14. Diagrama UML do padrão Singleton: Fonte: BISHOP, 2013.

### 2.4.3 O Padrão *Strategy*

O último padrão utilizado neste projeto foi o *Strategy*. Este padrão propõe que quando existir mais de um algoritmo a ser aplicado num problema, estes devem estar em uma classe separada e o cliente escolherá o qual utilizar através de uma forma simplificada de acesso (BISHOP, 2013). Isso ajuda a evitar que o código fique bagunçado e cheio de condicionais encadeadas. Além do fato dos algoritmos tornarem-se reutilizáveis e tornaram-se independente do tipo de dados que estão sendo usados. A figura 15 ilustra o diagrama de classes deste padrão.

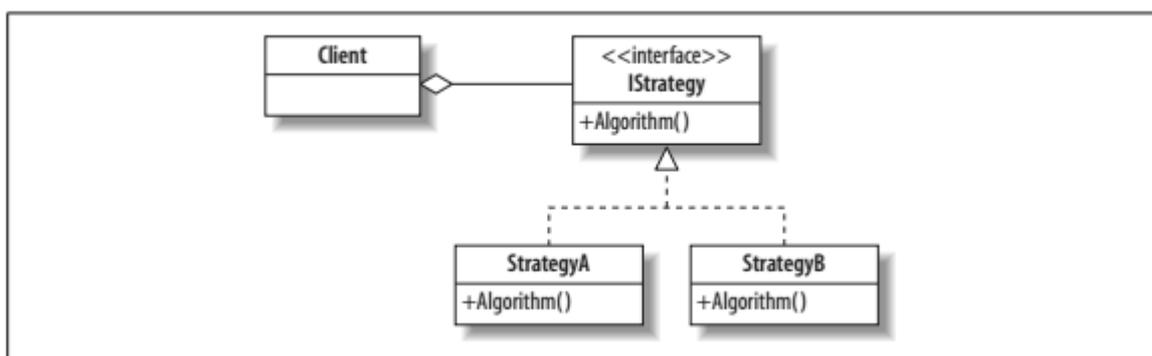


Figura 15. Diagrama UML do padrão Strategy: Fonte: BISHOP, 2013

## 2.5 Histograma de Gradientes Orientados (*HOG*)

O Histograma de Gradientes Orientados (*Histogram of Oriented Gradients - HOG*) é um descriptor de texturas utilizado na detecção de objetos. Foi proposto pela primeira vez em 2005 por (DALLAL; TRIGGS, 2005). Através do *HOG* tanto a aparência quanto a forma de um objeto podem ser descritas pela distribuição dos gradientes de intensidade dos pixels ou pelas direções das bordas (GRITTI et al., 2008).

O Processo é composto por quatro fases. Na primeira calcula-se o gradiente de cada pixel com utilizando máscaras unidimensionais conforme mostra a figura 16:

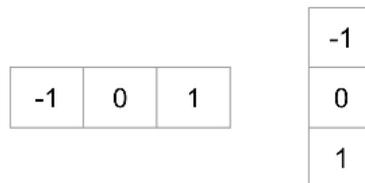


Figura 16. Máscaras unidimensionais para cálculo de gradiente de um pixel.. Fonte: O Autor.

A segunda fase tem como objetivo agrupar os pixels de determinada região, criando assim uma célula. Na terceira etapa essas células são agrupadas em blocos.

Por fim o descriptor (que é uma lista dos histogramas de todas as células e de todos os blocos) é criado (DALLAL; TRIGGS, 2005). A figura 12 demonstra esse processo. Essas estruturas podem ser observadas na figura 17.

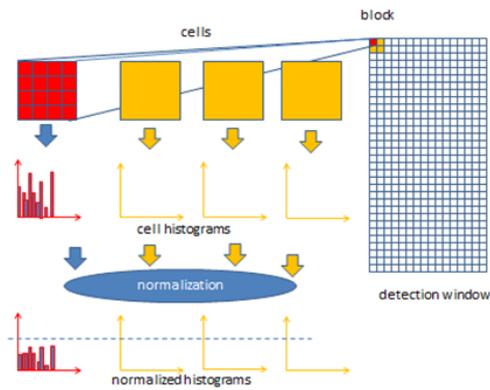


Figura 17. Os blocos e células utilizados no HOG. Fonte: Intel

O Resultado da aplicação do algoritmo *HOG* é apresentado na Figura 12:



Figura 18. HOG aplicado em uma imagem.

## 2.6 ESTADO DA ARTE

Os métodos mais comuns de biometria da geometria da mão envolvem a utilização de pinos e moldes para fixação da mão e assim amenizar as variações como o trabalho de (REILLO et al.; 2000). Nesse trabalho, 200 imagens de 20

peças. Os resultados atingiram a taxa de 97% de acerto na classificação com Modelos de Mistura Gaussiana. Se por um lado a utilização de pinos garante uma menor variação na aquisição das imagens por outro gera desconforto nos usuários do sistema. Por isso, trabalhos mais recentes fazem a aquisição das imagens sem qualquer tipo de suporte para a mão, ou seja, sem contato com uma superfície como por exemplo os trabalhos de (DE SANTOS-SIERRA et al., 2011) e (GUO et al., 2012) e desta dissertação. Por outro lado, o ganho do conforto para o usuário acarreta na dificuldade do processamento, pois as imagens sofrem muitas variações (distância, inclinação, luminosidade, etc).

Essas dificuldades foram analisadas no trabalho de (XIONG et al., 2005), o qual extraiu 37 características para cada dedo com uma base de dados de 108 indivíduos e cinco imagens para cada um. O resultado obtido foi uma taxa EER de 2,41%.

Como este trabalho, diversos outros autores além de usarem a biometria da mão fazem uso de outras biometrias, sendo assim, implementando um sistema biométrico multimodal.

Um sistema biométrico multimodal utilizando características da geometria da mão em conjunto com características tridimensionais da mão como profundidade e intensidade e textura dos dedos foi proposto por (KANHANGAD et al., 2017). O banco de dados continha imagens de 177 indivíduos. Após a fusão das características de todas as biometrias uma taxa EER de 0,22% foi obtida.

Outro trabalho de multibiometria proposto fez o uso de características da geometria da mão junto com o padrão vascular da mesma (KIM, PARK; 2013). Foram coletadas 1300 imagens da lateral e do dorso da mão de 100 pessoas. O resultado obtido com a fusão das características foi uma EER de 0,06%. Cabe ressaltar que este trabalho utilizou suporte com pinos para obtenção das biometrias.

A tabela 1 exibe alguns dos trabalhos mais recentes sobre sistemas biométricos baseados na geometria da mão e também o conjunto de características utilizado pelos autores dentro outros dados.

Ano	Autores	Características Utilizadas	Banco de dados	Taxa de acerto
2011	Xin et al.	Comprimentos dos dedos e da palma, largura dos dedos, mudança angular do contorno, distâncias de pontos base até a vale dos dedos e área dos dedos.	4.000 imagens de 100 indivíduos.	97,84%
2012	Guo et al.	Comprimentos e larguras dos dedos e distâncias do centro da palma até pontos base.	6.000 imagens de 100 indivíduos	96,23%
2013	Gangopadhyay et al.	Vetor resultante da transformada de Radon	300 imagens de 20 indivíduos	96,67%
2014	Singh et al.	Comprimentos e larguras dos dedos e distâncias do centro da palma até pontas dos dedos	480 imagens de 48 indivíduos	95,84%

Tabela 1: Estado da Arte extraídas da geometria da mão.

A tabela 2 exibe alguns dos trabalhos mais recentes sobre sistemas biométricos baseados em descrição de texturas.

Ano	Autores	Técnica	Banco de dados	Resultado
2012	Lee	Gabor-2D Filter com representação <i>bit-string</i>	4140 imagens de 207 indivíduos	EER=0,44%
2014	Abbas e George	Distribuição espacial das médias locais das linhas extraídas que representam as veias	6000 imagens de 500 indivíduos	EER = 0,24%
2014	Wang et al.	Gabor Wavelet	683 imagens de 101 indivíduos	98,88% de acerto

Ano	Autores	Técnica	Banco de dados	Resultado
2014	Elnasir e Shamsuddin	LDA	2000 imagens de 200 indivíduos	EER = 0%
2014	Kang et al.	Algoritmo RootSIFT + LBP	1200 imagens de 100 indivíduos + 1260 imagens de 105 indivíduos	EER = 0,996% e EER = 3,11%
2015	Yan et al.	Algoritmo SIFT com remoção de redundâncias.	3600 imagens de 100 indivíduos + 1260 imagens de 105 indivíduos	EER = 0,16%

Tabela 2. Estado da Arte. Texturas.

### 3. MATERIAIS E MÉTODOS

A base de todos projeto de classificação de imagens é a base de dados. No projeto proposto foi utilizada a CASIA-MS-Palmprint V1.0 (CASIA-MS-Palmprint V1) a ser detalhada no próximo capítulo.

Com o banco de dados formado, o próximo passo foi decidir qual linguagem e frameworks ou bibliotecas a serem usadas. A linguagem escolhida foi .NET C# pois a aplicação desenvolvida foi para ambientes desktop. As bibliotecas externas selecionadas para auxiliar no processamento de imagens foram AForge e Emgu.CV. Para o aprendizado de máquinas optou-se pela libSVM-3.2.1 pois possui bibliotecas para diversar linguagens incluindo uma extensão para o matlab. O software irá processar as imagens, extrair as características da geometria da mão, e das veias da palma. Além disso, normalizar essas características, realizar a fusão das mesmas, classificá-las, decidir e mostrar o resultado.

As etapas do sistema biométrico até antes do escaneamento e extração das características são exemplificadas na figura 19:

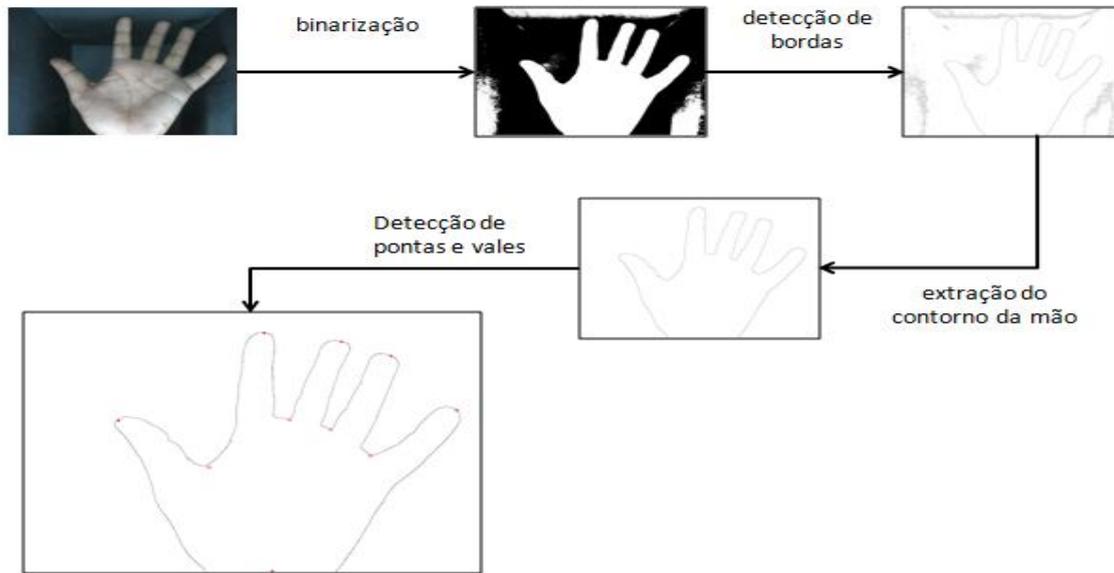


Figura 19. Processamento de imagem da Binarização até detecção dos vales e pontas. Fonte: O Autor.

O processamento prévio da imagem se faz necessário para eliminar ruídos e outros detalhes inúteis, bem como melhorar a qualidade das imagens. Um grupo de imagens selecionadas aleatoriamente será usado para realização de testes com o intuito de validar os métodos e parâmetros escolhidos do algoritmo de processamento de imagens.

Na parte de extração de características, dois conjuntos de características serão extraídos da mão conforme pode ser visualizado na figura 20:

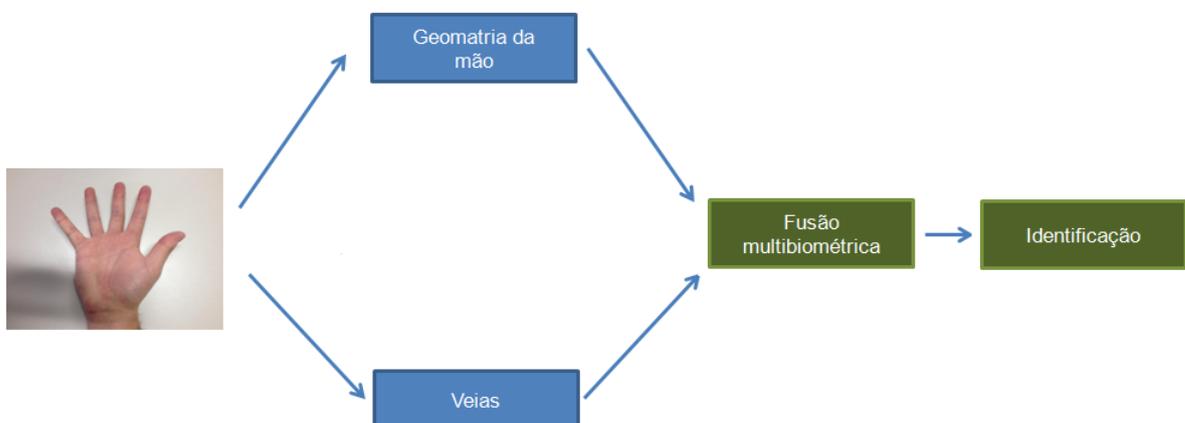


Figura 20. Características utilizadas. Fonte: O autor.

A classificação dessas características para o reconhecimento de padrões foi feita utilizando máquina de vetor suporte através da biblioteca libSVM.

### 3.1 BANCO DE DADOS

O banco de imagens CASIA-MS-Palmprint V1.0 (CASIA-MS-Palmprint V1), fornecido pelo Instituto de Automação da Academia Chinesa de Ciências (CASIA). Contém 7200 imagens, capturadas com um equipamento multiespectral. A resolução das imagens é de 72 dpi com 8 bits de níveis de cinza em formato JPEG. Cada uma das amostras desse banco contém seis imagens para ambas as mãos, as quais foram capturadas ao mesmo tempo mas em diferentes espectros eletromagnéticos. São eles: 460nm, 630nm, 700nm, 850nm, 940nm e luz branca. Fato o qual possibilita a extração de características utilizadas neste projeto: da geometria da mão e das veias presentes nela.

Dentro do universo exposto acima selecionou-se apenas as fotos do espectro de 940nm e da mão direita.

### 3.2 GEOMETRIA DA MÃO

O primeiro conjunto de características são as que podem ser extraídas da geometria da mão. A tabela 3 enumera todas as características que foram extraídas.

Característica	
id	descrição
1	Perímetro da mão
2	Largura da palma da mão
3	Linha Base entre primeiro e segundo vales
[4..18]	Larguras dedo indicador
19	Comprimento dedo indicador
20	Linha Base entre segundo e terceiro vales
[21..35]	Larguras dedo médio
36	Comprimento dedo médio
37	Linha Base entre terceiro e quarto vales
[38..52]	Larguras dedo anelar
53	Comprimento dedo anelar
54	Linha Base entre quarto e quinto vales
55	Comprimento dedo mínimo
[56..70]	Larguras dedo mínimo
71	Distância centro de massa vale 1
72	Distância centro de massa vale 2
73	Distância centro de massa vale 3
74	Distância centro de massa vale 4
75	Distância centro de massa vale 5
76	Distância centro de massa ponta dedo 1
77	Distância centro de massa ponta dedo 2
78	Distância centro de massa ponta dedo 3
79	Distância centro de massa ponta dedo 4
80	Distância centro de massa ponta dedo 5

Tabela 3: Características extraídas da geometria da mão.

### 3.2.1 Ponto de referência

O ponto base para o cálculo e extração das características geométricas escolhido foi o centro de massa da mão. Uma das principais vantagens de adotá-lo ao invés do ponto médio do pulso, por exemplo, consiste do fato de que ele é invariante a rotações e translação (GUO et al., 2012). Fato deveras importante dada a característica *touchless* das aquisições das imagens.

Para calcular o centro de massa da mão fez-se a utilização das equações 8 e 9 para o conjunto de pixels pretos do contorno:

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

$$\bar{y} = \frac{\sum_{i=1}^n y_i}{n} \quad (15)$$

A Figura 21 mostra o centro de massa após calculado e desenhado para as diversas variações de uma mesma pessoa:

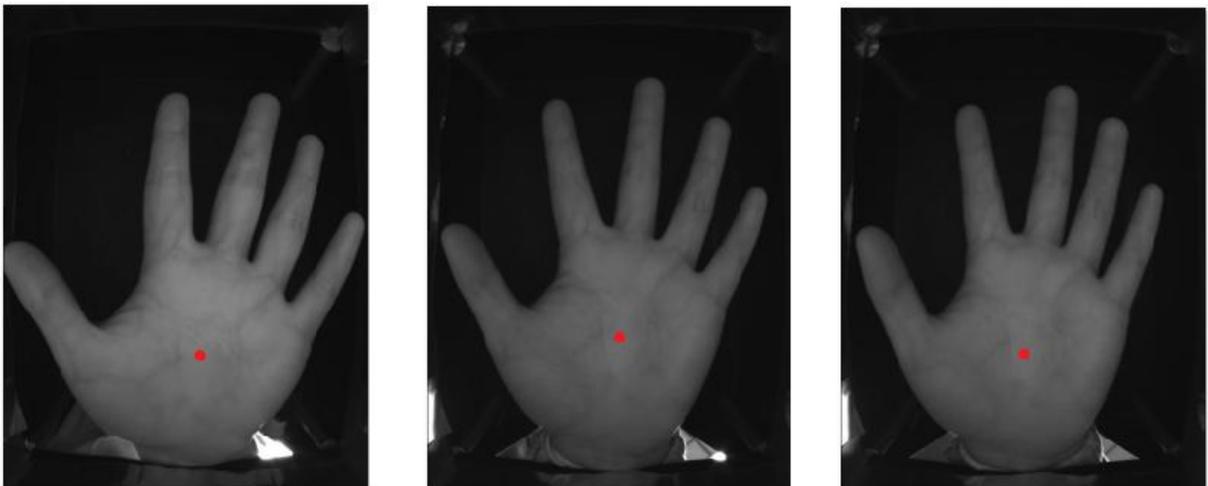


Figura 21. Centro de massa da mão. Fonte: O Autor.

### 3.2.2 Detecção de vales e pontas dos dedos

Após a obtenção do contorno da mão. O primeiro passo foi criar um algoritmo para extração dos vales da mão e das pontas dos dedos. Pontos esses que são os alicerces para que as demais características sejam extraídas.

Um método já consagrado é o *Difference of Slopes* (DOS, DOS+) (O'GORMAN, 1988). Esse método consiste essencialmente em percorrer o contorno da mão com dois vetores de mesmo tamanho e calcular o ângulo formado entre eles. A Figura 22 ilustra esse conceito:

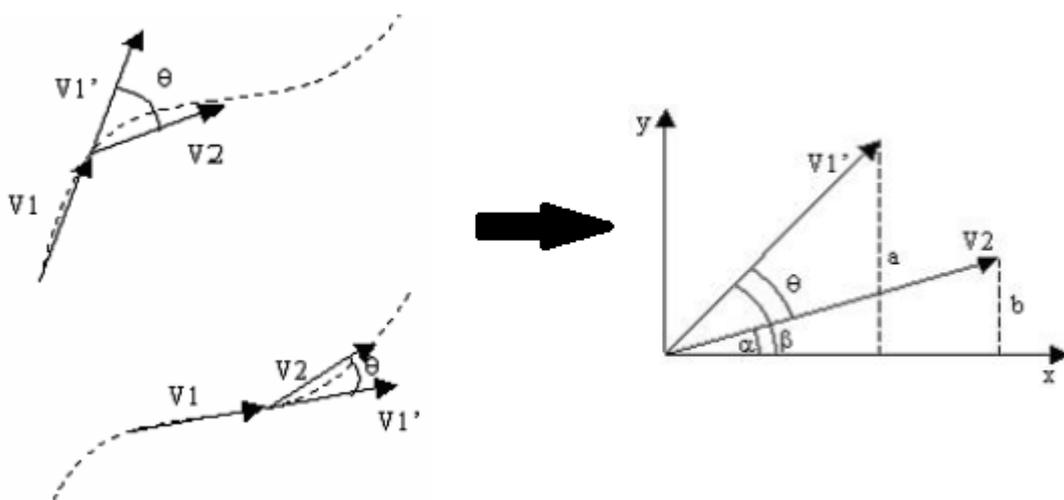


Figura 22. Método DOS+. Fonte BOREKI, 2003

Já o método proposto busca dividir o contorno em regiões distintas e calcular a menor distância entre o centro de massa da mão e cada uma dessas regiões. Esse método será descrito em detalhes mais adiante.

O algoritmo de detecção primeiramente agrupa o contorno da mão em 5 regiões da esquerda para direita. A largura de cada região é definida pela distância existentes entre os dedos: se mesmo encontram-se mais abertos ela é maior. Caso contrário, menor. Essa regiões podem ser observadas na Figura 23.

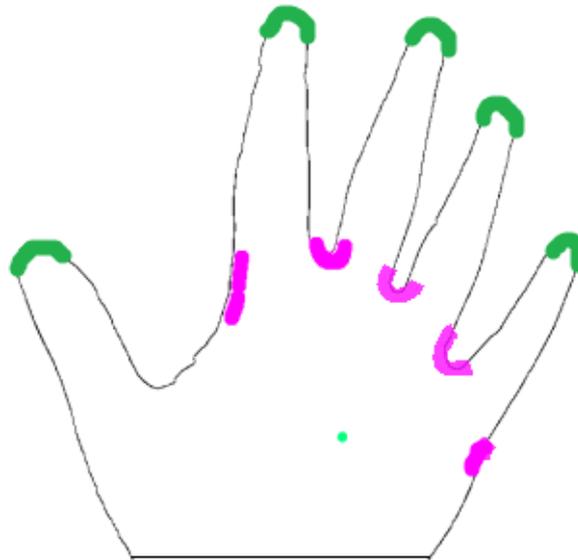


Figura 23. Regiões de extração de pontas e vales. Fonte: O Autor.

Com as regiões definidas e divididas em dois grupos: rosa para vales e verde para pontas o próximo passo é obter a menor distância do centro de massa até que cada uma das regiões rosa para detectar os vales e a maior distância do centro de massa até cada uma das regiões verdes para detecção das pontas.

A fórmula utilizada para o cálculo da distância foi a da distância euclidiana entre dois pontos, representada pela equação 10.

$$d_{(x,y)} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (16)$$

Essas distâncias foram armazenadas em uma estrutura de dados do tipo dicionário, onde a chave é a distância e o valor é o ponto que contém o pixel pertinente ao contorno.

Utilizando a linguagem LINQ (do .NET para manipulação de dados de objetos na memória) essas distâncias (as chaves do dicionário) foram ordenadas de forma decrescente, de modo que as maiores distâncias são colocadas no começo da lista.

A maior distância sempre será entre o ponto de referência e o dedo médio, a partir desse ponto o algoritmo varre todos os outros para a direita dele e para a esquerda também.

Para evitar que pixels vizinhos de um mesmo dedo fossem escolhidos, utilizou-se um limiar inicial de 50 (cinquenta) pixels tanto para esquerda quanto para a direita. Isso garante que somente as maiores distâncias de cada um dos dedos sejam escolhidas. Essas distâncias foram armazenadas em uma lista.

Ao detectar uma ponta de dedo (localidade de maior distância do ponto de referência), uma elipse vermelha de raio igual a 10 pixels é desenhada nesse ponto para que a percepção do mesmo seja identificada de maneira clara.

Para a detecção dos vales, um raciocínio semelhante foi utilizado. Porém de forma otimizada, pois nem todos os pontos precisam ser processados, apenas aqueles entre os limites das coordenadas do eixo das abscissas entre cada um dos cinco pontos que representam as pontas dos dedos. Outro detalhe é que os pontos (armazenados no dicionário) foram reordenados. Dessa vez de forma ascendente, porque procuramos agora as menores distâncias. A figura 24 exhibe o resultado final desse processo:

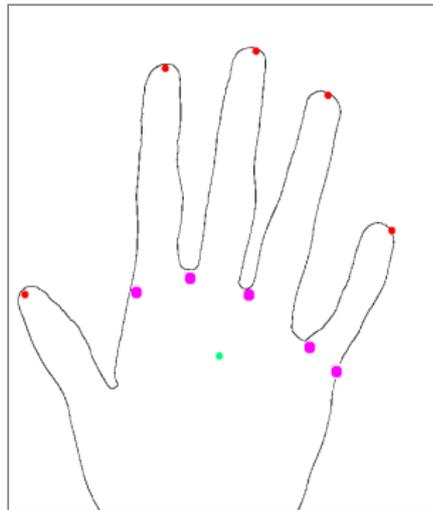


Figura 24. Resultado final da detecção das pontas e vales. Fonte: O Autor

A partir da detecção dos pontos mencionados acima, torna-se possível a extração das características descritas a seguir.

### 3.2.3 Comprimento da palma e linhas base

Estabelecidos os pontos base a próxima etapa é definir a linhas base: a largura da mão da mão e as linhas base de cada um dos dedos menos o polegar.

A linha entre os dedos é uma tarefa fácil, dada um lista com os pontos ordenados pela coordenada do eixo X de forma ascendente, basta traçar uma reta entre o ponto corrente e o próximo.

Para a largura da mão a técnica utilizada foi ( a partir do centro de massa) procurar pela maior distância variando o ângulo de inclinação até o limite que este extrapolasse o primeiro vale. O resultado dessas operações é exposto na figura 25.

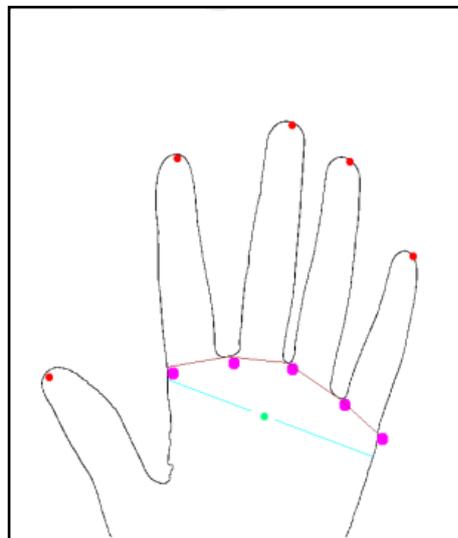


Figura 25. Resultado final das linhas base. Fonte: O Autor.

As cinco medidas extraídas, em ordem da esquerda para a direita com base na figura 25, correspondem aos valores 2, 3, 20, 37 e 54 da coluna “id” da tabela 1.

### 3.2.4 Comprimentos dos dedos

O comprimento dos dedos foi calculado primeiramente obtendo-se o ponto médio entre os dois pontos da linha base e depois calculando a distância euclidiana até a ponta do dedo. A Figura 26 mostra os comprimentos dos dedos calculados e plotados.

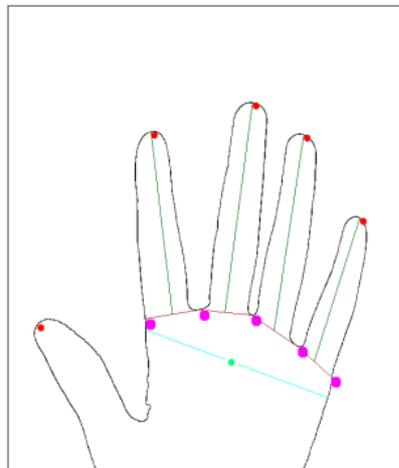


Figura 26. : Comprimentos dos dedos. Fonte: O Autor.

Os comprimentos são os valores 19, 36, 53 e 54, em ordem da esquerda para a direita com base na figura 26, da coluna "id" da tabela 1.

### 3.2.5 Larguras dos dedos

Cada um dos dedos teve (no máximo) quinze larguras extraídas. A partir da linha base dos vales foi calculado o coeficiente angular da mesma para que as linhas de largura seguissem o mesmo padrão. O critério de parada é a coordenada y do ponto representado pela ponta do dedo menos uma distância de 15 pixels ou

então a quantidade de larguras extraídas, que é igual ou menor a quinze. As larguras extraídas podem ser observadas a figura 27.

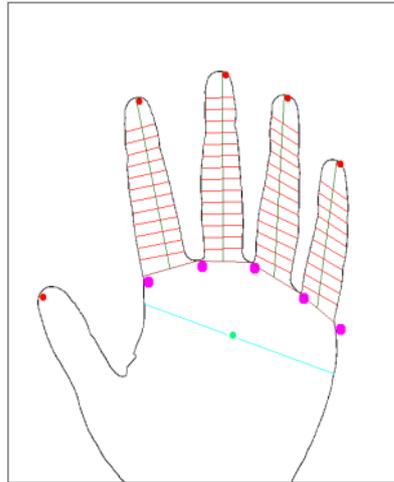


Figura 27. Larguras dos dedos. Fonte: O Autor.

Os comprimentos extraídos correspondem, respectivamente para cada um dos dedos da esquerda para a direita com base na figura 27, aos valores 4 a 18, 21 a 35, 38 a 52 e 56 a 70 da coluna “id” da tabela 1.

### 3.2.6 Distâncias do centro de massa até pontas e vales

Por fim, o último conjunto de características a serem extraídas da geometria da mão foram as distâncias do centro da massa até cada um dos vales e cada uma das pontas dos dedos. Tal distância foi calculada como todas as outras utilizando a equação 16 da distância euclidiana entre dois pontos. O Resultado final é exibido na figura 28.

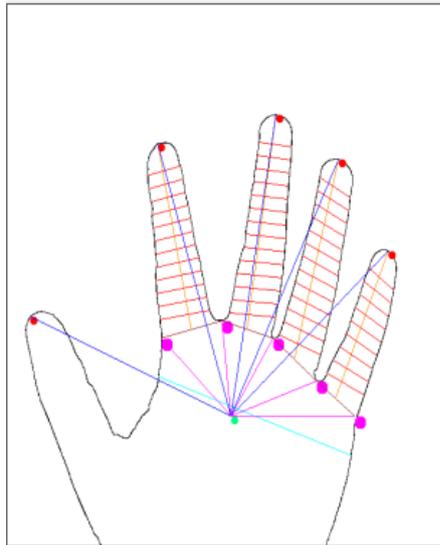


Figura 28. Todas as características da geometria da mão extraídas. Fonte: O Autor.

### 3.2.7 Limitações do Algoritmo de detecção de curvas

Algumas das imagens apresentaram problemas. Três usuários ao tiveram uma das imagens intratáveis com os atuais algoritmos.

O primeiro deles, o usuário com identificação 35, imagem 1 apresentou um problema na aquisição da distância do centro de massa até o polegar devido a imagem de má qualidade. Essa imagem é representada pela Figura 29.

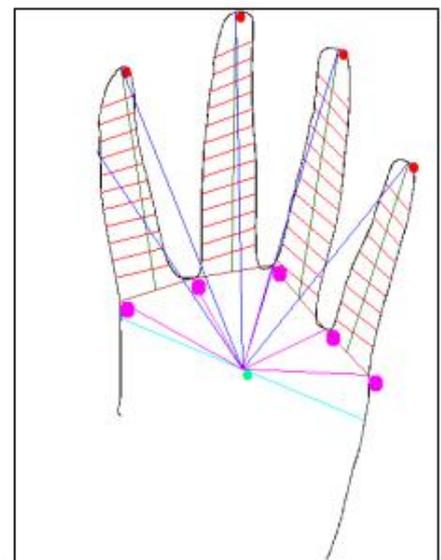


Figura 29. Problema de aquisição: distância do centro de massa até o polegar. Fonte: O Autor.

É fácil de observar que a qualidade da foto deixa muito a desejar, com muita iluminação excedente adicionando ruído.

Outro usuário que apresentou problema foi o com a identificação 39. Parte do dedo mínimo não conseguir ser adquirida de forma satisfatória. A figura 30 retrata essa problema.

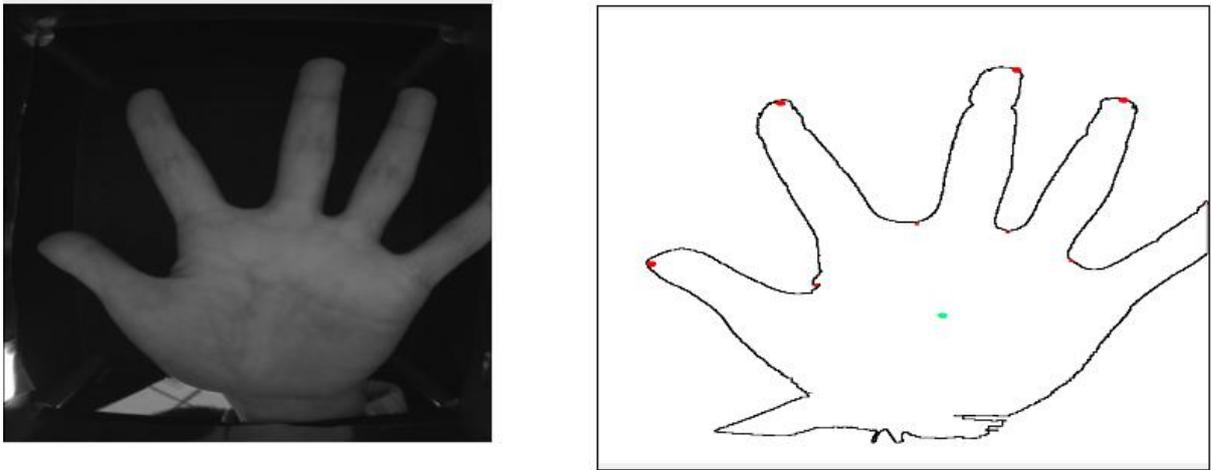


Figura 30. Problema com posicionamento. Fonte: O Autor

Um último exemplo de dificuldade encontrada também com relação a iluminação inadequada é mostrado na figura 31:

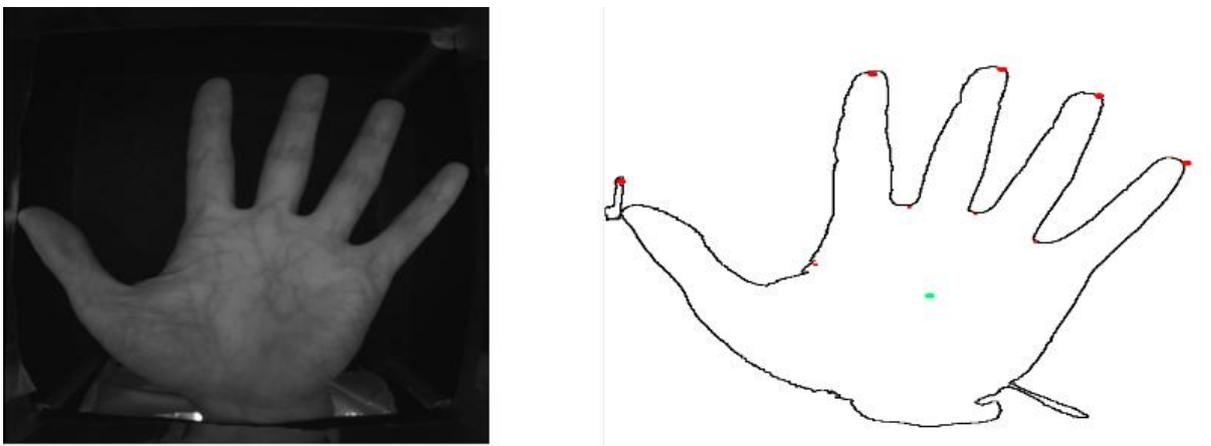


Figura 31. Problema com posicionamento. Fonte: O Autor

Esse problema ocorreu com os usuários de identificação 78. Também é possível observar que a iluminação atrapalhou na qualidade da foto. Esse problema gerou uma medida errônea da distância do centro de massa até o polegar.

### 3.3 VEIAS DA PALMA

O conjunto de características referentes às veias da palma da mão são as texturas da mesma. Essas foram extraídas da Região de Interesse (do Inglês: *Region Of Interest*, ROI) e processadas com o descritor de texturas HOG.

A partir do centro de massa, uma ROI de 160 x 120 foi extraída. Essa dimensão foi obtida gerando um retângulo de tamanho mínimo (10x10) e incrementando os lados até chegar num valor máximo (o mencionado anteriormente) que não extrapole nenhuma das imagens do banco de dados, garantido dessa forma que todas as ROIs conterão apenas imagens com informações relativas a palma da mão. Os parâmetros utilizados foram: células por bloco igual 4x4 e pixels por célula igual 2x2. e o tamanho da célula foi dois. A Figura 32 ilustra uma palma da mão utilizada nesse projeto.



Figura 32. Region of Interest (ROI). Fonte: O Autor.

A representação dessa imagem em blocos de células pode ser visualizada na Figura 33.

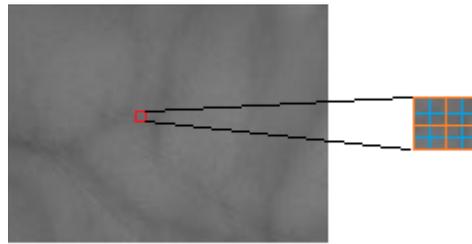


Figura 33. Blocos e células da HOG. Fonte: O Autor.

O processo começa com o carregamento da imagem no sistema, passa pela extração, processamento e normalização da ROI, aplicação do algoritmo HOG e por fim extração do vetor de características que é representado por um vetor do tipo *float*. Esse processo é ilustrado na Figura 34.

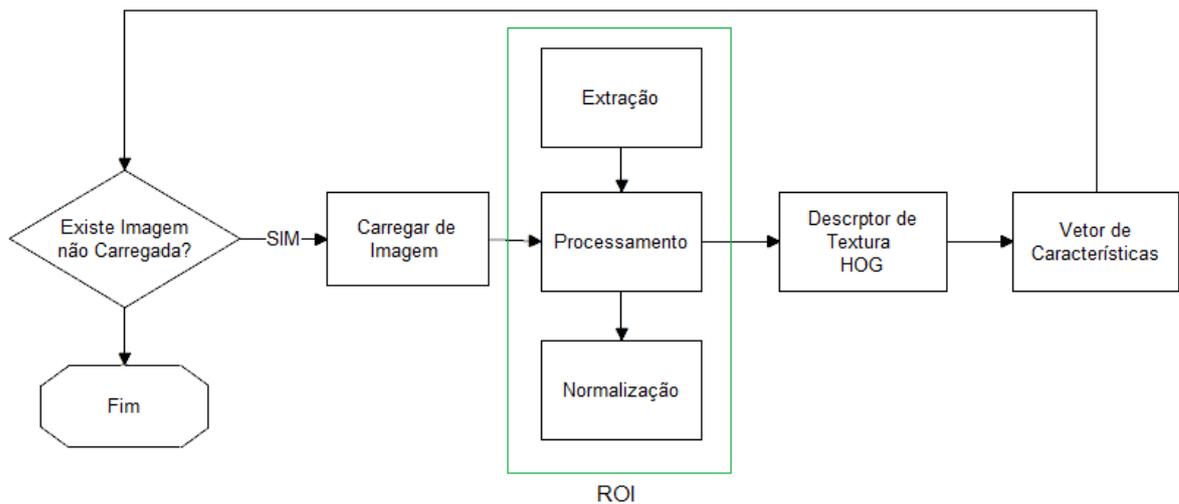


Figura 34. Processamento das veias da palma. Fonte: O Autor.

Por fim, para cada imagem da palma da mão uma imagem correspondente com o descritor de texturas HOG é gerada. Esse resultado é exibido na figura 35.

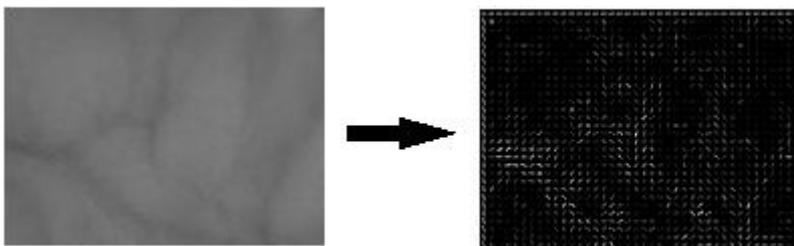


Figura 35. Descritor HOG aplicado. Fonte: O Autor.

### 3.4 O SISTEMA *BIOMETRICSLAB*

Para tornar possível a realização dos experimentos dessa dissertação foi implementado um sistema: o *BiometricsLab*.

Ele foi arquitetado de modo que possa auxiliar os futuros pesquisadores da área de biometria. Para isso, foi desenvolvido não apenas com foco em desempenho e usabilidade mas principalmente na reusabilidade.

No tocante a questões de desempenho, o sistema faz o uso seguro e controlado de *threads*, as quais possibilitam uma execução mais rápida de diversas partes do processamento, seja ele pertinente as imagens ou processamento de fusões e características.

A usabilidade do sistema é bem simples. Todas as operações são acessíveis de dois modos: menus e botões. A tela principal do sistema contém duas abas: uma para geometria da mão e outra para as veias da mão. Além disso, há uma área de informações que exibe as operações que estão sendo realizadas em tempo real e também uma área para notificação de erros caso esses ocorram.

Quanto ao último aspecto, a reusabilidade, este é muito importante porque futuramente o *BiometricsLab* poderá ser estendido com novas funcionalidades facilmente. Como foi projetado com base nos princípios de programação orientada a objetos e padrões de projetos, novos *plugins* podem ser desenvolvidos e facilmente adicionados a ele.

O sistema fornece uma abstração para cada filtro ou função tanto para processamento de imagens como para processos e cálculos referentes a biometria, fato que permite que futuros pesquisadores utilizem suas funcionalidades sem se preocupar com detalhes de implementação.

Uma última característica a ser mencionada é o fato de o software concentrar nele todas as operações necessários ao processamento de imagens requeridas para este projeto, sem a necessidade de utilizar ferramentas externas. E caso novas funcionalidades sejam necessárias ela podem ser facilmente adicionadas ao sistema conforme mencionado acima.

A figura 36 exibe a tela principal do *BiometricsLab*.

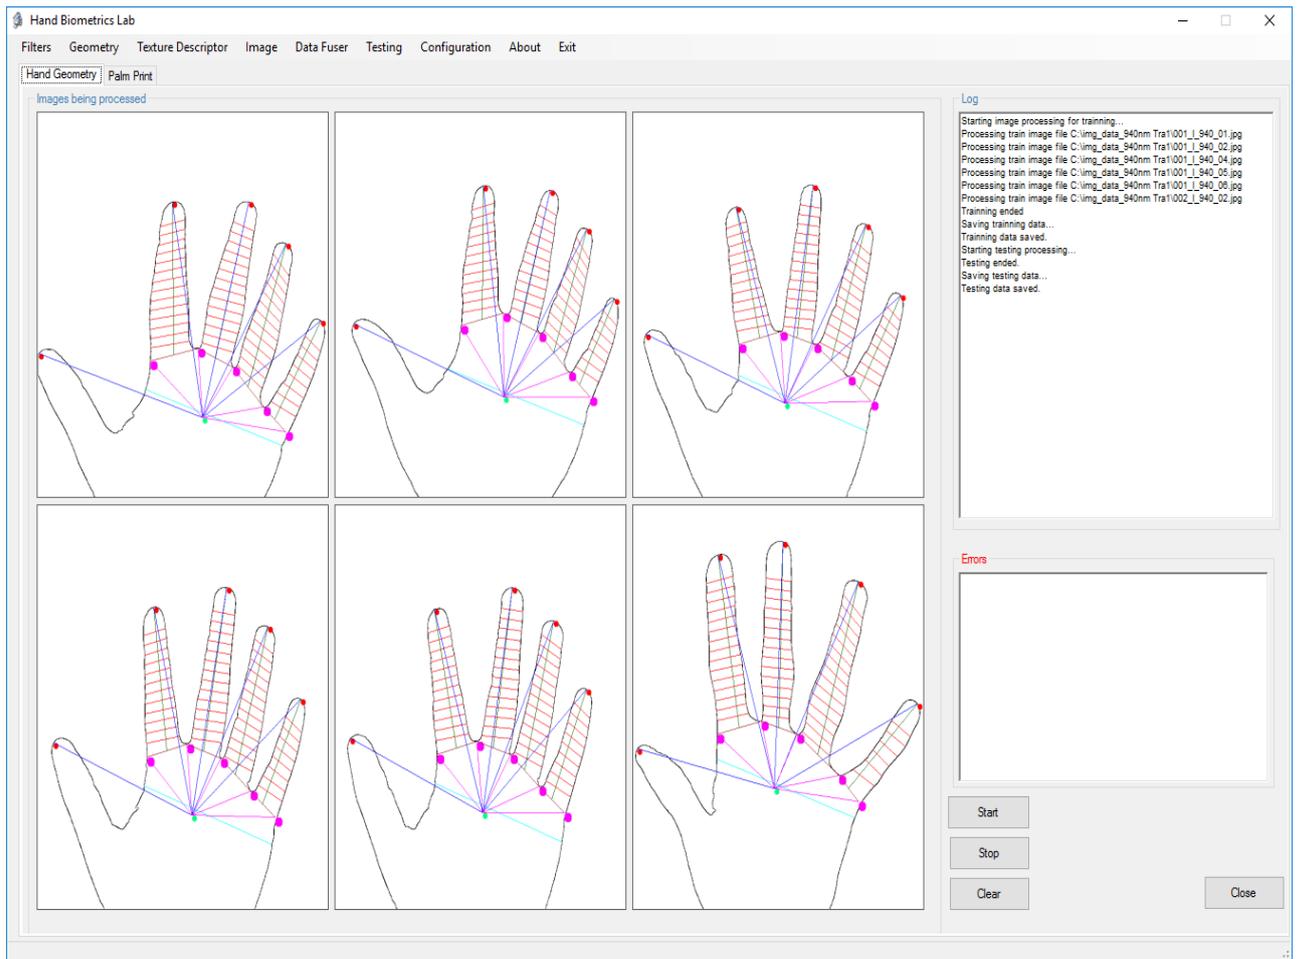


Figura 36. O sistema BiometricsLab. Fonte: O Autor.

### 3.5 NORMALIZAÇÃO DOS DADOS

Como os dados dos dois vetores de características possuem grande variação em relação ao outro, optou-se pela normalização Min-Max que possui bons resultados na normalização de dados para aprendizagem de máquinas (AKSOY, HARALICK; 2000)

A técnica é descrita na equação 17:

$$x_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (17)$$

## 4. RESULTADOS

A seguir serão apresentadas as experiências realizadas que proporcionaram validar o sistema desenvolvido. As experiências começaram com teste mais simples e evoluíram até o teste mais complexo e computacionalmente custoso, o que permitiu verificar o comportamento do sistema de forma gradual. Cada teste bem sucedido significava que o sistema estava pronto para um teste mais robusto com a garantia de estar validado para tarefas mais simples.

Ao todo, três experimentos foram executados:

- 1) Biometria da geometria da mão com normalização por regiões;
- 2) Biometria das veias da palma da mão;
- 3) Multibiometria da geometria + veias da mão

Nas duas primeiras experiências o software desenvolvido carregava primeiro a pasta que continha as imagens para treinamento. Processava-as com a utilização de *threads* e após finalizado repetia a tarefa para o diretório que continha as imagens de testes. A única diferença era que para as duas primeiras experiências, os diretórios relativos a geometria era carregadas assim como somente os *plugins* relativos a essa biometria. Com os dados gerados no padrão de entrada da biblioteca libSVM eles foram salvos em um arquivo. Esse arquivo foi carregado pela libSVM no Matlab para gerar a matriz de saída com os valores de classificação usados para geração da FAR, FRR e ROI.

A fase do experimento envolveu multibiometria com a consolidação os resultados gerados pelos dois processos acima. A fusão das características foi realizada em nível de características concatenando os vetores de resultado das biometria acima mencionadas.

## 4.1 GEOMETRIA DA MÃO COM NORMALIZAÇÃO POR REGIÕES

O primeiro experimento tratou do processamento da características relacionadas a geometria da mão, ao todo foram 80 características como já exposto.

A normalização foi feita de acordo com cada área em que a característica pertencia ou de dimensão próxima. Por exemplo, para o dedo anelar utilizou-se a linha de base desse dedo. Para cada um dos comprimentos dos dedos utilizou-se a largura da palma da mão.

A EER obtida para esse experimento foi 4,77% com 100 usuários e 600 testes realizados. Das 600 imagens disponíveis 500 foram utilizadas para treinamento, sendo cinco para cada usuário e 100 para testes sendo uma para cada usuário. Esse resultado pode ser observado na Figura 37.

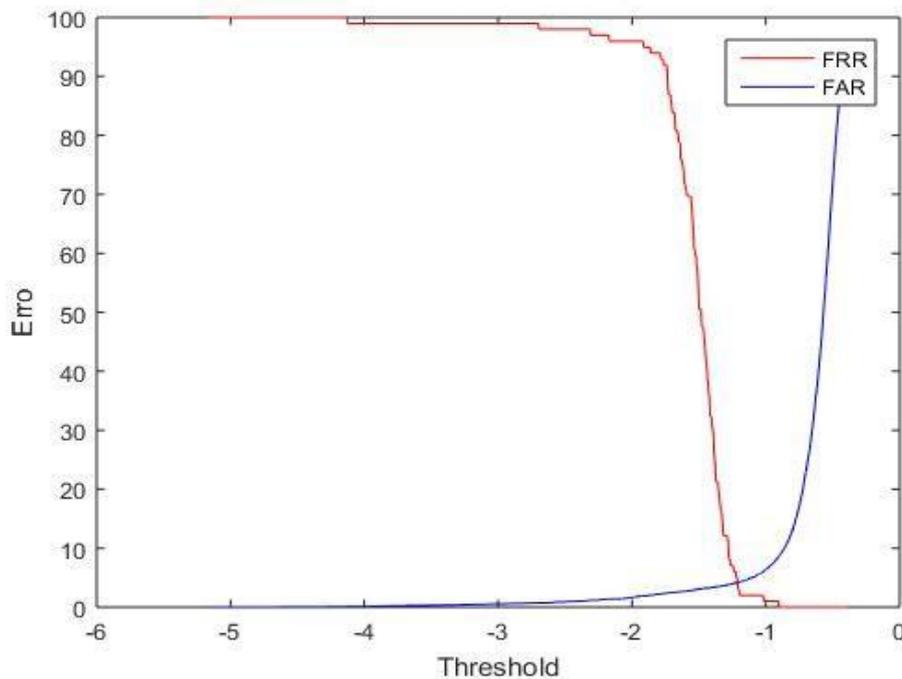


Figura 37. Curvas FAR e FRR com EER para Geometria da mão. Fonte: O Autor.

É fácil de observar que uma pequena variação no limiar altera de forma significativa o desempenho do sistema. Dessa forma inviabilizando a obtenção de maior segurança e detrimento de confiabilidade.

A curva ROC pode ser observada na Figura 38.

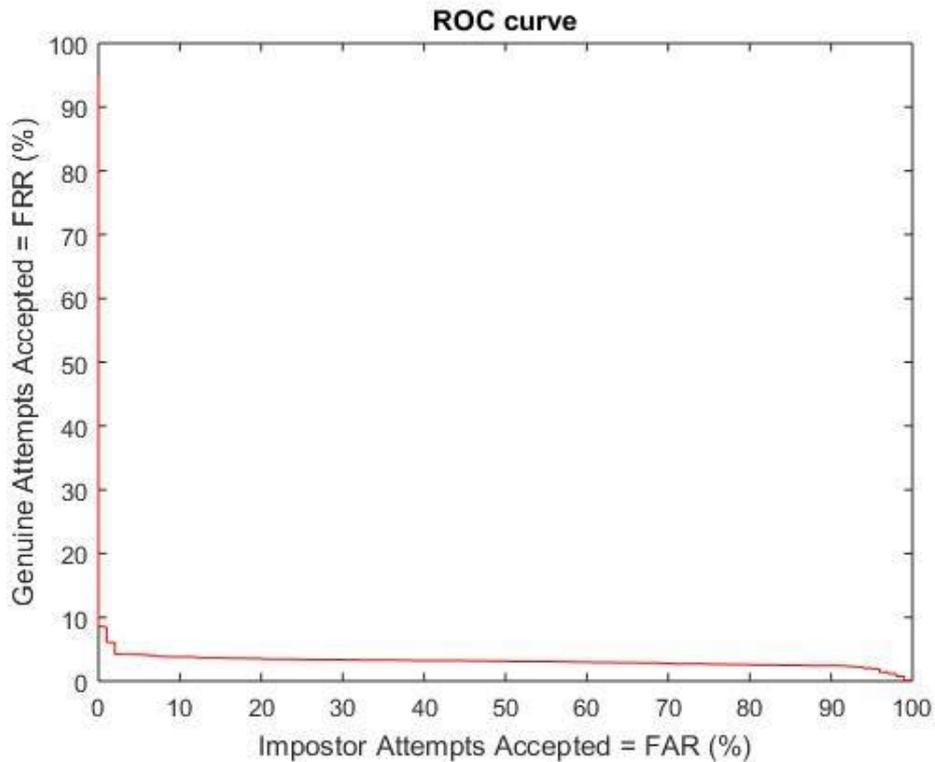


Figura 38. Curva ROC para Geometria da mão. Fonte: O Autor.

Conforme pode ser observado a curva está longe dos eixos do gráfico o que indica que só a geometria da mão não é suficiente para um sistema biométrico confiável para a base de dados CASIA (CASIA-MS-Palmprint V1). Isso se deve ao fato de que as fotos de um mesmo indivíduo possuem grandes variações devido a natureza de aquisição das mesmas. Ao optar pelo modo *touchless* você prioriza o conforto do usuário mas perde em precisão, pois as imagens sofrem variações de distância, inclinação (ângulo) e luminosidade ao passo que sistemas biométricos baseados na geometria com aquisição de imagens com suporte, ou fixos, são menos sensíveis a tais variações. Fato este que contribui para a melhora significativa dos resultados como os apresentados na tabela 2 do capítulo 3.2.

Diante disso, para melhorar a confiabilidade do sistema optou-se por agregar mais uma biometria, a textura das veias da palma da mão.

## 4.2 VEIAS DA PALMA DA MÃO

As veias por si só já apresentaram um resultado melhor do que a geometria da mão. Mesmo assim, a geometria oferece importantes características que auxiliam na distinção do indivíduo, fato o qual justifica a sua utilização.

A EER alcançada para a região de interesse processada foi de 3,11%. Diferente da curva do sistema da geometria da mão, aqui existe a possibilidade variar o limiar para obter melhor segurança e aumentar a taxa de fala rejeição já que a variação das curvas é mais suave após a intersecção. Por exemplo, para uma FAR de 0,5% temos uma FRR de 4,82%. As curvas podem ser visualizadas na figura 39.

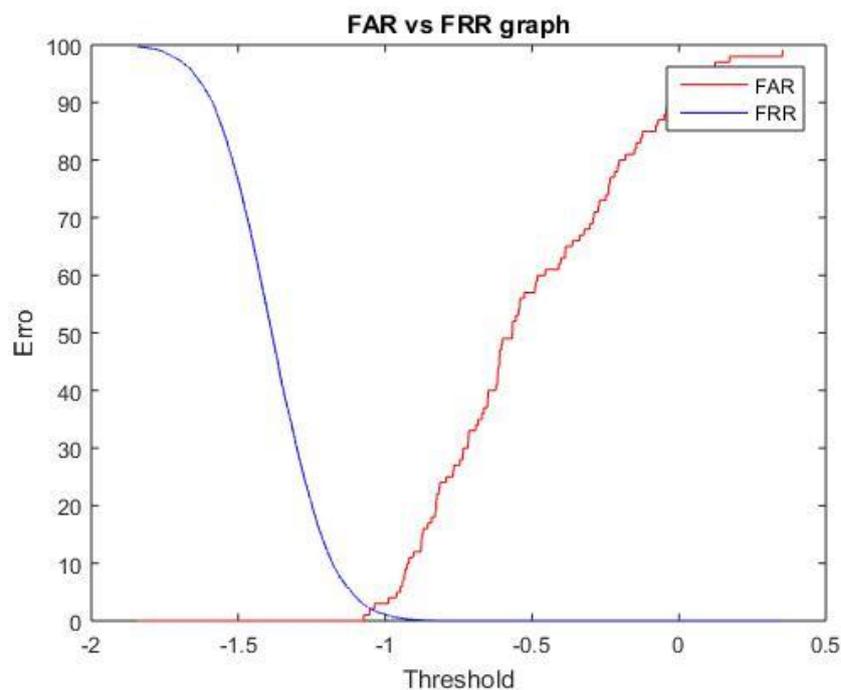


Figura 39. Curvas FAR e FRR com EER para veias da palma da mão. Fonte: O Autor.

A curva ROC é mostrada na figura 40

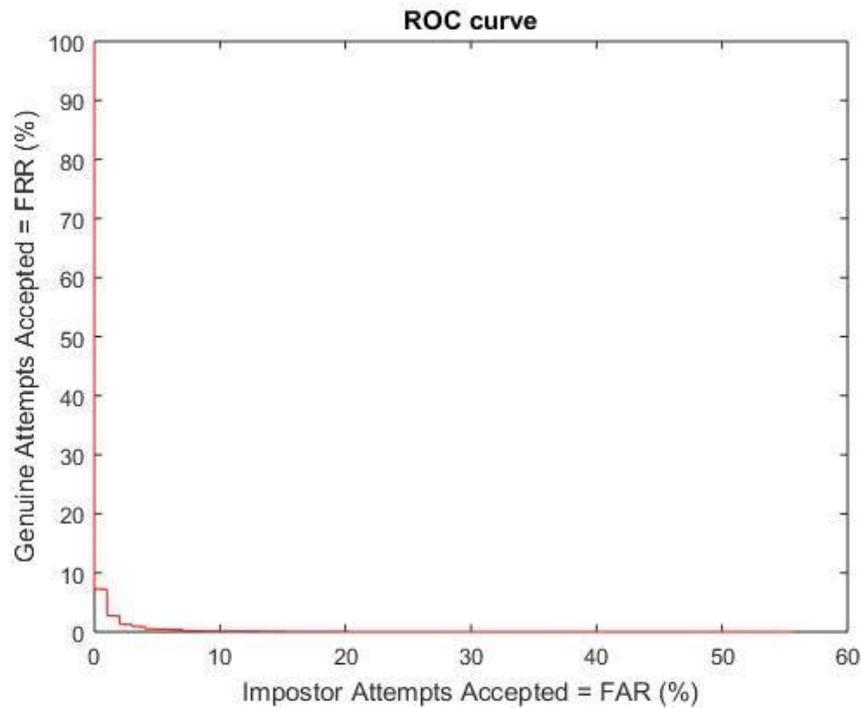


Figura 40. Curva ROC para veias da palma da mão. Fonte: O Autor.

### 4.3 FUSÃO DA GEOMETRIA COM AS VEIAS DA PALMA DA MÃO

O último experimento consistiu em juntar as duas biometrias mencionadas previamente. Realizou-se a fusão no nível de características com a normalização Min-Max. A EER obtida foi 2,33%. Alterando o valor do limiar é possível obter uma FAR de 1,30% e uma FRR de 4,27%. A fusão permite alterar o limiar e obter uma melhor FAR em detrimento da FRR de uma forma mais suave se comparado ao experimento anterior. As Figuras 41 e 42 mostram este resultado.

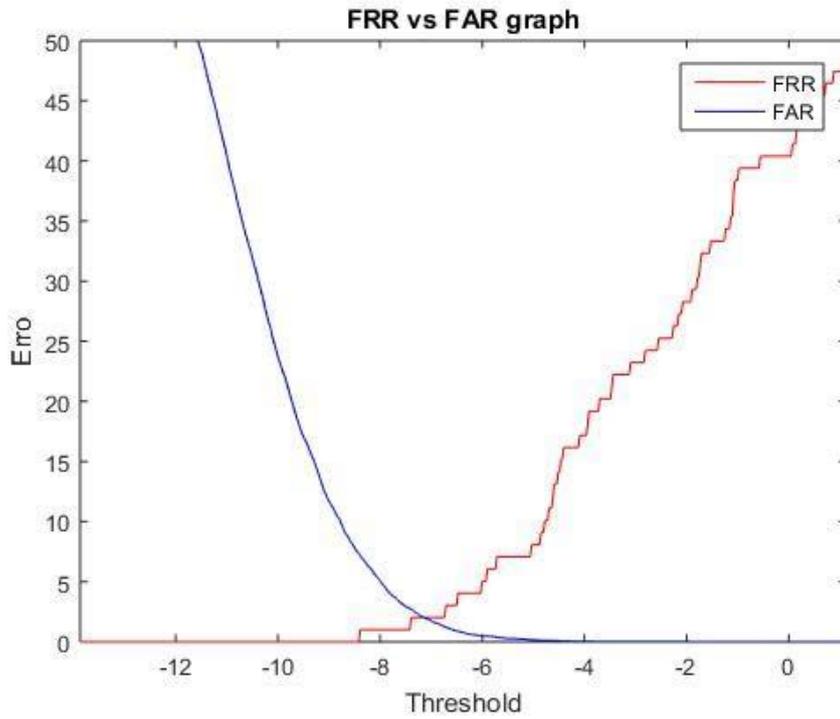


Figura 41. Curvas FAR e FRR com EER para veias da palma da mão e geometria da mão com fusão por características. Fonte: O Autor.

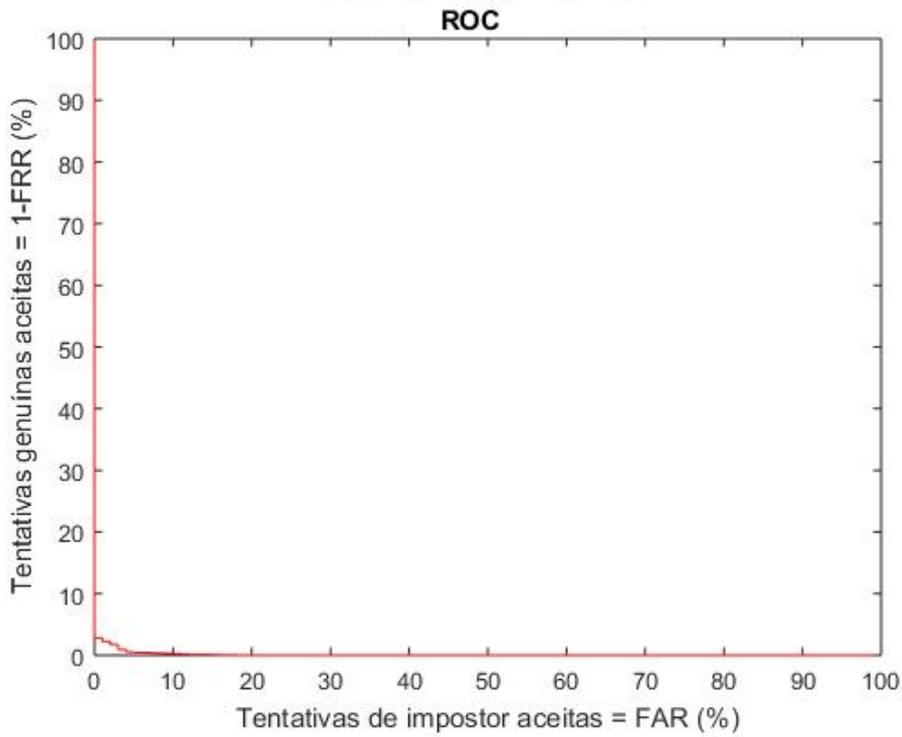


Figura 42. Curva ROC para veias da palma da mão e geometria da mão com fusão por características. Fonte: O Autor.

Esses foram os resultados obtidos utilizando técnicas e métodos diferentes dos propostos pelos autores mencionados na seção 3. Outro ponto a considerar é que o resultado final foi bom considerando apenas duas formas de biometria para o sistema multimodal. Sendo assim, uma terceira biometria muito pouco ou nada teria a acrescentar a não ser complexidade. A tabela 4 mostra um resumo dos experimentos realizados e seus respectivos resultados.

<b>Experimento</b>	<b>Taxas</b>
Biometria da Geometria da Mão	EER = 4,77%
Biometria das Veias da Mão	EER = 3,11% FAR = 0,5% FRR = 4,82%
Biometria da Geometria + Veias	EER = 2,33% FAR = 1,30% FRR = 4,27%

Tabela 4 - Resultados

## 5. CONCLUSÃO

Para que se possa diminuir a possibilidade de fraude em um sistema o uso de mais de uma biometria é uma alternativa viável. Ao extrair-se características de diversas fontes o sistema se torna mais seguro e menos suscetível a ataques bem sucedidos. Além de outras benesses como possibilitar a inclusão de indivíduos com limitação físicas.

A primeira inovação que pode ser percebida foi o método proposto para extrair os vales da mão e as pontas dos dedos. Ele obteve bons resultados com a base utilizada (CASIA). Não só se mostrou confiável e robusto como apresentou um bom desempenho computacional.

A segunda, ainda pertinente a geometria da mão, foi a quantidade de características extraídas, onde procurou-se esgotar as possibilidades de extração dessa biometria, ao todo foram 80 características que englobam a palma e os dedos bem como distâncias que utilizam ambas. A classe responsável pela extração das características contam com mecanismos tolerantes a falha, caso a característica não consiga ser extraída.

A biometria das veias da palma também contou com um método diferente dos já utilizados (Capítulo 3.3) para extração das texturas das veias, o Histograma de Gradientes Orientados. Tal método mostrou-se eficiente na descrição das texturas da veias como pode ser observado no capítulo 4.3.

Ao propor um sistema biométrico multimodal baseado nas biometrias da geometria da mão e das veias da palma da mão uma outra preocupação foi a de não só projetar um sistema capaz de ser reutilizável por outros pesquisadores mas também torná-lo extensível a novas funcionalidades e biometrias. O sistema facilitará trabalhos futuros dos pesquisadores da área de biometria, concentrando nele todas as tarefas pertinentes ao processamento de imagens sem a necessidade de recorrer a outros softwares como o *Matlab*.

Os resultados obtidos foram satisfatórios e em alguns casos melhores do que alguns já alcançados como pode ser conferido comparando-os com os das tabelas 3 e 4 do capítulo 3.

### 5.1 CONTRIBUIÇÕES

O legado deste projeto pode ser dividido em dois temas distintos. O primeiro diz respeito às técnicas e métodos utilizados para a obtenção do resultado. O segundo é o sistema que foi desenvolvido e a disponibilização de suas bibliotecas.

No que concerne às técnicas utilizadas, a normalização dos dados por regiões mostrou-se promissora pois trata características de um mesmo grupo de forma consistente e assim dando maior estabilidade aos dados. O *HOG* mostrou-se eficaz na descrição das texturas das veias da palma da mão, deixando um caminho certo para futuras pesquisas que queiram utilizar esse descritor em trabalhos de biometria.

A última contribuição é o *BiometricsLab*. O sistema foi criado tendo em mente desde início de seu projeto a reutilização e a facilidade de extensão para inclusão de novas biometrias e funcionalidades. É um sistema *multithreading* e como consequência possui excelente desempenho. Caso futuros pesquisadores optem por não querer utilizar a interface gráfica dele, podem fazer o uso apenas de suas bibliotecas, as quais podem ser facilmente adicionadas em outros projetos que utilizem a linguagem C# e são de fácil entendimento por possuírem interfaces que descrevem os métodos disponíveis nas classes. Além disso, todas as fases que englobam o processamento das imagens, extração das características e a fusão das mesmas encontram-se em apenas um ambiente. Facilitando assim o trabalho de pesquisa.

## 5.2 TRABALHOS FUTUROS

Para que resultados ainda melhores possam ser obtidos algumas ideias para trabalhos futuros são sugeridas:

Realizar outros tipos mais complexos de fusão, como por exemplo fusão por nível de decisão

Implementar segmentação dinâmica com erosão e recuperação.

Testar outras formas de normalização de dados

Otimizar o vetor final de características com métodos que localizem redundâncias e também características não importantes atribuindo a elas pesos.

Testar outros métodos de aprendizagem de máquinas como por exemplo *Deep Belief Networks* e *Quadratic Discriminant Analysis*.

## REFERÊNCIAS

ABBAS, Asmaa M. J.; GEORGE, Loay E. "Palm Vein Recognition and Verification System Using Local Average of Vein Direction", International Journal of Scientific & Engineering Research, Vol. 5, No. 4, pp. 1026-1033, 2014.

AKSOY, S.; HARALICK, R. "Feature normalization and likelihood-based similarity measures for image retrieval," Pattern Recognit. Lett., Special Issue on Image and Video Retrieval, 2000.

BISHOP, Judith. C# 3.0 Design Patterns. First Edition. O'Really, 2007.

BOREKI, Guilherme. "Sistema de Controle de Acesso por IButton com Verificação Biométrica da Geometria da Mão". Dissertação (Engenharia da Computação) - Centro Universitário Positivo, Curitiba, 2003.

BOSWELL, D. (2002). Introduction to Support Vector Machines.

CANNY, John. "A Computational Approach to Edge Detection", IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 8, pp. 679-98, 1986.

CASIA-MS-Palmpoint V1. Disponível em: <http://biometrics.idealtest.org>

CHEN, Hong; VALIZADEGAN, Hamed; JACKSON, Carrie; SOLTYSIAK, Shannon, JAIN, Anil K. "Fake Hands: Spoofing Hand Geometry Systems", The Biometric Consortium Conference, pp. 2-3, 2005.

DALAL, N.; TRIGGS, B. Histograms of Oriented Gradients for Human Detection. In: 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 886-893, 2005.

DE SANTOS-SIERRA, A. et al. Unconstrained and contactless hand geometry biometrics. Sensors, 11, pp. 10143-10164, 2011.

ELNASIR, Selma; SHAMSUDDIN, Siti Mariyam." Palm Vein Recognition based on 2D-Discrete Wavelet Transform and Linear Discrimination Analysis", International Journal of Advances in Soft Computing and its Application, Vol. 6, No. 3, pp. 43-59, 2014.

FISCHER, M.; RYBNICEK, M.; TJOA, S. "A Novel Palm Vein Recognition Approach Based On Enhanced Local Gabor Binary Patterns Histogram Sequence",

International Conference on Systems, Signals and Image Processing, pp. 429-432, 2012.

FREEMAN, E. ROBSON, E.; BATES, B.; SIERRA, K. Head First Design Patterns. O'Reilly Media, 2004.

GAMMA, E., HELM, R., JOHNSON, R., VLISSIDES, J. Design Patterns: Elements of Reusable Object-Oriented Software. Addison Wesley, 2010.

GANGOPADHYAY, Ahana; CHATTERJEE, Oindrila; CHATTERJEE, Amitava. "Hand shape based biometric authentication system using radon transform and collaborative representation based classification", IEEE Second International Conference on Image Information Processing, pp. 635-639, 2013.

GONZALEZ , R. C.; WOODS, R. E. Digital Image Processing, " 3rd edition, Prentice-Hall, 2008

PATRO, S. G. K.; SAHU, K. K. Normalization: A Preprocessing Stage. Cornell University, 2015.

GRITTI, T. et al. Local Features based Facial Expression Recognition with Face Registration Errors. IEEE International Conference on Automatic Face and Gesture Recognition, 2008.

GUO, Jing-Ming; HSIA, Chih-Hsein; LIU, Yun-Fu; YU, Jie-Cyun; CHU, Mei-Hui; LE, Thanh-Nam. "Contact-free hand geometry-based identification system", Expert System with Applications, Vol. 39, No. 14, pp. 11728-11736, 2012.

HAO, Ying; SUN, Zhenan; TAN, Tieniu. "Comparative Studies on Multispectral Palm Image Fusion for Biometrics", 8th Asian Conference on Computer Vision, pp. 12-21, 2007.

HEARST, M. A., SCHÖLKOPF, B., DUMAIS, S., OSUNA, E., and Platt, J. Trends and Controversies - Support Vector Machines. IEEE Intelligent Systems, 13(4):18–28, 1998

HO, T. K.; HULL, J. J.; SRIHARI, S. N. Decision Combination in Multiple Classifier Systems. IEEE Transactions on Pattern Analysis and Machine Intelligence, 16(1), pp. 66-75, 1994.

INTEL DEVELOPER ZONE. "Histogram of Oriented Gradients (HOG) Descriptor". Disponível em: <<https://software.intel.com/en-us/node/529070>>. Acesso em: 08 de dez. de 2016.

JAIN, et. al.. Handbook of Biometrics. 1ª Edição. Springer, New York, 2008.

JAIN, et. al.. Handbook of Multibiometrics. 1ª Edição. Springer, New York, 2006.

- JAIN, Anil K.; ROSS, Arun; PRABHAKAR, Salil. "An Introduction to Biometric Recognition", IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, No. 1, pp. 4-20, 2004.
- JIANG, Xiaoqian; et al. "New Directions in Contact Free Hand Recognition", IEEE International Conference on Image Processing, Vol.2, pp. 389-392, 2007
- KANCHANA S., BALAKRISHNAN, G. "Robust Approach For Palm (Roi) Extraction In Palmprint Recognition System.", International Conference on Signa, Image Processing and Applications, Vol. 21, 2011.
- KANHANGAD, V.; KUMAR, A.; ZHANG, D. A unified framework for contactless hand verification. IEEE Transactions on Information Forensics and Security. Vol. 6, n. 3, pp. 1014 – 1027, 2011.
- KANG, Wenxiong; LIU, Yang; WU, Qiuxia; YUE, Xishun. "Contact-Free Palm-Vein Recognition Based on Local Invariant Features", PLoS ONE, Vol. 9, No. 5, pp. 1- 12, 2014.
- LEE, Jen-Chun. "A novel biometric system based on palm vein image", Pattern Recognition Letters, Vol. 33, No. 12, pp. 1520-1528, 2012.
- LE-QING, Zhu; SAN-YUAN, Zhang. "Multimodal biometric identification system based on finger geometry, knuckle print and palm print", Pattern Recognition Letters, Vol. 31, No. 12, pp. 1641-1649, 2010.
- MATSUMOTO, T; MATSUMOTO, H; YAMADA, K; HOSHINO, S. Impact of artificial gummy fingers on fingerprint system, *Proc. SPIE* 4677, pp. 275-289, 2002.
- MICROSOFT MSDN. "Native Pixel Formats Overview". Disponível em: < [https://msdn.microsoft.com/en-us/library/windows/desktop/ee719797\(v=vs.85\).aspx](https://msdn.microsoft.com/en-us/library/windows/desktop/ee719797(v=vs.85).aspx) >. Acesso em: 13 de ago. de 2016.
- NATIONAL BIOMETRIC SECURITY PROJECT. "Biometric Technology Application Manual". Vol. 1, 2008.
- PALANIKUMAR, S; SAJAN, C. Minu; SASIKUMAR, M. "Advanced Palmprint Recognition using Unsharp Masking and Histogram Equalization", IEEE Conference on Information and Communication Technologies, pp. 47-52, 2013.
- O'GORMAN, L, "Curvilinear Feature Detection from Curvature Estimation", Proceedings of the 9th International Conference on Pattern Recognition, pp. 1116-1119, 1988.
- OPENCV. Version 3.2. [S.I.] Disponível em: <http://opencv.org>.
- OTSU, Nobuyuki. "A Threshold Selection Method from Gray-level Histograms", IEEE Transactions on Systems, Man and Cybernetics, Vol. 9, No. 1, pp. 62-66, 1979

PARK, G.; KIM, S.; Hand Biometric Recognition Based on Fused Hand Geometry and Vascular Patterns. *Sensors*, vol. 13, n. 3, pp. 2895 – 2910, 2013.

PEDRINI, Hélio e SCHWARTZ, William R. “Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações”. São Paulo: Thomson, 2008.

ROSS, Arun. "A Prototype Hand Geometry-based Verification System". Proceedings of 2nd International Conference on Audio and Video-based Biometric Person Authentication (AVBPA), pp. 166-171, 1999.

SANCHEZ-REILLO, R.; SANCHEZ-AVILA, C.; GONZALEZ-MARCOS, A. Biometric Identification through hand geometry measurements. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 22, n. 10, pp. 1168-1171, 2000.

SCHMIDHUBER, Jürgen. “Deep Learning in Neural Networks: An Overview”, *Neural Networks*, Elsevier, Vol. 61, pp. 85-117, 2015.

SHALLOWAY , Alan; TROTT, James. *Design Patterns Explained: A New Perspective on Object-Oriented Design, 2nd Edition*, Addison-Wesley Professional, 2004.

SINGH, Aditya P.; THAKUR, Ranjan K.; KUMAR, Arabind; BAKSH, Ram. “User Authentication Using Hand Images”, *International Journal of Science and Research*, Vol. 3, No. 3, pp. 317-322, 2014.

SMOLA, A. J.; BARLETT, P.; SCHÖLKOPF, B.; SCHUURMANS, D. Introduction to Large Margin Classifiers, chapter 1, pages 1–28. (1999b).

SNEHA, M. Ramteke; HATKAR, S. S. “Segmentation of Palmprint into Region of Interest (ROI): A Survey”, *International Journal of Computer & Technology*, Vol. 14, No. 2, 2013

SURALKAR, S.R.; KARODE, A. H.; PAWADE, Priti W. “Texture Image Classification Using Support Vector Machine”, *International Journal of Computer Applications in Technology*, Vol. 2, No. 1, pp. 71-75, 2012.

VAPNIK, Vladimir. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York, 1995.

WANG, Ran; WANG, Guoyou; CHEN, Zhong; ZENG, Zhigang; WANG, Yong. “A palm vein identification system based on Gabor wavelet features”, *Neural Computing and Applications*, Vol. 24, pp. 161-168, 2014.

WITKIN, A. P. "Scale-space filtering", Proc. 8th Int. Joint Conf. Art. Intell., Karlsruhe, Germany, 1019–1022, 1983.

WU, Kuang Shyr; LEE, Jen-Chun; LO, Tsung Ming; CHANG, Ko-Chin; CHANG, Chien-Ping. “A secure palm vein recognition system”, *Journal of Systems and Software*, Vol. 86, No. 11, pp. 2870-2876, 2013.

XIN, Cui; WU, Xiangqian; QIUSHI, Zhao; YOUBAO, Tang. "A Contactless Hand Shape Identification System", 3rd International Conference on Advanced Computer Control, pp. 561-565, 2011.

XIONG, W. et al. Model-guided deformable hand shape recognition without positioning aids. *Pattern Recognition*, v.38 , pp. 1651-1664, 2005.

YAN, Xuekui; KANG, Wenxiong; DENG, Feiqi; WU, Qiuxia. "Palm vein recognition based on multi-sampling and feature-level fusion", *Neurocomputing*, Vol. 151, pp. 798-807, 2015.

YANO, Vitor A. N." Sistema Biométrico Multimodal Baseado em Pupilometria Dinâmica." Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Paraná, Curitiba, 2011.

ZIEN, A., RÄTSCH, G., MIKA, S., SCHÖLKOPF, B., LENGAEUER, T., and MÜLLER, K. R. Engineering Support Vector Machine kernels that recognize translation initiation sites in DNA. *Bioinformatics*, 16:906–914, 2000.

ZHOU, Yingbo; KUMAR, Ajay. "Contactless Palm Vein Identification Using Multiple Representations", *IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS)*, pp. 1-6, 2010.