

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO**  
**CENTRO TECNOLÓGICO**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**REINALDO LUBE FILHO**  
**ROBERTO MARTINELLI GUERRA**

**SISTEMA DE CONTROLE AUTOMÁTICO DE ACESSO**  
**ATRAVÉS DE IMAGEM DIGITALIZADA DO DEDO**  
**UTILIZANDO *WAVELET* E REDES NEURAIIS**

Vitória  
2008

REINALDO LUBE FILHO  
ROBERTO MARTINELLI GUERRA

**SISTEMA DE CONTROLE AUTOMÁTICO DE ACESSO  
ATRAVÉS DE IMAGEM DIGITALIZADA DO DEDO  
UTILIZANDO *WAVELET* E REDES NEURAIS**

Projeto de Graduação apresentado ao  
Corpo Docente do Departamento de  
Engenharia Mecânica da Universidade  
Federal do Estado do Espírito Santo  
como parte dos requisitos para obtenção  
do Título de Engenheiro Mecânico com  
Ênfase cursada em Sistemas  
Mecânicos.  
Orientador: Prof. Dr. Rafael Luís  
Teixeira.

Vitória  
2008

**REINALDO LUBE FILHO**  
**ROBERTO MARTINELLI GUERRA**

**SISTEMA DE CONTROLE AUTOMÁTICO DE ACESSO  
ATRAVÉS DE IMAGEM DIGITALIZADA DO DEDO  
UTILIZANDO *WAVELET* E REDES NEURAIS**

Projeto de Graduação apresentado ao Corpo Docente do Departamento de Engenharia Mecânica da Universidade Federal do Estado do Espírito Santo como parte dos requisitos para obtenção do Título de Engenheiro Mecânico com Ênfase cursada em Sistemas Mecânicos.

Aprovado em 05 de dezembro de 2008.

**Comissão Examinadora**

---

Prof. Dr. Rafael Luiz Teixeira - Orientador  
Universidade Federal do Espírito Santo

---

Prof. Dr. Antônio Bento Filho  
Universidade Federal do Espírito Santo

---

Prof. Dr. Márcio Coelho de Mattos  
Universidade Federal do Espírito Santo

## **Agradecimentos**

Agradeço aos meus pais, Reinaldo e Maria Olinda, e minha irmã, Larissa, por sempre acreditarem no meu potencial, me incentivarem a melhorar sempre e nunca me deixarem desistir.

Aos meus tios, Celso e Ângela, e meus primos, Gustavo e Ana Rita, pelo abrigo, por cuidarem de mim como se fosse um de seus filhos e irmão, pois é assim que me sinto perto deles, e pelo apoio incondicional à minha formação.

À minha namorada, conselheira e, brevemente, esposa, Suane Queiroz, que me deu muito incentivo, desde antes de começar o curso de Engenharia Mecânica, e ainda me incentiva até hoje, e sei que continuará me ajudando por toda a vida.

Ao professor Rafael pela força, pelo potencial, responsabilidade, grande conhecimento passado, tanto nas matérias quanto nos estudos para este trabalho, pela grande disposição em ajudar, paciência e amizade.

Aos meus amigos, que sempre me ajudaram em todos os momentos.

*Reinaldo Lube Filho*

*Vitória, Espírito Santo*

*Dezembro de 2008*

## **Agradecimentos**

Agradeço a toda minha família principalmente ao Jairo Antonio Guerra, meu pai, parceiro, meu amigo e meu herói que me atura até hoje. À Cacilda Martinelli Guerra, minha mãe, que sempre me ajudou, que tenho saudades e sinto muita falta e à Gisele Martinelli Guerra, minha irmã, que sempre me estimulou a estudar.

Também devo agradecimentos a todos os professores e funcionários da UFES e, principalmente, ao Dr. Rafael Luís Teixeira, que além de professor e orientador se tornou um grande amigo, e me impressionou pela sua paciência, dedicação e empenho no nosso projeto de graduação.

Por fim, agradeço aos meus amigos que sempre estiveram do meu lado nos dias de lutas e em dias de glórias, me apoiando e ajudando não apenas em aspectos acadêmicos, mas também na vida.

*Roberto Martinelli Guerra*

*Vitória, Espírito Santo*

*Dezembro de 2008*

## Resumo

Este projeto de conclusão de curso propõe duas metodologias de projeto de um sistema de controle de acesso a um ambiente restrito, como por exemplo, uma sala. Para tanto são utilizados dados biométricos de impressões digitais de dedos digitalizadas. A metodologia de controle ao acesso a esse ambiente restrito, primeiramente, faz uso da Transformada *Wavelet* bi-dimensional, que transforma a matriz de uma imagem em quatro coeficientes. Assim é possível, não somente, reconstruir a imagem original a partir desses quatro coeficientes como, utilizá-los, após tratamento estatístico, para treinamento de uma rede neural artificial (RNA).

Palavras-chave: Transformada *Wavelet*, Redes Neurais Artificiais, Biometria de Impressões Digitais.

## **Abstract**

*This project of course conclusion proposes two methodologies of an access control system to a restricted environment, for example, a room. To solve this control problem is used fingerprints biometric data of digitalized fingers. First of all, the both methodologies use the bi-dimensional Wavelet Transformation, which transforms the matrix of an image into four coefficients. It is possible, to obtain the original image reconstruction from these four coefficients and, after statistical analysis, the data is ready to train an artificial neural network (ARN).*

*Keyword: Wavelet transformation, Artificial Neural Network, Fingerprint Biometry*

## LISTA DE FIGURAS

|                                                                                                                           |    |
|---------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1.1 - MINÚCIAS NA IMPRESSÃO DIGITAL.....                                                                           | 16 |
| FIGURA 2.1 - DIAGRAMA DE BLOCOS DE UM FILTRO DIGITAL EM TEMPO REAL.....                                                   | 19 |
| FIGURA 2.2 - OPERAÇÕES COM FILTROS DIGITAIS: (A) ARMAZENAMENTO, (B)<br>MULTIPLICAÇÃO POR UMA CONSTANTE E (C) ADIÇÃO. .... | 22 |
| FIGURA 2.3 - REQUISITOS DE PROJETOS PARA FILTROS PASSA-BAIXA.....                                                         | 24 |
| FIGURA 2.4 - REQUISITOS DE PROJETOS PARA FILTROS PASSA-BANDA. ....                                                        | 25 |
| FIGURA 2.5 – SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DO TEMPO. ....                                                        | 29 |
| FIGURA 2.6 – ZOOM DO SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DO TEMPO. ....                                                | 29 |
| FIGURA 2.7 - SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DA FREQUÊNCIA. ....                                                   | 30 |
| FIGURA 2.8 – ZOOM DO SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DA FREQUÊNCIA...30                                            |    |
| FIGURA 2.9 – SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DO TEMPO. ....                                                        | 32 |
| FIGURA 2.10 – TRANSFORMADA DE <i>FOURIER</i> DO SINAL NO DOMÍNIO DA FREQUÊNCIA.....                                       | 32 |
| FIGURA 2.11 – SINAL MODULADO EM AMPLITUDE NO DOMÍNIO DO TEMPO. ....                                                       | 33 |
| FIGURA 2.12 – TRANSFORMADA DE <i>FOURIER</i> DO SINAL NO DOMÍNIO DO TEMPO.....                                            | 33 |
| FIGURA 2.13 – IMAGEM DA DIGITAL E SUA TRANSFORMADA DE <i>FOURIER</i> ESPAÇO $L^2_{\mathbb{R}}$ DO<br>INDIVÍDUO 1.....     | 35 |
| FIGURA 2.14 – IMAGEM DA DIGITAL E SUA TRANSFORMADA DE <i>FOURIER</i> ESPAÇO $L^2_{\mathbb{R}}$ DO<br>INDIVÍDUO 2.....     | 35 |
| FIGURA 2.15 - IMAGEM DA DIGITAL E SUA TRANSFORMADA DE <i>FOURIER</i> ESPAÇO $L^2_{\mathbb{R}}$ DO<br>INDIVÍDUO 3.....     | 36 |
| FIGURA 2.16 – IMAGEM DA DIGITAL E SUA TRANSFORMADA DE <i>FOURIER</i> ESPAÇO $L^2_{\mathbb{R}}$ DO<br>INDIVÍDUO 4.....     | 36 |
| FIGURA 2.17 - EFEITO DA FUNÇÃO DE MODULAÇÃO. ....                                                                         | 39 |
| FIGURA 2.18 - GRÁFICO DA <i>WAVELET</i> CHAPÉU MEXICANO. ....                                                             | 41 |
| FIGURA 2.19 - ALGUMAS <i>WAVELETS</i> .....                                                                               | 42 |

|                                                                                                                                                 |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 2.20 - ESCALAS DE UMA FUNÇÃO. ....                                                                                                       | 43 |
| FIGURA 2.21 - DILATAÇÃO DA <i>WAVELET</i> CHAPÉU MEXICANO. ....                                                                                 | 44 |
| FIGURA 2.22 - TRANSLAÇÃO DA <i>WAVELET</i> CHAPÉU MEXICANO. ....                                                                                | 44 |
| FIGURA 2.23 – <i>WAVELET</i> MÃE COM FILTRO BI-ORTOGONAL 6.8. ....                                                                              | 46 |
| FIGURA 2.24 – <i>WAVELET</i> MÃE <i>DAUBECHIES</i> DE NÍVEL 2.....                                                                              | 47 |
| FIGURA 2.25 – SUPERFÍCIE DE UMA AMOSTRA DO BANCO DE DADOS REPRESENTANDO A<br>SUPERFÍCIE ONDE A COORDENADA Z BRANCO(255).....                    | 48 |
| FIGURA 2.26 – SUPERFÍCIE DE UMA AMOSTRA DO BANCO DE DADOS REPRESENTANDO A<br>SUPERFÍCIE ONDE A COORDENADA Z BRANCO(255).....                    | 48 |
| FIGURA 2.27 – IMAGEM ORIGINAL DA DIGITAL E SUA RECONSTRUÇÃO ( <i>HAAR</i> 1º NÍVEL)...                                                          | 49 |
| FIGURA 2.28 – IMAGEM ORIGINAL DA DIGITAL E SUA RECONSTRUÇÃO ( <i>DAUBECHIES</i> 3º<br>NÍVEL).....                                               | 49 |
| FIGURA 2.29 – IMAGEM ORIGINAL DA DIGITAL E SUA RECONSTRUÇÃO ( <i>BI-ORTOGONAL</i> 5º<br>NÍVEL).....                                             | 50 |
| FIGURA 2.30 – IMAGEM ORIGINAL DA DIGITAL E SUA RECONSTRUÇÃO ( <i>BI-ORTOGONAL</i> 7º<br>NÍVEL).....                                             | 50 |
| FIGURA 2.31 – ESQUEMA DE UM NEURÔNIO DE <i>MCCULLOCH-PITTS</i> . ....                                                                           | 51 |
| FIGURA 2.32 – ARQUITETURA DE UMA REDE <i>FEEDFORWARD</i> . ....                                                                                 | 53 |
| FIGURA 2.33 – ARQUITETURA DE UMA REDE NEURAL RECORRENTE. ....                                                                                   | 54 |
| FIGURA 2.34 – REDE NEURAL COM ASSOCIAÇÃO LINEAR. ....                                                                                           | 55 |
| FIGURA 2.35 – REPRESENTAÇÃO DE REDE <i>OUTSTAR</i> (À ESQUERDA) E <i>INSTAR</i> (À DIREITA).<br>.....                                           | 57 |
| FIGURA 2.36 – UMA REDE DE APRENDIZADO <i>OUTSTAR</i> . ....                                                                                     | 57 |
| FIGURA 2.37 – REPRESENTAÇÃO DA REDE NEURAL PROBABILÍSTICA.....                                                                                  | 59 |
| FIGURA 2.38 – REPRESENTAÇÃO GRÁFICA DA FUNÇÃO DE ATIVAÇÃO (EQUAÇÃO 2.31). ..                                                                    | 59 |
| FIGURA 3.1 - GRÁFICO DAS MÉDIAS DO COEFICIENTE <i>C3</i> EXTRAÍDO PELO FILTRO BI-<br>ORTOGONAL PARA AS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO..... | 62 |

|                                                                                                                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 3.2 - GRÁFICO DAS MÉDIAS DOS COEFICIENTES C3 EXTRAÍDOS PELO FILTRO BI-ORTOGONAL PARA AS AMOSTRAS DE TREINAMENTO E VALIDAÇÃO.....                                                                | 63 |
| FIGURA 3.3 – DIAGRAMA DE BLOCOS DE TREINAMENTO BASEADO EM TREINAMENTO <i>HEBBIANO</i> . ....                                                                                                           | 64 |
| FIGURA 3.4 – DIAGRAMA DE BLOCOS DE VALIDAÇÃO COM O CONJUNTO B QUE ATINGE O ALVO REQUERIDO. ....                                                                                                        | 64 |
| FIGURA 3.5 – TESTE 1: OS DOIS GRÁFICOS SUPERIORES SÃO OS DEDOS E ALVO COM 1 ACESSO NEGADO, E OS GRÁFICOS INFERIORES, OS RESPECTIVOS DADOS E ALVO DE TREINAMENTO E VALIDAÇÃO. ....                      | 65 |
| FIGURA 3.6 – TESTE 2: OS DOIS GRÁFICOS SUPERIORES SÃO OS DEDOS E ALVO COM 2 ACESSOS NEGADOS, E OS GRÁFICOS INFERIORES, OS RESPECTIVOS DADOS E ALVO DE TREINAMENTO E VALIDAÇÃO. ....                    | 66 |
| FIGURA 3.7 – TESTE 3: OS DOIS GRÁFICOS SUPERIORES SÃO OS DEDOS E ALVO COM 4 ACESSOS NEGADOS, E OS GRÁFICOS INFERIORES, OS RESPECTIVOS DADOS E ALVO DE TREINAMENTO E VALIDAÇÃO. ....                    | 67 |
| FIGURA 3.8 – DIAGRAMA DE BLOCOS DE TREINAMENTO BASEADO EM TREINAMENTO POR RNA PROBABILÍSTICA. ....                                                                                                     | 68 |
| FIGURA 3.9 – DIAGRAMA DE BLOCOS DE VALIDAÇÃO COM O CONJUNTO B QUE ATINGE O ALVO REQUERIDO. ....                                                                                                        | 68 |
| FIGURA 3.10 – TESTE DA REDE PROBABILÍSTICA: OS GRÁFICOS MOSTRAM OS DADOS DE TREINAMENTO E VALIDAÇÃO EM SUAS RESPECTIVAS CLASSES, ONDE PARA A CLASSE 1 PERMITE O ACESSO E A CLASSE 2 NEGA O ACESSO..... | 69 |
| FIGURA 3.11 – RESULTADO DA VALIDAÇÃO DA REDE NEURAL PROBABILÍSTICA. ....                                                                                                                               | 70 |
| FIGURA B.1 – LEITOR UTILIZADO NO TRABALHO.....                                                                                                                                                         | 81 |
| FIGURA B.2 – <i>SOFTWARE</i> DE OBTENÇÃO DAS IMAGENS. ....                                                                                                                                             | 82 |
| FIGURA B.3 – IMAGEM OBTIDA COM O <i>MICROSOFT® FINGERPRINT READER</i> . ....                                                                                                                           | 82 |

## LISTA DE TABELAS

|                                                                 |    |
|-----------------------------------------------------------------|----|
| TABELA 2.1– EXEMPLOS DA TRANSFORMADA Z DE ALGUMAS FUNÇÕES ..... | 22 |
| TABELA 3.1 – FILTRO BI-ORTOGONAL $(a_k, b_k)$ .....             | 61 |

## LISTA DE SÍMBOLOS

|                        |                                                                        |
|------------------------|------------------------------------------------------------------------|
| $f(n)$                 | Função discreta, onde $n=1,2,3,4,5\dots$                               |
| $F(z)$                 | Transformada Z de uma função $f(n)$                                    |
| FIR                    | Filtros de Resposta ao Impulso Finito                                  |
| IIR                    | Filtros de Resposta ao Impulso Infinito                                |
| $a_k, b_k$             | Coefficientes do filtro                                                |
| $a_j$                  | Coefficiente que mede amplitude do componente de frequência $\varpi_j$ |
| $\varpi_j$             | Frequência j-ésima                                                     |
| $L^1(\mathbb{R})$      | <i>Transformada de Fourier no Espaço em uma dimensão</i>               |
| $L^2(\mathbb{R})$      | Transformada de Fourier no Espaço na segunda dimensão                  |
| $a(s)$                 | Amplitude de uma frequência                                            |
| $\hat{f}(s)$           | Integral de <i>Fourier</i>                                             |
| AM                     | <i>Amplitude Modulation</i> (modulação em amplitude)                   |
| FM                     | <i>Frequency Modulation</i> (modulação em frequência)                  |
| $\psi(t)$              | Função da <i>Wavelet</i>                                               |
| $E$                    | Energia da função $\psi(t)$                                            |
| $\hat{\psi}(f)$        | Transformada de <i>Fourier</i> da função $\psi$                        |
| $C_\psi$               | Constante de admissibilidade.                                          |
| $T_{m,n}$              | Valores da transformada discreta <i>Wavelet</i>                        |
| $f(u)$                 | Função de ativação                                                     |
| $u$                    | Somador dos produtos das entradas com os pesos                         |
| $w_{AB}^{novo}$        | Peso AB novo                                                           |
| $w_{AB}^{velho}$       | Peso AB velho                                                          |
| $\alpha$               | Constante de “esquecimento”                                            |
| $\beta$                | Constante de “aprendizagem”                                            |
| $\tilde{f}(t, \varpi)$ | Transformada de <i>Fourier</i> em Janelas                              |

# SUMÁRIO

|          |                                                                                |           |
|----------|--------------------------------------------------------------------------------|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>                                                        | <b>14</b> |
| <b>2</b> | <b>FUNDAMENTAÇÃO TEÓRICA .....</b>                                             | <b>19</b> |
| 2.1      | FILTROS DIGITAIS .....                                                         | 19        |
| 2.1.1    | <i>A Transformada Z .....</i>                                                  | <i>21</i> |
| 2.1.2    | <i>As duas classes de Filtros Digitais.....</i>                                | <i>22</i> |
| 2.1.3    | <i>Fases do Projeto de Filtros Digitais.....</i>                               | <i>24</i> |
| 2.2      | A TRANSFORMADA DE <i>FOURIER</i> .....                                         | 25        |
| 2.2.1    | <i>A Transformada de Fourier no Espaço <math>L^1\mathbb{R}</math>.....</i>     | <i>26</i> |
| 2.2.1.1  | Transformada de <i>Fourier</i> de um sinal digital modulado em amplitude.....  | 28        |
| 2.2.1.2  | Transformada de <i>Fourier</i> de um sinal digital modulado em frequência..... | 31        |
| 2.2.2    | <i>A Transformada de Fourier no Espaço <math>L^2\mathbb{R}</math>.....</i>     | <i>34</i> |
| 2.2.3    | <i>A Transformada de Fourier em Janelas .....</i>                              | <i>37</i> |
| 2.3      | A TRANSFORMADA WAVELET .....                                                   | 40        |
| 2.3.1    | <i>Famílias de Funções Wavelet.....</i>                                        | <i>42</i> |
| 2.3.2    | <i>A Transformada Wavelet Discreta.....</i>                                    | <i>44</i> |
| 2.3.3    | <i>A Transformada Wavelet Inversa .....</i>                                    | <i>47</i> |
| 2.3.4    | <i>Decomposição e Reconstrução de Imagens.....</i>                             | <i>47</i> |
| 2.4      | AS REDES NEURAIS ARTIFICIAIS.....                                              | 51        |
| 2.4.1    | <i>O aprendizado de Hebbian.....</i>                                           | <i>55</i> |
| 2.4.2    | <i>Rede Instar e Rede Outstar.....</i>                                         | <i>56</i> |

|                                                                                              |           |
|----------------------------------------------------------------------------------------------|-----------|
| <b>2.4.3 Redes Probabilísticas (PNN).....</b>                                                | <b>58</b> |
| <b>3 METODOLOGIAS PROPOSTAS .....</b>                                                        | <b>60</b> |
| 3.1 METODOLOGIA A: <i>WAVELET</i> E REDES NEURAIS COM<br>TREINAMENTO DE <i>HEBBIAN</i> ..... | 61        |
| 3.2 METODOLOGIA B: <i>WAVELET</i> E REDE NEURAL<br>PROBABILÍSTICA .....                      | 68        |
| <b>4 CONCLUSÃO .....</b>                                                                     | <b>71</b> |
| <b>5 REFERÊNCIAS BIBLIOGRÁFICAS .....</b>                                                    | <b>73</b> |
| <b>6 SITES ACESSADOS .....</b>                                                               | <b>75</b> |
| <b>ANEXO A – HISTÓRICO DA IDENTIFICAÇÃO NO MUNDO .....</b>                                   | <b>76</b> |
| <b>ANEXO B – <i>HARDWARE</i> UTILIZADO .....</b>                                             | <b>81</b> |
| <b>ANEXO C – BANCO DE DADOS ORIGINAL.....</b>                                                | <b>83</b> |

## 1 INTRODUÇÃO

No decorrer da história, partes de nossos corpos e aspectos de nosso comportamento têm sido usados como uma forma de identificação. Os primeiros estudos das imagens das marcas deixadas pelos dedos das pessoas, o que hoje é conhecido como impressões digitais, são datados da China antiga<sup>1</sup>.

O cientista inglês Francis Galton (1822-1911 †) é considerado um dos fundadores da biometria, cujos estudos estão relacionados a métodos estatísticos para fenômenos biológicos. A sua paixão pela medição permitiu que ele abrisse um laboratório de Antropométrica na Exibição Internacional de Saúde em 1884, onde ele coletou amostras para tratamento estatístico de milhares de pessoas. Em 1888, Galton inventou o primeiro sistema moderno de impressão digital, que foi posteriormente adotado por vários departamentos de polícia em todo o mundo, e só foi superado com o advento da genética molecular, ou seja, a estrutura do DNA.

O termo biometria refere-se a uma ciência que envolve a análise estatística de características biológicas. Uma possível definição deste termo pode ser: *“A biometria é uma característica única mensurável ou um traço do ser humano que, automaticamente, reconhece ou verifica sua identidade”* (CBA, 2008)

Com o advento da micro-eletrônica, nessa última década, a biometria é muito utilizada no que tange a segurança, de casas, prédios, bancos, etc.

A preocupação com a segurança é um desafio à população, às autoridades e, ultimamente, com o crescente aumento da violência, novas propostas de controle de acesso têm sido desenvolvidas. Há séculos utiliza-se chaves, cadeados, etc.. Todavia, muitos problemas são intrínsecos em relação ao uso de chaves, tais como: a perda, a quantidade e a facilidade em copiá-las, e isso, pode facilitar a ação de pessoas mal intencionadas.

---

<sup>1</sup> No Apêndice A encontra-se a cronologia histórica da identificação.

Uma solução para controle de acesso, desenvolvida nas últimas décadas, foi o conjunto de um teclado alfa-numérico e uma fechadura elétrica comandada por solenóide. Esse sistema é confiável, desde que o usuário defina uma senha difícil de ser decifrada, não a esqueça e não deixe que outras pessoas o vejam digitando-a.


Buscando cada vez mais segurança, pretende-se com esse trabalho uma maior confiabilidade, pois a tendência é a utilização de dados biométricos que são inerentes a cada pessoa. Para citá-los, encontra-se o reconhecimento de:

- Íris;
- Impressões digitais;
- Face;
- Forma da mão;
- Características sanguíneas;
- Características dos cabelos;
- Padrões genéticos; e
- Padrões de voz.

Contudo, o alto custo, dos sistemas que usam biometria encontrados comercialmente, é um inconveniente que pode ser superado e, desta forma, aglutinar-se a um maior número de famílias, o que se pretende num futuro próximo com a implementação experimental dessa pesquisa computacional.

Desta forma, esse trabalho propõe um sistema de reconhecimento de impressões digitais do dedo para controle de acesso, tal que seja barato e confiável.

Um problema encontrado em usar impressões digitais, é obter padrões das imagens. Os métodos para análise utilizam a mesma abordagem da análise feita por um especialista, na qual um par de impressões digitais é comparado e é observada a orientação dos sulcos e a localização das minúcias existentes (RATHA *et al.*, 1995; KARU e JAIN, 1996). As minúcias são descontinuidades nos padrões dos sulcos nas impressões digitais, tais como, terminações, ilhas e bifurcações, como mostrado na Figura 1.1.



**Figura 1.1 - Minúcias na Impressão Digital.**

A quantidade das minúcias numa impressão digital pode variar entre 50 e 150, porém, cerca de 10 minúcias já é suficiente para identificar um indivíduo. Todavia, a análise das minúcias é bastante sensível a ruídos e deformações, como a criação de minúcias artificiais ou desaparecimento das existentes, de acordo com a forma que a imagem é adquirida (BALDI e CHAUVIN, 1993). Ou seja, a aquisição das imagens é uma questão bem relevante.

Houve nas últimas duas décadas uma evolução dos algoritmos para decomposição e reconstrução de imagens (HUNG, 1993), todavia demandam de um grande esforço computacional por se tratar essencialmente de um problema de comparação das coordenadas relativas das minúcias (pixels variando entre 0 e 255).

Haja vista que a solução automática com teclado alfa-numérico e senha ser eficiente, atualmente, já está ultrapassado, pois verifica-se que o uso da leitura de impressões digitais estão cada vez mais presentes em lugares onde há controle de acesso.

*“Assim esse trabalho de conclusão de curso tem como objetivo propor duas metodologias para identificação de pessoas, liberando (ou não) seu acesso e que utilizam a Transformada de Wavelet e as Redes Neurais Artificiais que classificam padrões.”*

A impressão digital é o método de biometria mais utilizado mundialmente. Só para se ter uma idéia, os dispositivos biométricos por impressão digital vendidos pela Authentec, em 2002, contabilizam um aumento 50% dos que foram vendidos de produtos similares em 2001 (IHT, 2003). Além de ser mais barato é bem seguro. Apenas por curiosidade, existe uma chance em cem bilhões de uma pessoa ter a mesma digital que a outra. Trevor W. Prout, da *Biometric Group*, que é uma empresa americana especializada em biometria, retrata que: "*É a opção ideal porque combina boa aplicação com bom balanço entre nível de uso e custo*".

Existem três tipos de dispositivos digitais que podem coletar a impressão digital: ótico, capacitivo e ultra-sônico. O primeiro trabalha através da reflexão da luz sobre o dedo, o segundo mede o calor que sai da digital e o terceiro envia sinais sonoros e analisa o retorno deles como se fosse um radar milimétrico. Desta forma é intuitivo que a opção do sensor ótico é a mais utilizada e segura.

Para desenvolvimento do sistema de controle de acesso via impressões digitais é necessário, inicialmente, adquirir um banco de dados de imagens para cadastramento dos indivíduos que terão ou não acesso. Nesse banco é previsto um conjunto para elaborar a metodologia e outro para validá-la. Há um ano, quando se iniciou esse trabalho adquiriu-se um *hardware* da *Microsoft® Fingerprint Reader*<sup>2</sup> visando compatibilidade de *software/hardware*.

Resumidamente, esse trabalho busca minimizar os custos de um reconhecimento de impressões digitais que fez uso de um sensor ótico. Assim são propostas duas metodologias que utilizam a compactação de dados da imagem, via Transformada de *Wavelet* e, a partir dessa compactação, utiliza-se uma rede neural artificial (RNA) para classificar os indivíduos. Ambas as teorias foram utilizadas com os respectivos *toolboxes* do *Matlab®* (MATLAB, 2004).

Uma motivação para o uso da transformada *Wavelet* discreta, 2D, para extração de características foi devido ao fato do FBI utilizar uma família *Wavelet* baseada em filtros bi-ortogonais (STRANG e NGUYEN, 1997).

---

<sup>2</sup> Ver Anexo B para maiores informações sobre este dispositivo.

As RNA's possuem algoritmos com grande capacidade de classificações não lineares e com eficiência; são robustos e oferecem grande adaptabilidade às condições de diversos casos especiais (RUMELHART *et al.*, 1994).

Tanto a transformada *Wavelet* discreta 2D como as RNA's podem ser facilmente implementadas em microprocessadores digitais de baixíssimo custo, a partir dos algoritmos desenvolvidos com o *Matlab*®.

O uso da Transformada de *Wavelet's* se justifica por reduzir os dados para treinamento de uma RNA, o que facilita a convergência, o treinamento e a validação da RNA e, também, o diminui custo computacional envolvido.

Diante dos objetivos propostos, essa monografia está estruturada da seguinte forma:

- No capítulo II é apresentada uma fundamentação teórica dos filtros digitais, da transformada de *Fourier* 1D e 2D, da transformada de *Wavelet* 2D e da teoria das redes neurais artificiais;
- O capítulo III são apresentadas as 2 metodologias propostas onde utiliza-se a Transformada de *Wavelet* 2D com filtros bi-ortogonais associada a duas RNA's classificatórias buscando identificar os indivíduos; e
- Finalmente, no capítulo IV são feitas algumas conclusões e no capítulo VI, descritas as futuras perspectivas desse projeto de controle automático de acesso através de imagens digitalizadas do dedo.


## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os fundamentos dos Filtros Digitais, da Transformada Discreta de *Fourier* 1D e 2D, da Transformada de *Wavelet* e das Redes Neurais Artificiais (RNA).

### 2.1 FILTROS DIGITAIS

Um filtro digital é essencialmente um elemento que modifica a forma de uma onda ou as características de um sinal segundo requisitos de projeto. Tais características são a amplitude e frequência e/ou a fase e frequência do sinal que se deseja filtrar. O objetivo principal de filtrar um sinal é promover qualidade do sinal, como por exemplo, a eliminação de um ruído presente em um sinal. Basicamente, um filtro digital é um algoritmo matemático baseado em equações de diferenças que utiliza a transformada Z.

A Figura 2.1 apresenta um diagrama de blocos simplificado de um filtro digital que filtra sinais analógicos de entrada em sinais analógicos de saída filtrados.



**Figura 2.1 - Diagrama de blocos de um filtro digital em tempo real.**

O sinal analógico de entrada,  $x(t)$ , com banda limitada é amostrado periodicamente e convertido em uma série de amostras digitais  $x(n)$ ,  $n = 1, 2, \dots$  por meio de um conversor AD (Analógico/Digital). Um processador de sinal digital, que pode ser *software* instalado em um computador pessoal ou um microcontrolador, efetua as operações de filtragem que mapeiam uma seqüência de entradas  $x(n)$  em uma seqüência de saídas  $y(n)$ , de acordo com o algoritmo computacional do filtro.

Após filtragem digital, um conversor DA (Digital/Analógico) converte a saída filtrada em um valor analógico.

Quando comparados aos filtros analógicos, os filtros digitais são preferidos em inúmeras aplicações, tais como: compressão de dados, processamento de sinal biomédico, processamento de fala/imagem, transmissão de dados, cancelamento de eco de telefonia, etc., devido às seguintes vantagens:

- Filtros digitais podem ter características que não são possíveis com os filtros analógicos, como uma resposta em fase linear;
- O desempenho dos filtros digitais não varia com a temperatura, eliminando a necessidade de calibrações periódicas;
- A resposta em frequência de um filtro digital pode ser ajustada automaticamente, caso seja implementado utilizando processadores programáveis;
- Os dados filtrados e os não filtrados podem ser re-armazenados guardados para uso futuro;
- Os filtros digitais fabricados atualmente são de pequeno porte, consomem menos potência e a baixo custo; e
- Filtros digitais podem ser utilizados em baixas frequências, como as que geralmente ocorrem em sistemas biomédicos, onde o uso de filtros analógicos é impraticável.

Porém, os filtros digitais apresentam algumas limitações quando comparados aos filtros analógicos, tais como:

- Limitação de velocidade: a largura máxima de banda que um sinal pode a ser submetido a um filtro digital é muito inferior a um analógico, em tempo real. Assim o tempo de conversão AD e DA, velocidade do processador e o número de operações aritméticas envolvidas no algoritmo do filtro digital causam atrasos;
- Efeito de tamanho finito da palavra: Existem ruídos devido à conversão AD resultantes da quantização do sinal analógico. Ruídos, também aparecem,

durante o processamento devido aos arredondamentos; Salieta-se que, acúmulo de ruídos, pode levar à instabilidade, sistemas de controle a malha fechada;

- Tempo de desenvolvimento do projeto: Os filtros digitais demandam, principalmente na parte de *hardware*, um maior tempo de projeto em relação aos filtros analógicos. Uma vez desenvolvido o *hardware/software*, eles podem facilmente ser utilizados em outros processamentos digitais de sinais (*DSP-Digital Signal Processing*).

### 2.1.1 A Transformada Z

A Transformada Z de uma função  $f(n)$  é definida conforme as Equações 2.1a e 2.1b.

$$F(z) = \sum_{n=0}^k f(nT)z^{-n} \quad (2.1a)$$

Por exemplo, se  $f(n)$  for:  $[f(0), f(T), f(2T), f(3T), \dots, f(kT)]$ , então:

$$F(z) = f(0) + f(T)z^{-1} + f(2T)z^{-2} + \dots + f(kT)z^{-k} \quad (2.1b)$$

Assim, numericamente, se  $x(5) = [1, 2, 5, 3, 0, 0]$ , logo:  $X(z) = 1 + 2z^{-1} + 5z^{-2} + 3z^{-3}$ .

A Tabela 2.1 apresenta a Transformada Z de algumas funções comumente utilizadas.

Tabela 2.1 - Exemplos da Transformada Z de algumas funções.

| $f(t), t \geq 0$         | $f(nt), nt \geq 0$        | $F(z)$                                                                         |
|--------------------------|---------------------------|--------------------------------------------------------------------------------|
| 1 (degrau unitário)      | 1                         | $\frac{1}{1 - z^{-1}}$                                                         |
| $t$                      | $nT$                      | $\frac{Tz^{-1}}{(1 - z^{-1})^2}$                                               |
| $e^{-at}$                | $e^{-anT}$                | $\frac{1}{1 - e^{-aT}z^{-1}}$                                                  |
| $te^{-at}$               | $nTe^{-anT}$              | $\frac{Tze^{-aT}z^{-1}}{(1 - e^{-aT}z^{-1})^2}$                                |
| $\text{sen } \omega_c t$ | $\text{sen } n\omega_c T$ | $\frac{(\text{sen } \omega_c T)z^{-1}}{1 - 2(\cos \omega_c T)z^{-1} + z^{-2}}$ |
| $\cos \omega_c t$        | $\cos n\omega_c T$        | $\frac{1 - (\cos \omega_c T)z^{-1}}{1 - 2(\cos \omega_c T)z^{-1} + z^{-2}}$    |

Associando os filtros digitais com a Transformada Z, basicamente, eles utilizam 3 tipos de operação, tal como ilustrado na Figura 2.2.




Figura 2.2 - Operações com filtros digitais: (a) Armazenamento, (b) Multiplicação por uma constante e (c) Adição.

### 2.1.2 As duas classes de Filtros Digitais

Os filtros digitais são divididos em duas classes:

- Filtros de Resposta ao Impulso Finito (FIR: *Finite Impulse Response*); e
- Filtros de Resposta ao Impulso Infinito (IIR: *Infinite Impulse Response*).

Basicamente, os filtros digitais podem ser representados por uma seqüência,  $h(k)$  com  $k = 0, 1, 2, 3, \dots$ , relacionando os sinais de entrada e saída pelo somatório de convoluções. As Equações 2.2 e 2.3 apresentam, respectivamente, estas relações para os filtros FIR e IIR.

$$y(n) = \sum_{k=0}^{N-1} h(k)x(n-k) \quad (2.2)$$

$$y(n) = \sum_{k=0}^{\infty} h(k)x(n-k) \quad (2.3)$$

Estas equações mostram o caráter finito e infinito da FIR e IIR, pois o FIR possui um somatório com  $N$  valores, enquanto o IIR possui um somatório que vai de 0 a  $\infty$ . Na prática não é possível, computacionalmente, calcular a saída do IIR, pois a resposta é teoricamente infinita. Então, a Equação 2.3 do IIR pode ser expressa na sua forma recursiva, descrita na Equação 2.4.

$$y(n) = \sum_{k=0}^N a_k x(n-k) - \sum_{k=1}^M b_k y(n-k), \quad (2.4)$$

onde  $a_k$  e  $b_k$  são os coeficientes do filtro.

No projeto de filtros as equações de diferenças 2.2 e 2.4 são utilizadas para os filtros FIR e IIR, respectivamente. O objetivo principal é obter o valor de  $h(k)$  para o FIR e os coeficientes  $a_k$  e  $b_k$  para o IIR.

Nota-se que a saída  $y(n)$ , na equação recursiva do IIR, depende das entradas e de saídas anteriores, ou seja, o IIR é um sistema re-alimentado de determinadas saídas. Em contrapartida, o FIR depende apenas das entradas.

### 2.1.3 Fases do Projeto de Filtros Digitais

O projeto de filtros digitais envolve cinco fases, quais sejam:

1. Especificação do Filtro;
2. Cálculo dos coeficientes do Filtro;
3. Realização do Filtro em uma Estrutura;
4. Análise do efeito de tamanho de palavras sob a performance do filtro; e
5. Implementação do Filtro em *software* e/ou *hardware*.

Estão ilustrados nas Figuras 2.3 e 2.4 os requisitos de projeto de filtros passa-baixa e passa-banda.




Figura 2.3 - Requisitos de projetos para filtros passa-baixa.




Figura 2.4 - Requisitos de projetos para filtros passa-banda.

## 2.2 A TRANSFORMADA DE FOURIER

O trabalho do matemático francês *Joseph Fourier* (1768-1820 †) demonstrou que qualquer função periódica pode ser decomposta como uma soma infinita de senos e cossenos.

Matematicamente, seja  $f$  uma função periódica com período  $T > 0$ , ou seja,  $f(t + T) = f(t)$ , a teoria de *Fourier* estabelece que a função  $f$  pode ser decomposta de acordo com a Equação 2.5.

$$f(i\varpi_j) = \sum_{j=-\infty}^{+\infty} a_j e^{i\varpi_j}, a_j \in \mathbb{R} \quad (2.5)$$

onde  $\varpi_j = j/T$  é uma constante. Essa decomposição da função  $f(i\varpi_j)$  é conhecida como série de *Fourier*. Como a família  $\{e^{i\varpi_j}, j \in \mathbb{Z}\}$  é um conjunto ortonormal

completo do espaço  $L_T^2(\mathbb{R})$ , então, a Equação 2.5, representa uma base ortogonal de  $f(i\varpi_j)$  (GOMES e VELHO, 1999).

Essa representação torna mais fácil a análise das frequências presentes em  $f(i\varpi_j)$ , pois existe uma frequência fundamental  $\varpi$  onde todas as outras frequências,  $\varpi_j$ ,  $j \in \mathbb{Z}$ , são múltiplas. Há o coeficiente  $a_j$ , que mede a amplitude do componente de frequência  $\varpi_j$ , na função  $f$ . Em particular, se  $a_j = 0$ ,  $\varpi_j$  não está presente na função. Esse coeficiente é calculado utilizando a Equação 2.6.

$$a_j = \int_0^L f(u) e^{i\varpi_j u} du \quad (2.6)$$

A motivação de *Fourier* para desenvolver suas séries foi o estudo da propagação de calor em corpos sólidos, que é regida por uma equação diferencial linear difícil de ser analisada e resolvida. A principal característica das séries, observada por *Fourier*, é a habilidade de gerar uma representação exata de uma função, que transfere o sinal do domínio do tempo para o domínio da frequência.

### 2.2.1 A Transformada de Fourier no Espaço $L^1(\mathbb{R})$

Primeiramente, a transformada de *Fourier* foi definida no espaço das funções integráveis,  $L^1(\mathbb{R})$ , conforme mostra na Equação 2.7,

$$L^1(\mathbb{R}) = \{f: \mathbb{R} \rightarrow \mathbb{R}, \int |f(t)| dt < \infty\}, \quad (2.7)$$

e, depois, a definição foi estendida para o espaço  $L^2(\mathbb{R})$ , das funções de energia finita (MALLAT; TEOLIS, 1998), tal como Equação 2.8.

$$L^2(\mathbb{R}) = \{f: \mathbb{R} \rightarrow \mathbb{R}, \int |f(t)|^2 dt < \infty\}, \quad (2.8)$$

No caso do espaço  $L^1(\mathbb{R})$ , o raciocínio inicia-se a partir da Equação 2.6, que calcula a amplitude de uma frequência. Considerando  $s = i\omega_j$ , obtém-se a Equação 2.9.

$$a(s) = \int_{-\infty}^{+\infty} f(u)e^{su} du \quad (2.9)$$

Na Equação 2.9, para cada  $s$ ,  $e^{su}$  é uma função periódica de frequência  $s$  onde  $s \in \mathbb{R}$ . A operação  $f(u)e^{su}$  é conhecida como modulação da função  $f$  (GOMES e VELHO, 1999).

Assim, o cálculo da frequência presente em um sinal digital é obtido da seguinte forma: quando  $f$  possui oscilações de frequência de valores iguais ou muito próximos ao valor de  $s$ , na região de ressonância, há uma amplificação de sua magnitude.

A equação da transformada de *Fourier* das funções que pertencem ao espaço  $L^1(\mathbb{R})$  é obtida mudando a notação da Equação 2.9. Embora a notação das equações seja diferente, a mesma interpretação associada a  $a(s)$  na Equação 2.9 é reescrita  $\hat{f}(s)$ . Isto é, seja a função  $\hat{f}(s) \in L^1(\mathbb{R})$ , sua transformada de *Fourier*, denominada  $\hat{f}(s)$ , é dada pela integral mostrada na Equação 2.10.

$$\hat{f}(s) = \int_{-\infty}^{+\infty} f(u)e^{-su} du \quad (2.10)$$

Se  $\hat{f}(s) \in L^1(\mathbb{R})$ , então essa integral de *Fourier* converge e (MALLAT, 1998):

$$|\hat{f}(s)| \leq \int_{-\infty}^{+\infty} |f(u)| du \quad (2.11)$$

Com isso, tem-se que a transformada de *Fourier* é uma função de  $s$  contínua e limitada. Além disso, se  $\hat{f}(s)$  é integrável, ou seja,  $\hat{f}(s) \in L^1(\mathbb{R})$ , então a transformada inversa de *Fourier* de  $\hat{f}$  existe (GOMES e VELHO, 1999).

Utilizando a Equação 2.10, prova-se que, se  $\hat{f}(s) \in L^1(\mathbb{R})$  então  $f$  é contínua (GOMES e VELHO, 1999). Com isso, conclui-se que não há transformada inversa para funções descontínuas. Para eliminar essa lacuna, a transformada de *Fourier* deve ser estendida para o espaço  $L^2(\mathbb{R})$ .

Contudo, serão apresentadas, anteriormente à *Fourier* 2D, as transformadas de *Fourier* no Espaço  $L^1(\mathbb{R})$  de sinais digitais modulados em amplitude (*AM – Amplitude Modulation*) e frequência (*FM – Frequency Modulation*).

#### 2.2.1.1 Transformada de *Fourier* de um sinal digital modulado em amplitude

Será analisado o espectro de frequência de um sinal modulado em amplitude com uma frequência de amostragem de 1Hz, com 1024 pontos de frequências. Sendo que a frequência da operadora ( $f_o$ ) e a frequência da portadora ( $f_p$ ) são respectivamente 10 e 100 Hz. A Equação 2.12 apresenta o sinal  $y(t)$  resultante da modulação, onde a magnitude da portadora é metade da operadora.

$$y(t) = \text{sen}(2\pi f_o t) 0,5 \text{sen}(2\pi f_p t) \quad (2.12)$$

As Figuras 2.5 e 2.6 apresentam o sinal  $y(t)$  modulado em amplitude no domínio do tempo, respectivamente, de 0 a 2 segundos e, um zoom, de 0.25 a 0.4 segundos.




Figura 2.5 – Sinal modulado em amplitude no domínio do tempo.




Figura 2.6 – Zoom do Sinal modulado em amplitude no domínio do tempo.

Percebe-se no sinal uma repetição de 0,05s em 0,05s de 10 oscilações o que é consequência da frequência de modulação de 10 Hz.

Em posse do sinal modulado  $y(t)$  foi aplicado à transformada rápida de Fourier (FFT – Fast Fourier Transformation). Sabe-se que ao aplicar a transformada de Fourier obtém-se para cada uma das frequências um número complexo. Normalmente, traça-se uma curva para magnitude e outra para fase. Contudo será apresentada nas Figuras 2.7 e 2.8 somente a magnitude, a fim de identificar as frequências da operadora e da portadora.




Figura 2.7 - Sinal modulado em amplitude no domínio da frequência.




Figura 2.8 – Zoom do Sinal modulado em amplitude no domínio da frequência.

As Figuras 2.7 e 2.8 apresentam, respectivamente, os espectros do sinal modulado na banda de frequência e toda a banda de interesse. Caso fosse apenas um sinal senoidal de uma única frequência, a transformada de *Fourier* resultaria em uma única magnitude com pico dessa frequência, ou seja, nesse caso dado um sinal senoidal sem saber sua frequência, ao aplicar a transformada de *Fourier* essa frequência é obtida.

A intenção de fazer modulações AM e FM é ocultar as frequências da portadora e da operadora.

Assim mostrou-se que a frequência resultante da modulação em amplitude depende sempre da soma e da diferença das frequências dos sinais modulados, ou seja, as frequências resultantes dessa modulação são sempre dadas pelos valores  $(f_o + f_p)$  e  $(f_o - f_p)$ .

#### 2.2.1.2 Transformada de *Fourier* de um sinal digital modulado em frequência

Modificando-se apenas o sinal de frequência da operadora para 20Hz e mantendo os demais parâmetros do exemplo do sinal FM. A Equação 2.13 apresenta o sinal  $y(t)$  resultante da modulação em frequência (FM).

$$y(t) = a \cdot \cos(2\pi f_p t + b \cdot \sin(2\pi f_o t)), \quad (2.13)$$

onde  $a$  é amplitude da portadora e  $b$  é o índice de modulação, que é igual à flutuação de  $f_o$ .

A Figura 2.9, onde foi adotado  $a = 3$  e  $b = 2$ , apresenta o sinal modulado em frequência no domínio do tempo, e a Figura 2.10 a transformada rápida de *Fourier* do sinal no domínio da frequência.




Figura 2.9 – Sinal modulado em frequência no domínio do tempo.




Figura 2.10 – Transformada de *Fourier* do sinal no domínio da frequência.

Já as Figuras 2.11 e 2.12 são, respectivamente, o sinal modulado em frequência no domínio do tempo e a transformada rápida de *Fourier* do sinal no domínio da frequência, para o caso em que  $a = 1$  e  $b = 5$ .




Figura 2.11 – Sinal modulado em amplitude no domínio do tempo.




Figura 2.12 – Transformada de *Fourier* do Sinal no domínio do tempo.

A mudança do índice de modulação de  $b = 2$  para  $b = 5$  reduziu a magnitude de alguns picos das frequências de flutuação em relação ao pico da frequência da portadora e outros mantiveram suas magnitudes. Percebe-se que para esse índice

de modulação o espectro cobre uma maior faixa de freqüências de flutuação devido à modulação.

### 2.2.2 A Transformada de Fourier no Espaço $L^2(\mathbb{R})$

Dois aspectos motivaram a extensão da transformada de *Fourier* para o espaço  $L^2(\mathbb{R})$ . Um deles é que a transformada de uma função integrável não é necessariamente integrável, ou seja,  $\hat{f}$  não é um operador do tipo  $\hat{f}: L^1(\mathbb{R}) \rightarrow L^1(\mathbb{R})$ , por causa disso nem todas as funções do espaço  $L^1(\mathbb{R})$  possuem inversa. O outro aspecto é que há grande interesse no espaço  $L^2(\mathbb{R})$ , uma vez que ele tem uma estrutura mais rica do que o espaço  $L^1(\mathbb{R})$ , pois possui produto interno definido e é, na verdade, um Espaço de *Hilbert* (TEOLIS, 1998).

Tem-se que, se a função  $f \in L^2(\mathbb{R})$  mas  $f \notin L^1(\mathbb{R})$ , sua transformada de *Fourier* não pode ser calculada, utilizando a Equação 2.11, pois  $f(t)e^{i\omega t}$  não é integrável. Por isto, ela é definida, aplicando-se limite às transformadas de *Fourier* de funções que estão em  $f \in L^1(\mathbb{R}) \cap f \in L^2(\mathbb{R})$ . Por definição, a transformada de *Fourier* de  $f$  é dada por  $\hat{f}$ , que no seguinte limite (MALLAT, 1998) descrito na Equação 2.14:

$$\lim_{n \rightarrow +\infty} \|\hat{f} - \hat{f}_n\| = 0 \quad (2.14)$$

Assim, tem-se que a transformada de *Fourier* é um operador linear definido no espaço  $L^2(\mathbb{R})$ . Seja a função  $f(t)$ , tal que  $f: \mathbb{R} \rightarrow \mathbb{R}$ , definida no domínio do tempo. Ao calcular a transformada de *Fourier* de  $f$ , obtém-se uma nova função  $\hat{f}_\omega$ , definida em  $L^2(\mathbb{R})$ , tal que para cada valor do parâmetro  $\omega \in \mathbb{R}$ ,  $\hat{f}_\omega$  representa a densidade da freqüência  $\omega$  em  $f$ .

Assim, serão apresentadas nas Figuras 2.13 a 2.16, a Transformada Rápida de *Fourier* 2D de algumas imagens do banco de dados que é composto por 128 digitais de 16 pessoas.




Figura 2.13 – Imagem da digital e sua Transformada de *Fourier Espaço*  $L^2(\mathbb{R})$  do indivíduo 1.




Figura 2.14 – Imagem da digital e sua Transformada de *Fourier Espaço*  $L^2(\mathbb{R})$  do indivíduo 2.




Figura 2.15 - Imagem da digital e sua Transformada de *Fourier Espaço*  $L^2(\mathbb{R})$  do indivíduo 3.




Figura 2.16 – Imagem da digital e sua Transformada de *Fourier Espaço*  $L^2(\mathbb{R})$  do indivíduo 4.

Portanto podemos concluir que, analisando as Figuras de 2.13 a 2.16 pode-se verificar que a aplicação da transformada de *Fourier* no Espaço  $L^2(\mathbb{R})$ , não foi uma ferramenta adequada para obtenção de padrões para treinamento de uma RNA, isto é, não foram obtidos padrões diferentes entre as impressões digitais, o que impossibilita o reconhecimento.

De acordo com a definição da transformada de *Fourier*, se  $\hat{f}(s_0) \neq 0$ , conclui-se que a função  $f$  possui frequências iguais ou próximas a  $s_0$ . Nesse caso, o próximo passo da análise de  $f$  consiste em localizar a posição destas frequências no domínio do espaço que no caso de imagem, o espaço é pixel x pixel.

Esse é o ponto de maior fragilidade da transformada de *Fourier*, pois não é trivial localizar frequências no domínio espacial. De forma geral, se uma função apresenta mudanças repentinas, como descontinuidades, as altas frequências ocasionadas por essas mudanças são detectadas, mas elas influenciam no cálculo da transformada ao longo de todo o domínio, porque a função exponencial não tem suporte compacto. Por isso, a análise de *Fourier* é mais eficaz no estudo de sinais que não sofrem variações repentinas ao longo do tempo (ou espaço) (GOMES e VELHO, 1999).

Para obter uma transformada com propriedades melhores de localização no domínio tempo-frequência, foi feita uma modificação na definição da transformada de *Fourier*. A transformada obtida, denominada *Transformada Fourier em Janelas*, apresenta resultados melhores do que a transformada de *Fourier* na representação de funções.

### **2.2.3 A Transformada de Fourier em Janelas**

O propósito da Transformada de *Fourier* em Janelas (*WFT - Windowed Fourier Transform*) é melhorar a transformada de *Fourier* para obter uma transformada que possua as seguintes propriedades (GOMES e VELHO, 1999):

- Ao ser aplicada a um sinal  $f(t)$ , produza um sinal,  $\tilde{f}(t, \varpi)$ , que esteja definido nos domínios do tempo e da frequência simultaneamente;
- Apenas valores que estejam dentro do intervalo de tempo estabelecido,  $f(t)$ , tal que  $t \leq t_1$ , sejam analisados no cálculo da “transformada”  $\tilde{f}(t, \varpi)$ ; e
- O cálculo da transformada de  $f(t)$ , em um intervalo de tempo específico, não influencia no cálculo da transformada de  $f(t)$  em outros intervalos de tempo, ou seja, dado um número real  $t_0 > 0$ , o cálculo de  $\tilde{f}(t, \varpi)$  deve depender apenas dos valores de  $t$  no intervalo  $[t - t_0, t]$ .


Matematicamente, as duas últimas propriedades citadas mostram que a função de modulação utilizada para detectar as frequências no cálculo da transformada,  $\tilde{f}(t, \varpi)$ , deve ter os seus valores concentrados em uma vizinhança de  $t$ , ou seja, deve ser localizada no tempo.

Um método para obter uma função de modulação localizada no tempo consiste em utilizar uma função auxiliar  $g(u)$  que faça com que a função de modulação, utilizada na transformada de *Fourier*,  $e^{-i\varpi u}$ , fique “localizada” em uma certa vizinhança no domínio do tempo (GOMES e VELHO, 1999), conforme mostrado matematicamente na Equação 2.15.

$$g_{\varpi, u}(u) = g(u - t)e^{-i\varpi u} \quad (2.15)$$

A atuação dessa função de localização é ilustrada na Figura 2.17. Se a função  $g$  é localizada no tempo, obtém-se a localização desejada da função de modulação  $g(u - t)e^{-i\varpi u}$ . A partir dessa idéia, a Transformada de *Fourier* em Janelas é definida por (GOMES e VELHO, 1999), tal como descrito na Equação 2.16.

$$\tilde{f}(t, \varpi) = \int g(u - t)f(u)e^{-i\varpi u} du \quad (2.16)$$



**Figura 2.17 - Efeito da função de modulação.**

Com a WFT, o sinal  $f(t)$  é recortado em seções, ou janelas, de forma que a frequência de cada seção pode ser analisada separadamente. Se o sinal tem transições bruscas, efetua-se a janela no sinal de entrada de modo que as seções venham a convergir para zero em seus pontos finais.

A WFT é inversível e a sua inversa é dada por (GOMES e VELHO, 1999):

$$f(u) = \frac{1}{\|g\|^2} \iint_{\omega, t} g(u - t) e^{i\omega u} \tilde{f}(t, \omega) d\omega \quad (2.17)$$

Uma análise precisa das informações de uma função  $f \in L^2(\mathbb{R})$  pode ser obtida utilizando uma função  $g$  com boas propriedades de localização no domínio tempo-frequência  $(t, \omega)$ . Entretanto, existe um limite para a precisão dessa localização, decorrente de um princípio que governa as transformadas nesse domínio, conhecido como o princípio da incerteza.

De acordo com o princípio da incerteza, não é possível obter uma localização precisa no domínio do tempo e no da frequência simultaneamente. A explicação para isso é simples, para medir frequências é necessário observar o sinal ao longo de um período de tempo, quanto maior for a precisão das medidas de frequência, maior deve ser o intervalo de tempo a ser observado. Assim, se a função  $g$  é bem localizada na frequência, o período de tempo  $T$  deve ser grande, conseqüentemente  $g$  não possui boa localização no tempo. O mesmo raciocínio se aplica quando  $g$  é bem localizada no tempo (MALLAT, 1998).

A WFT utiliza uma escala dada pela largura da janela e analisa o sinal do ponto de vista dessa escala. Se o sinal tem detalhes de frequência fora dessa escala, haverá problemas em sua análise:

- Se os detalhes do sinal são muito menores do que a escala ou a largura da janela, haverá um problema similar ao da Transformada de *Fourier*: os detalhes serão detectados, mas a transformada não poderá localizá-los.
- Se os detalhes são maiores do que a escala, eles não serão detectados apropriadamente.

Para resolver esse problema deve-se utilizar uma transformada que seja independente da escala, que utilize uma escala variável ao invés de uma escala fixa. A transformada *Wavelet*, apresentada na próxima seção, possui essa propriedade.

## 2.3 A TRANSFORMADA WAVELET

A transformada *Wavelet* resolve o problema da Transformada de *Fourier* em Janelas, utilizando escalas variáveis ao invés de uma escala fixa. A escala é definida pela largura da função de modulação, portanto, para que a escala seja variável, essa função deve ter largura variável. Além disso, a função deve ter boa localização no domínio do tempo.

As *Wavelets* são funções matemáticas que possuem algumas propriedades específicas. De forma geral, estas funções satisfazem as seguintes condições (TEOLIS, 1998):

1. Deve possuir energia concentrada e finita, conforme Equação 2.18, onde  $E$  é a energia da função  $\psi(t)$ .

$$E = \int_{-\infty}^{+\infty} |\psi(t)|^2 dt < \infty \quad (2.18)$$

2. Deve exibir oscilação no tempo.

Seja  $\hat{\psi}(f)$  a transformada de *Fourier* da função  $\psi$ , dada pela Equação 2.19,

$$\hat{\psi}(f) = \int_{-\infty}^{+\infty} \psi(t) e^{-i(2\pi f)t} dt \quad (2.19)$$

então, a seguinte condição descrito na Equação 2.20:

$$C_{\psi} = \int_0^{+\infty} \frac{|\hat{\psi}(f)|^2}{f} df < \infty \quad (2.20)$$

A Equação 2.20 é chamada de condição de admissibilidade e  $C_{\psi}$  constante de admissibilidade. Para que a função  $\psi$  satisfaça essa condição, ela não pode possuir componente de frequência zero, ou seja, se  $\psi(u)$  é contínua, então  $\hat{\psi}(0) = 0$  (ADDISON, 2002).

Geometricamente, essa condição exige que o gráfico da função  $\psi$  oscile de forma que as áreas positivas e negativas se cancelem (GOMES e VELHO, 1999), como mostra a Figura 2.18.




Figura 2.18 - Gráfico da Wavelet chapéu mexicano.

Essas condições, necessárias para que uma função seja considerada uma *Wavelet* e que deram origem a esse nome. Literalmente, *Wavelet* é uma palavra oriunda do termo francês “*ondelette*” (onda pequena). O termo “onda” se justifica, pois as funções *Wavelet* oscilam até que suas extremidades se anulem, devido a isso a média de qualquer família de *Wavelet* é nula. O termo “pequena” caracteriza a função *Wavelet*, pois exige que a onda seja bem localizada no domínio do tempo e da frequência. A Figura 2.19 mostra algumas *Wavelets* muito utilizadas na prática.




Figura 2.19 - Algumas *Wavelets*.


### 2.3.1 Famílias de Funções *Wavelet*

Para que a Transformada *Wavelet* seja capaz de resolver o problema da Transformada de *Fourier* em Janelas, é necessário obter uma função de modulação que apresente escala e localização no tempo, variáveis. Para obter funções com estas características, inicia-se com uma função  $\psi(t)$ . Variando a escala dessa função, obtém-se uma família de funções.

Assim, para  $p \geq 0$ , para todo  $s \in \mathbb{R}, s \neq 0$ , tem-se (GOMES e VELHO, 1999) a função  $\psi_s(u)$ , conforme Equação 2.21.

$$\psi_s(u) = |s|^{-p} \psi\left(\frac{u}{s}\right) = \frac{1}{|s|^p} \psi\left(\frac{u}{s}\right) \quad (2.21)$$

Se  $\psi$  tem largura  $T$ , então a largura de  $\psi_s$  é  $sT$ . A modulação da função  $\psi$  pelo fator  $\frac{1}{|s|^2}$  aumenta sua amplitude enquanto sua escala  $s$  diminui e vice-versa. Em termos de freqüência, para valores menores da escala  $s$ ,  $\psi_s$  tem altas freqüências, e à medida que  $s$  aumenta a freqüência de  $\psi_s$  diminui (GOMES e VELHO, 1999). Isso está ilustrado na Figura 2.20.



**Figura 2.20 - Escalas de uma Função.**


Assim como na Transformada de *Fourier* em Janelas, é necessário localizar cada função  $\psi_s$  no tempo. Por isto, para cada  $\psi \in \mathbb{R}$ , a Equação 2.22 é definida.

$$\psi_{s,t}(u) = \psi_s(u - t) = |s|^{-p} \psi\left(\frac{u - t}{s}\right) = \frac{1}{|s|^p} \psi\left(\frac{u - t}{s}\right), \quad (2.22)$$

A Equação 2.22 possibilita que uma função *Wavelet*  $\psi$ , conhecida como *Wavelet* mãe ou função de base, gere uma família de *Wavelets* por meio de duas operações: a de translação e a de dilatação (ADDISON, 2002; MALLAT, 1998).


A equação *Wavelet* mãe chapéu mexicano, é descrita pela Equação 2.23. A dilatação é determinada pelo valor de  $s$  e consiste em expandir e contrair a *Wavelet* mãe, permitindo aumentar ou diminuir sua amplitude, como mostra a Figura 2.21.

$$\psi(t) = (1 - t^2)e^{\frac{-t^2}{2}} \quad (2.23)$$



**Figura 2.21 - Dilatação da *Wavelet* Chapéu Mexicano.**

A translação é determinada pelo valor de  $t$  e consiste em movimentar a *Wavelet* mãe ao longo do eixo do tempo. A Figura 2.22 ilustra a translação da *Wavelet chapéu mexicano*:



**Figura 2.22 - Translação da *Wavelet* Chapéu Mexicano.**

Por meio dessas duas operações, pode-se deslizar a função *Wavelet* sobre o sinal a ser analisado e expandi-la ou contraí-la de forma que haja correspondência entre a função e o sinal. Isso é o que a transformada *Wavelet* faz. Matematicamente, essa transformada é definida no espaço  $L^2(\mathbb{R})$ .

### **2.3.2 A Transformada *Wavelet* Discreta**

A Transformada *Wavelet* Discreta (DWT) de uma função contínua  $f(t)$  é definida com a discretização dos valores de escala  $s$  e de localização  $t$ . Sabe-se que a operação de dilatação é multiplicativa, e a sua discretização é simples: fixa-se um

valor de escala inicial  $s_0 > 1$  e obtêm-se as escalas discretas, conforme Equação 2.24.

$$s_m = s_0^m, m \in \mathbb{Z} \quad (2.24)$$

Valores positivos de  $m$  produzem escalas maiores que 1, enquanto valores negativos produzem valores de escala menores que 1.

Quanto à discretização do tempo, é importante observar que se deve obter uma relação entre tempo e escala de forma que seja possível reconstruir uma função  $f$  a partir dos coeficientes gerados do cálculo de sua transformada,  $\tilde{f}_{s,t}$ , utilizando essa relação e com o mínimo de redundância (GOMES e VELHO, 1999).

O valor da escala influencia na largura da *Wavelet*, com o aumento da escala a largura da *Wavelet* também aumenta, logo, abrange um intervalo de tempo maior. Por outro lado, com a diminuição da escala, a largura da *Wavelet* diminui e é necessário aumentar a frequência, para que ela continue a abranger o mesmo intervalo de tempo.

Para obter uma correlação exata entre tempo e escala, deve-se levar em consideração a seguinte propriedade da transformada *Wavelet*: quando se altera a escala da função  $f$  e, simultaneamente, altera-se a escala no domínio do tempo pelo mesmo fator de escala, a transformada *Wavelet* não muda. É importante que essa propriedade da transformada seja preservada na sua discretização, a fim de que ela que seja válida para a DWT. Para alcançar esse objetivo, quando se passa da escala  $s_m = s_0^m$  para a escala  $s_{m+1} = s_0^{m+1}$ , é necessário incrementar o valor do tempo pelo fator de escala  $s_0$ . Assim, escolhe-se um tempo inicial  $t_0$  e obtêm-se o comprimento do intervalo de amostragem:  $\Delta t = s_0^m t_0$ . Portanto, para cada valor de escala  $s_0$ , o valor do tempo é dado por (GOMES e VELHO, 1999):

$$t_{m,n} = n s_0^m t_0, n \in \mathbb{Z} \quad (2.25)$$

Considerando os valores discretos dos parâmetros escala e tempo definidos, a seguinte equação define a DWT (ADDISON, 2002):

$$\psi_{m,n}(u) = \frac{1}{\sqrt{s_0^m}} \psi\left(\frac{u - nt_0 s_0^m}{s_0^m}\right) \quad (2.26)$$

Nessa equação, os inteiros  $m$  e  $n$  controlam a dilatação e a translação respectivamente;  $s_0$  é um parâmetro inicial de dilatação, seu valor deve ser maior que 1; e  $t_0$  é um parâmetro inicial de localização, seu valor deve ser maior que zero. A transformada *Wavelet* de um sinal contínuo  $f(u)$ , utilizando a forma discreta de *Wavelet* definida na Equação 2.26 é dada por (ADDISON, 2002).

$$T_{m,n} = \int_{-\infty}^{+\infty} \frac{1}{\sqrt{s_0^m}} \psi(s_0^{-m}u - nt_0) du, \quad (2.27)$$

onde  $T_{m,n}$  são os valores da transformada discreta *Wavelet*, calculados em uma grade de valores de escala e de tempo, no índice  $m, n$ . Para a DWT, os valores de  $T_{m,n}$  são conhecidos como coeficientes *Wavelet* discretos.

As Figuras 2.23 e 2.24 estão representadas, respectivamente, as seguintes *Wavelet*'s: *Filtro bi-ortogonal* com 6 coeficientes  $a_k$  e 8  $b_k$  e *Daubechies* de nível 2.




Figura 2.23 – *Wavelet* mãe com Filtro bi-ortogonal 6.8.




Figura 2.24 – Wavelet mãe Daubechies de nível 2.

### 2.3.3 A Transformada Wavelet Inversa


Um aspecto importante relacionado à transformada *Wavelet* refere-se à sua inversibilidade. Se uma função  $\psi$  satisfaz a condição de admissibilidade, então a transformada *Wavelet*  $\tilde{f}(s,t)$  é inversível e a Equação 2.28 reconstrói a função  $f$  a partir de sua transformada (GOMES e VELHO, 1999).

$$f(u) = \frac{1}{C} \iint |s|^{2p-3} \tilde{f}_{s,t}(u) \psi_{s,t}(u) ds dt \quad (2.28)$$


Assim, por meio da transformada *Wavelet*, uma função  $f$  pode ser decomposta como uma sobreposição de funções  $\psi_{s,t}(u)$  e, por meio da transformada inversa, a função  $f$  pode ser reconstruída a partir de sua transformada  $\tilde{f}_{s,t}(u)$ .

### 2.3.4 Decomposição e Reconstrução de Imagens

Inicialmente, nessa subseção pode-se observar algumas imagens e suas superfícies tridimensionais, mostradas nas Figuras 2.25 e 2.26.




**Figura 2.25 – Superfície de uma amostra do banco de dados representando a superfície onde a coordenada z branco(255).**




**Figura 2.26 – Superfície de uma amostra do banco de dados representando a superfície onde a coordenada z branco(255).**


Apesar de não ser o intuito desse trabalho, nas Figuras 2.27 a 2.30 é apresentado a decomposição de imagens digitais em coeficientes de aproximação e de detalhes e a sua reconstrução a partir desses coeficientes.




**Figura 2.27 – Imagem Original da Digital e sua Reconstrução (Haar 1º nível).**



**Figura 2.28 – Imagem Original da Digital e sua Reconstrução (Daubechies 3º nível).**



**Figura 2.29 – Imagem Original da Digital e sua Reconstrução (Bi-ortogonal 5º nível).**




**Figura 2.30 – Imagem Original da Digital e sua Reconstrução (Bi-ortogonal 7º nível).**

Tanto a decomposição quanto a reconstrução são executadas de forma hierárquica, em que se têm escalas de diferentes níveis de resolução, isto é, quanto menor a escala, maior a resolução.

Analisando a reconstrução das imagens comparando o valor do erro médio quadrático (*RMS - Root Mean Square*) entre a matriz real e a reconstruída, obteve-se sempre os mesmos valores na ordem de  $10^{-16}$ .

## 2.4 AS REDES NEURAIS ARTIFICIAIS

Atentos aos estudos de neurociência, o neurologista Warren McCulloch e o matemático Walter Pitts, em 1943, publicaram um artigo chamado “*A logical Calculus of the Ideas Immanent in Nervous Activity*”. Neste trabalho eles desenvolveram um modelo matemático análogo ao neurônio biológico, denominado neurônio artificial McCulloch-Pitts, que possui múltiplas entradas e uma única saída, onde cada uma das entradas possui um peso associado, como no esquema mostrado na Figura 2.31.



**Figura 2.31 – Esquema de um Neurônio de McCulloch-Pitts.**

onde  $x_i$  são as entradas,  $w_i$  são os pesos associados às entradas,  $u$  é o somador dos produtos das entradas com os pesos, como mostrado na Equação 2.29,  $f(u)$  é a função de ativação não-linear e  $y$  é a saída da rede.

$$u = \sum_{i=0}^n x_i w_i \quad (2.29)$$

O neurônio artificial possui duas fases de processamento. Na primeira fase calcula-se o somatório do produto das entradas pelos pesos associados. Na segunda fase é atribuída uma função não linear  $f(u)$ , chamada de função de ativação, que é aplicada ao somatório  $u$  resultante da primeira fase.

Em 1956 nasceram os dois paradigmas da Inteligência Artificial, o simbólico e o conexionista, onde o primeiro tenta simular comportamento inteligente humano

desconsiderando os mecanismos responsáveis por tal. Já o segundo acredita que, construindo-se um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros.

Em 1958, Roseblatt deu mais um passo no desenvolvimento das RNAs, quando mostrou em seu livro modelo da rede "*Perceptron*". Nela, os neurônios eram organizados em camada de entrada e saída, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica. Seu interesse inicial para a criação do Perceptron era o reconhecimento de padrões.

Em 1960 surgiram as redes *Adaline* (*Adaptive Linear Network*), equipada com uma poderosa lei de aprendizado, e a *Madaline* (*Many Adaline*), que era o "*perceptron*" proposto por Widrow e Hoff. Estas redes utilizam uma arquitetura de três camadas com função de ativação linear.

Alguns históricos sobre a área costumam "pular" os anos 60 e 70 e apontar um reinício da área com a publicação dos trabalhos de Hopfield (1982) relatando a utilização de redes simétricas para otimização e de RUMELHART et al., Hinton e Williams que introduziram o poderoso método *Backpropagation*.

Entretanto, para se ter um histórico completo, deve ser citado alguns pesquisadores que realizaram, nos anos 60 e 70, importantes trabalhos sobre modelos de redes neurais em visão, memória, controle e auto-organização como: Amari, Anderson, Cooper, Cowan, Fukushima, Grossberg, Kohonen, von der Malsburg, Werbos e Widrow.

Uma rede neural artificial consiste em um sistema de processamento de dados, com muitos neurônios artificiais interconectados e organizados em seqüências de camadas. Este arranjo entre camadas de neurônios configura a arquitetura de uma rede neural artificial, inspirado na estrutura cerebral do córtex. As camadas de uma rede neural são interconectadas através de parâmetros internos denominados pesos ( $w$ ). A camada de entrada somente apresenta os dados à rede neural, ela não possui neurônios de processamentos e a camada de saída resulta

nos valores de saída da rede. As outras camadas são chamadas de intermediárias ou ocultas. A arquitetura da rede neural mostrada na Figura 2.32, por exemplo, é composta por uma camada de entrada com três neurônios, uma camada de saída com dois neurônios e uma camada oculta com cinco neurônios.




Figura 2.32 – Arquitetura de uma rede *FeedForward*.

As redes neurais com arquitetura de tipo *feedback* (realimentada), possuem um processo de obtenção das operações matemáticas para as saídas mais complexo, porém, uma vez treinada, as saídas são calculadas instantaneamente. A Figura 2.33 mostra o esquema de uma rede recorrente, onde a rede possui entradas  $u_n(0)$ , passando por somatórios e pelas funções da rede, então cada saída da rede tem uma conexão de realimentação para camada anterior. São exemplos de redes recorrentes as redes de Hopfield (1982) e Kohonen (1984). A rede recorrente apresenta uma realimentação após a propagação, o que favorece o treinamento.

Deste modo a rede é treinada com propagações e realimentações, até que haja um equilíbrio entre as entradas, pesos e saídas ou algum critério de convergência seja atingido. Estas redes recorrentes não serão tratadas neste trabalho.




Figura 2.33 – Arquitetura de uma rede neural recorrente.

Quando a rede neural não apresenta em sua arquitetura interconexões entre os neurônios de uma mesma camada ou interconexão de realimentação (*feedback*) com neurônios de camadas anteriores, e a rede é caracterizada por um fluxo unidirecional recebe o nome de rede neural *feedforward*. Nesse tipo de rede, o vetor de entradas é aplicado à camada de entrada, então as funções de ativação são rapidamente calculadas e o processo flui da camada de entrada para a camada oculta e desta para a camada de saída. O aprendizado da rede, ou seja, o ajuste dos pesos é realizado através de treinamento supervisionado. Após o treinamento, a rede é capaz de mapear uma simples entrada em uma saída desejável. São exemplos clássicos de redes *feedforward* as redes *adeline*, *madeline* e *perceptron*.

As redes neurais de associação linear são os tipos mais elementares de redes. Sua arquitetura é muito simples, dispondo de uma camada de entrada e uma de saída, onde estas camadas são interconectadas conforme Figura 2.34. A função de ativação da camada de saída é linear. Inicialmente, a partir de um conjunto de entradas e saídas padrões, retiram-se pares de entradas padrões com suas saídas correspondentes. A rede aprende quando existe entrada ativa, que ocorre quando

uma entrada padrão produz, para um determinado conjunto de pesos, uma saída padrão. Para que todas as entradas se tornem ativas, é necessário o treinamento da matriz de pesos. A vantagem das redes com associação linear é a habilidade que apresentam para aprender mais de um padrão de saída simultaneamente.




Figura 2.34 – Rede neural com associação linear.

Será apresentado agora o aprendizado de *Hebbian* para treinamento de RNAs, redes *Instar* e *Outstar* e Rede Neural Probabilística (*PNN – Probabilistic Neural Network*).

### 2.4.1 O aprendizado de *Hebbian*

Em 1949, Donald Hebb, propôs uma forma de aprendizado que passou a ser, atualmente, denominada de treinamento de *Hebbian*, onde é proposto um treinamento auto-organizável para a RNA. Muitas redes utilizam este tipo de aprendizado devido ao sucesso obtido por esse treinamento de redes neurais nas últimas décadas.

Um problema não solucionado no treinamento de *Hebbian* é que questões básicas e que permanecem sob investigação não ainda solucionado é da estrutura

da RNA, tais como: qual a quantidade de neurônios nas camadas ocultas ou qual a quantidade de camadas ocultas da RNA?

Existem muitas variações do aprendizado de *Hebbian*, uma delas foi proposta por Steven Grossberg, que desenvolveu uma ponderação matemática apresentada na Equação 2.30.

$$w_{AB}^{novo} = w_{AB}^{velho}(1 - \alpha) + \beta x_B x_A \quad (2.30)$$

onde  $w_{AB}^{novo}$  é o peso atualizado a partir do  $w_{AB}^{velho}$  que é ponderado por coeficientes que estimulam o aprendizado e o esquecimento. O termo  $\alpha$  corresponde ao “esquecimento” que, fazendo uma analogia aos sistemas biológicos, é tal como se esquece ou se aprende com o tempo. Já o  $\beta$  é a constante de “aprendizagem” que quantifica o quão a rede está no caminho de seu treinamento. Geralmente,  $\alpha$  e  $\beta$  são adotados entre 0 e 1.

### 2.4.2 Rede Instar e Rede Outstar

Todo neurônio biológico envia centenas ou milhares de informações por suas sinapses que vem de uma seqüência de axônios de outros neurônios. Isto pode computacionalmente ser representado por uma estrela (*star*) com trajetos radiais direcionadas para fora. Uma interpretação geométrica da rede *Outstar* pode ser vista na Figura 2.35 (à esquerda), onde neste tipo de rede há apenas uma entrada e várias saídas, enquanto na rede *Instar* há várias entradas e uma única saída como pode ser visto na Figura 2.35 (à direita).




Figura 2.35 – Representação de rede *Outstar* (à esquerda) e *Instar* (à direita).

Nessa rede, o número mínimo de neurônios artificiais ativado promove a recordação de um padrão, o que é o núcleo da *Outstar*. Estimulando repetidamente no núcleo do neurônio e, simultaneamente, inserir estímulos com padrões nos  $m$  neurônios na borda da rede *Outstar*, ou a grade de neurônios conforme Figura 2.36, onde cada conexão ligada ao núcleo do neurônio, eventualmente resultarão nos mesmos padrões que refletem a saída padrão apresentada à RNA.




Figura 2.36 – Uma rede de aprendizado *Outstar*.

O aprendizado da rede *Outstar*, proposto por Grossberg, é baseado no aprendizado de *Hebbian*, isto é, se o estímulo chega ao neurônio de entrada, então o peso associado com esta ligação vai aumentar baseando associar os pesos às saídas da rede. No aprendizado *Outstar*, o aumento de peso depende do produto dos sinais das entradas e saídas para a grade de neurônios. Após um número de ciclos, as regiões (*clusters*) vão corresponder a pesos medianos. Os aprendizados neo-Hebbianos adicionam um termo de esquecimento. Então, no aprendizado neo-Hebbiano, os pesos que não aumentam, diminuem gradualmente.

### **2.4.3 Redes Probabilísticas (PNN)**

As Redes Neurais Probabilísticas (*PNN – Probabilistic Neural Networks*) foram desenvolvidas por Donald Specht, e é uma técnica específica para problemas que buscam a classificação de padrões. Matematicamente, um vetor de entrada é treinado para determinar os padrões que são saídas pré-definidas da rede. A PNN usa dados de treinamento que envolvem regiões (*clusters*) que são usadas para estimar a probabilidade de um vetor estar alocado e associado à essas regiões.

A rede neural probabilística tal como mostrado na Figura 2.37 possui quatro camadas. A camada de entrada se relaciona com a camada de padrões definida de tal forma que a rede de camadas intermediárias se propaga para a camada de saída onde cada neurônio das camadas intermediárias possui uma função de ativação.




Figura 2.37 – Representação da rede neural probabilística.

A função de ativação não-linear usada pela camada de padrões é uma função exponencial como mostrada na Figura 2.38. Essa função de ativação é apresentada na Equação 2.31.

$$\phi(I_i) = e^{\left[\frac{(I_i-1)}{\sigma^2}\right]} \quad (2.31)$$

onde  $I$  é o peso correspondente a cada entrada ao seu neurônio e o  $\sigma$  é um parâmetro que torna a função de ativação não muito abrupta na transição de 0 a 1. Normalmente, utiliza-se  $\sigma$  entre 0,1 a 10.




Figura 2.38 – Representação gráfica da função de ativação (Equação 2.31).

### 3 METODOLOGIAS PROPOSTAS

Neste capítulo são apresentadas as duas metodologias propostas, as quais utilizam como *Wavelet* mãe, filtros bi-ortogonais, tal como é utilizado pelo FBI. Enquanto o FBI manipula milhões de imagens, este trabalho não foi baseado em análise quantitativa, e sim, qualitativa. Para tanto, foi adquirido através de um *hardware* da *Microsoft*<sup>®</sup>, 128 digitais, sendo 64 previstas para treinamento da RNA e as demais para validação, isto é, para cada um dos 16 indivíduos foram adquiridas 8 digitais. O que distingue cada metodologia é o tipo de RNA utilizada.

Após tentar usar técnicas de processamento, tais como a transformada de *Fourier* Bi-dimensional, tratamento via Função de Auto-Correlação, dentre outras, não se obteve um padrão propício para treinamento de um RNA.

Enquanto, na primeira metodologia foi feito um tratamento estatístico com os coeficientes que apresentaram coerência para treinamento da RNA *Outstar*, na outra metodologia não foi feito nenhum tratamento estatístico e foram utilizados dois coeficientes para definição de uma região no plano (*cluster*) para cada conjunto de dedos.

Enquanto, a primeira metodologia utiliza-se a média do coeficiente  $c_3$  para formação do conjunto de treinamento, a segunda utilizou-se os coeficientes  $c_3$  e  $c_4$ . Contudo, enquanto primeira metodologia proposta foi necessária a eliminação de amostras na outra utilizou-se todo o banco de dados. Para a outra metodologia, todas as 128 imagens foram recortadas sempre nas mesmas coordenadas, buscando manter suas características distintas que estão presentes na região central<sup>3</sup>. Para entendimento de cada uma das metodologias, elas serão detalhadas e apresentadas a seguir.

---

<sup>3</sup> No Anexo C encontra-se as imagens originais (antes de recortá-las), onde, da Figura A1 à A64 corresponde aos dados de treinamento e da Figura B1 à B64, os dados de validação.

### 3.1 METODOLOGIA A: *WAVELET* E REDES NEURAIS COM TREINAMENTO DE *HEBBIAN*


Para aplicar a metodologia foi necessário definir a ordem do filtro bi-ortogonal, observando qual situação em que os coeficientes da *Wavelet* apresentavam coerência. Para se chegar ao filtro ideal foi necessária a investigação do filtro bi-ortogonal com várias combinações dos coeficientes  $a_k$  e  $b_k$  do filtro de acordo com a Tabela 3.1, num total de 15 combinações e foi escolhida a combinação com 6  $a_k$  e 8  $b_k$ . Esse filtro foi ilustrado na Figura 2.23.

**Tabela 3.1 - Filtro Bi-ortogonal ( $a_k$ ,  $b_k$ ).**

| $a_k$ | $b_k$           |
|-------|-----------------|
| 1     | 1, 3 ou 5       |
| 2     | 2, 4, 6 ou 8    |
| 3     | 1, 3, 5, 7 ou 9 |
| 4     | 4               |
| 5     | 5               |
| 6     | 8               |


Além da análise da variação  $a_k$  e  $b_k$ , foi feita a análise das várias combinações entre os 4 coeficientes da *Wavelet* ( $c_1$ ,  $c_2$ ,  $c_3$  e  $c_4$ ), quanto à média entre eles.

Os gráficos da Figura 3.1 abaixo mostram que apenas o coeficiente  $c_3$  mostrou coerência.



**Figura 3.1 - Gráfico das médias do coeficiente  $C_3$  extraído pelo filtro bi-ortogonal para as amostras de treinamento e validação.**

Desta forma, foram tiradas as médias do coeficiente  $c_3$  de cada dedo, e foi então, montado o gráfico da Figura 3.2, que apresenta os dados de treinamento na cor azul e os de validação em vermelho.




**Figura 3.2 - Gráfico das médias dos coeficientes C3 extraídos pelo filtro bi-ortogonal para as amostras de treinamento e validação.**

Observando novamente a Figura 3.2, pode-se notar que alguns dedos, ou não tiveram padrão entre o treinamento e a validação, ou os padrões obtidos estão em patamares parecidos com outros dedos, o que daria problema para treinamento da rede. Por este motivo alguns dedos tiveram que ser eliminados para que o treinamento pudesse ser efetivado. Do total de 16 dedos, 9 foram eliminados, porém, poderiam ter sido multiplicado por uma constante diferente cada um tal que, fugissem do patamar dos outros dedos. Desta forma, o banco de dados poderia ser maior. Contudo, a metodologia foi aplicada a apenas 7 dedos quais sejam os dedos de treinamento A1, A2, A5, A6, A7, A14 e A16, e os de validação B1, B2, B5, B6, B7, B14 e B16.


A Figura 3.3 apresenta o diagrama de blocos para treinamento da rede usando o aprendizado de *Hebbian* conforme foi descrito no item 2.4.1, onde ao conjunto A que é formado pelo banco de dados de treinamento, foi aplicado uma análise estatística, e, após a extração de 4 coeficientes de cada dedo, pelo filtro bi-ortogonal 6.8 foi feita a média do coeficiente 3. Todas as médias dos coeficientes de cada dedo foram normalizadas entre -1 e 1 buscando um maior condicionamento da rede. O alvo, que define os que vão ou não possuir acesso foi definido de forma binária, onde foi adotado 0 para o acesso negado e 1 para acesso permitido. Os coeficientes e o alvo são, respectivamente, as entradas e saídas da rede neural que

após treinamento é obtido um conjunto de pesos segundo um critério de convergência.




**Figura 3.3 – Diagrama de blocos de treinamento baseado em treinamento *Hebbiano*.**

Na Figura 3.4 é mostrado o diagrama de blocos para a validação, onde o conjunto B, de validação, passa pelo mesmo processo de aplicação da *Wavelet* até a média dos coeficientes 3 de cada dedo do Conjunto B e normalização entre -1 e 1. Esses são apresentados à rede treinada que resulta num alvo.




**Figura 3.4 – Diagrama de blocos de validação com o Conjunto B que atinge o alvo requerido.**


Com essa metodologia foram feitos 3 testes para os mesmos conjuntos de treinamento e validação. O que foi modificado em cada teste foi o alvo onde é possível maior a quantidade de acesso negado. O teste 1, apresentado na Figura 3.5 nega o acesso a 1 indivíduo (dedo 7). O teste 2, apresentado na Figura 3.6 nega o acesso a 2 indivíduos (dedos 2 e 5) e o teste 3, apresentado na Figura 3.7, nega o acesso a 4 indivíduos (dedos 1, 2, 5 e 7).



**Figura 3.5 – Teste 1:** Os dois gráficos superiores são os dedos e alvo com 1 acesso negado, e os gráficos inferiores, os respectivos dados e alvo de treinamento e validação.



**Figura 3.6 – Teste 2: Os dois gráficos superiores são os dedos e alvo com 2 acessos negados, e os gráficos inferiores, os respectivos dados e alvo de treinamento e validação.**



**Figura 3.7 – Teste 3: Os dois gráficos superiores são os dedos e alvo com 4 acessos negados, e os gráficos inferiores, os respectivos dados e alvo de treinamento e validação.**


Com base nos 3 testes apresentados, além dos outros aqui não mostrados, foram todos 100% validados. Ou seja, essa metodologia mostrou-se bastante eficiente.

### 3.2 METODOLOGIA B: WAVELET E REDE NEURAL PROBABILÍSTICA

Da mesma forma foi aplicado a *Wavelet* com filtro bi-ortogonal com 6 parâmetros  $a_k$  e 8  $b_k$ .


Porém, neste caso foram utilizadas todas as amostras de treinamento e validação. Para cada dedo, utilizando os coeficientes  $c_3$  e  $c_4$ , gerou-se um ponto no plano  $xy$  e percebeu-se que eles se aglomeravam de forma eqüidistante, formando regiões específicas (*clusters*).

A Figura 3.8 apresenta o diagrama de blocos para treinamento, onde duas regiões do espaço foram classificadas em duas classes 1 e 2 que corresponde à permissão ou não do acesso.




**Figura 3.8 – Diagrama de blocos de treinamento baseado em treinamento por RNA probabilística.**

Já a Figura 3.9 mostra o diagrama de blocos de validação da rede os coeficientes  $c_3$  e  $c_4$  do Conjunto B é apresentado à rede treinada, resultando no alvo.




**Figura 3.9 – Diagrama de blocos de validação com o Conjunto B que atinge o alvo requerido.**

Então duas grandes regiões foram definidas, classes 1 e 2, à esquerda um oval indicando os dedos com acesso e à direita um oval indicando os dedos sem permissão, tanto para os 64 dedos de treinamento e 64 de validação, conforme mostra a Figura 3.10.



**Figura 3.10 – Teste da rede Probabilística: Os gráficos mostram os dados de treinamento e validação em suas respectivas classes, onde para a classe 1 permite o acesso e a classe 2 nega o acesso.**

Os dedos dos gráficos da Figura 3.10 de cada região são os dados de entrada da rede neural, que correspondem às saídas 1 ou 2, conforme sua localização.



**Figura 3.11 – Resultado da Validação da Rede Neural Probabilística.**

Após o treinamento da rede, os dedos do gráfico da Figura 3.11 são apresentados à rede treinada e 100% do alvo foi atingido.

## 4 CONCLUSÃO

Nesse trabalho de conclusão de curso, duas novas teorias foram estudadas e entendidas, quais sejam a Transformada de *Wavelet* e Redes Neurais Artificiais. Além de obviamente, evoluir, também, no uso do *software Matlab*<sup>®</sup> no que se refere às técnicas de processamento de sinais digitais.

Desta forma, primeiramente foi apresentada fundamentação teórica dos Filtros Digitais, seguido da Transformada de *Fourier* 1D e 2D, Transformada de *Wavelet* e a Teoria das Redes Neurais Artificiais.

Quanto ao *hardware* utilizado para aquisição das imagens, não foi uma escolha bem adequada, pois, após a aquisição do utilizado neste trabalho, descobriu-se outros *hardwares* com melhor resolução.

Assim, diante do projeto de controle automático ao acesso, inicialmente proposto, conclui-se que as metas foram atingidas uma vez que duas metodologias foram obtidas e validadas computacionalmente.

Quanto à metodologia B, que se refere à Rede Neural Probabilística, tem uma desvantagem de ter que definir inicialmente os dedos que têm acesso e os que não têm. Isto é, dado amostras de um novo indivíduo, ele pode vir a participar da classe que tem acesso ou não. Facilmente esse caso específico pode ser solucionado invertendo a saída referente a esse indivíduo específico. A comprovação computacional dessa metodologia foi mostrada na Figura 3.11.

Devido a esse fato, elege-se a metodologia A como a mais eficiente, e propícia para ser implementada em um microcontrolador, que envia um sinal para acionar ou não uma fechadura elétrica. Nesta metodologia, 3 testes foram mostrados, onde a ordem dos indivíduos que entram ou não foi alterada, como visto nas Figuras 3.5 a 3.7, respectivamente.

Como visto e discutido, a desvantagem dessa metodologia foi a necessidade de se multiplicar por um ganho, um indivíduo que tiver a mesma média do coeficiente escolhido ( $c_3$ ).

As futuras perspectivas deste trabalho são tornar o sistema de controle de acesso totalmente experimental, avaliando em microprocessadores as duas metodologias, e, avançar mais nas pesquisas, com a possibilidade de uma proposta de mestrado.

## 5 REFERÊNCIAS BIBLIOGRÁFICAS

- 1 ADDISON, P. S., 2002, "**The Illustrated Wavelet Transform Handbook Introductory Theory and Applications in Science**", Engineering, Medicine and Finance. [S.l.]: Institute of Physics Publishing Bristol and Philadelphia.
- 2 BALDI, P., CHAUVIN, Y., 1993, "Neural Networks for Fingerprint Recognition", **Neural Computation**, n. 5, p. 402-418.
- 3 GOMES J.; VELHO, L., 1999, "**From Fourier Analysis to Wavelets**", 1999, 1th. ed. Instituto de Matemática Pura e Aplicada, IMPA, Rio de Janeiro, Brazil: Prentice Hall, Inc.
- 4 HUNG, D. C. D., 1993, "Enhancement and Feature Purification of Fingerprint Images", **Pattern Recognition**, v. 26, n. 11, p. 1661-1671.
- 5 KARU, K., JAIN, A. K., 1996, "Fingerprint Classification", **Pattern Recognition**, v. 29, n. 3, p. 389-404.
- 6 MALLAT, S., 1998, "**A Wavelet Tour of Signal Processing**". [S.l.]: Academic Press.
- 7 MATLAB.EXE: "Toolboxes de Wavelet e Redes Neurais Artificiais", Versão 7.0.0.19920 (R14): Mathworks, 2004. 2CDs. Configuração mínima: Pentium III ou mais avançado.
- 8 RATHA, N. K., CHEN, S., JAIN, A. K., 1995, "Adaptive Flow Orientation-Based Feature Extraction in Fingerprint Images", **Pattern Recognition**, vol. 28, n. 11, p. 1657-1672.
- 9 RUMELHART, D. E., WIDROW, B., LEHR, M. A., 1994, "The Basic Ideas in Neural Networks", **Communications of the ACM**, vol. 37, n. 3, p. 87-92.

- 10 STRANG, G., NGUYEN, T., 1997, "Digitized Fingerprints and the FBI", **Wavelets and Filter Banks**, ISBN 0-9614088-7-1.
- 11 TEOLIS, A., 1998, "**Computational Signal Processing with Wavelets**". [S.I.]: Springer-Verlag Birkhäuser, ISBN 3-7643-3909-8, 324 p.

## 6 SITES ACESSADOS

- 1 APPEGO – Associação dos Papiloscopistas Policiais do Estado de Goiás, “**A Datiloscopia e a Datilograma**”, 2007, Disponível em: <<http://www.appego.com.br/?pag=conteudo&id=35>>. Acesso em: 28/11/2008
- 2 CBA – Consultores Biométricos Associados, “**Uma Introdução à Biometria e Sua História Geral**”, 2008, Disponível em: <[http://www.consultoresbiometricos.com.br/05\\_Bintroducao\\_definicao.php](http://www.consultoresbiometricos.com.br/05_Bintroducao_definicao.php)>. Acesso em: 12/09/08
- 3 IHT – International Herald Tribune, “**Unlocking Market for Fingerprint Scanners**”, 2003, Disponível em: <[http://www.iht.com/articles/2003/07/28/btfingerprint\\_ed3\\_.php?page=1](http://www.iht.com/articles/2003/07/28/btfingerprint_ed3_.php?page=1)>. Acesso em: 15/10/2008.

## ANEXO A – HISTÓRICO DA IDENTIFICAÇÃO NO MUNDO

Fonte: (APPEGO, 2007)

**Ano 650 da era Cristã:** Código de *Yng-Hwui*, durante a dinastia de *Tang* na China, determinava-se que o marido desse um documento à divorciada, autenticando com a sua impressão digital.

**Ano 782:** Foram retiradas de cidades soterradas na areia, no Turquestão, placas de cerâmica lavradas com as seguintes palavras: "Ambas as partes concordam com estes termos que são justos e claros e afixam as impressões dos seus dedos, que são marcas inconfundíveis."

**Ano 800:** Na Índia, as impressões digitais eram conhecidas com o nome de *Tipsahi*, termo criado pelos tabeliães de Bengala, onde os analfabetos legalizavam os seus papéis.

**Ano 1300:** Os chineses empregavam a impressão digital não só nos divórcios, como também nos casos de crimes.

**Ano 1658:** Em muitos países empregaram-se o ferrete, a tatuagem e a mutilação, para identificar escravos e criminosos.

Na Pensilvânia, EUA, os criminosos eram marcados com uma letra feita com ferro em brasa sobre o dedo polegar esquerdo: A=adúltero, M=assassino, T=felonia.

Na França, os condenados às galés eram marcados com o sinal GAL. Ao lado do ferrete, empregou-se a mutilação.

Em Cuba, cortavam-se as orelhas dos escravos e narinas dos criminosos.

Nos EUA, se um homem casado praticasse sodomia, seria castrado, também se amputava as orelhas dos criminosos condenados.

**Ano 1664:** Marcelo Malpighi, médico italiano, publicou um trabalho intitulado "Epístola sobre o órgão do tato", no qual estuda os desenhos digitais e palmares.

**Ano 1823:** João Evangelista Purkinje apresentou à Universidade de Breslau, na Alemanha, uma tese na qual analisou os caracteres externos da pele, estudou o sistema déltico e grupou os desenhos digitais em nove tipos.

**Ano 1840:** Com o aparecimento da fotografia, passou a ser esta empregada como processo exclusivo de identificação criminal, inicialmente na Suíça.

**Ano 1856:** José Engel publicou o "Tratado do Desenvolvimento da Mão Humana", no qual fez estudos sobre os desenhos digitais. Engel afirmou que os desenhos digitais existem desde o sexto mês de vida fetal e reduziu para quatro os nove tipos descritos por Purkinje.

**Ano 1858:** William James Herschel, coletor do governo inglês, em Bengala, Índia, iniciou seus estudos sobre as impressões digitais: tomou as impressões digitais dos nativos nos contratos em que firmavam com o governo. Essas impressões faziam as vezes de assinatura.

Herschel, então, aplicou-as nos registros de falecimentos e usou este processo nas prisões para reconhecimento dos evadidos. Henry Faulds, inglês, médico de hospital em Tóquio, contribuiu para o estudo da dactiloscopia, examinando impressões digitais em peças de cerâmica pré-histórica japonesa. Faulds previu a possibilidade de se descobrir um criminoso pela identificação das linhas papilares e preconizou uma técnica para a tomada de impressões digitais, utilizando-se de uma placa de estanho e tinta de imprensa.

**Ano 1882:** O Sistema Antropométrico, lançado em Paris, por Alfonse Bertillon, foi o primeiro sistema científico de identificação, pois se baseava nos elementos antropológicos do homem. Consistia no assinalamento, feito em milímetros, de várias partes do corpo humano: diâmetro da cabeça; comprimento da orelha direita; comprimento do pé esquerdo; estatura; envergadura; assinalamento descritivo do formato do nariz; lábios; orelhas; e também, de marcas particulares (tatuagens,

cicatrizes, etc.). Esses dados eram registrados em uma ficha antropométrica, que continha também a fotografia do identificado.

**Ano 1888:** Francis Galton, nobre inglês, foi incumbido pelo governo de analisar o material colhido por Herschel, quando esteve na Índia, a fim de estabelecer um sistema de identificação mais seguro que a antropometria. Foi então que lançou as bases científicas da impressão digital.

O sistema de Galton foi, sem dúvida, rudimentar. Teve, entretanto, um grande mérito: o de servir de ponto de partida para os demais sistemas dactiloscópicos.

**Ano 1891:** Henry de Varigny, articulista francês, publicou, na "*Revue Scientifique*" de 2 de Maio, um artigo discorrendo sobre o sistema de Galton, neste, apresentou várias sugestões quanto ao emprego das impressões digitais. O artigo de Varigny foi traduzido para o espanhol e publicado na "*Revista de Identificación y Ciencias Sociales Penales*".

Lendo esse artigo, Juan Vucetich, encarregado da oficina de identificação de La Plata, Argentina, logo se convenceu da superioridade do novo sistema de identificação, iniciando, assim, seus estudos sobre as impressões digitais.

Em 1º de Setembro, Vucetich apresentou seu sistema de identificação, com o nome de icnofalangometria.

Vucetich baseou sua classificação no sistema de Galton, procedeu a tomada das impressões dos dez dedos, empregando os símbolos literais e numerais na classificação das figuras: ARCO-A-1; PRESILHA INTERNA-I-2; PRESILHA EXTERNA-E-3; VERTICULO-V-4. Os símbolos literais representam os dedos polegares e nos demais dedos são empregados símbolos numerais. Os dez dedos de uma pessoa são diferentes entre si, assim como não existem duas pessoas que apresentam impressões digitais exatamente coincidentes.

**Ano 1894:** Dr. Francisco Latzina, publicou no jornal "La Nacion", de Buenos Aires, um artigo no qual critica, favoravelmente o sistema de Vucetich, sugerindo

entretanto, que o nome Icnofalangometria, fosse substituído por Dactiloscopia, este novo nome é constituído de dois elementos gregos (*DA'KTYLOS* = dedos; *SKOPÊIN* = examinar).

**Ano 1900:** Edward Richard Henry, publicou na Inglaterra, seu livro "*Classification and Uses of Fingerprints*" expondo seu novo sistema de identificação dactiloscópica, adotando 4 tipos fundamentais: ARCOS, PRESILHAS, VERTICILLOS E COMPOSTOS.

**Ano 1901:** Neste ano, o sistema dactiloscópico de Henry foi adotado oficialmente na Inglaterra, pela *Scotland Yard*.

**Ano 1902:** José Alves Felix Pacheco iniciou, no Rio de Janeiro, a tomada da impressão digital nas fichas Antropométricas.

Em 17 de Julho foi inaugurado em São Paulo o Gabinete de Identificação Antropométrica, sendo a fotografia elemento auxiliar da identificação. Foi promulgada a Lei Nº 947 em 29 de Dezembro, criando a identificação dactiloscópica no Rio de Janeiro, capital do Brasil.

**Ano 1903:** Em 05 de Fevereiro, foi regulamentada a Lei 947, pelo decreto Nº 4764, instituindo o sistema dactiloscópico Vucetich, no Rio de Janeiro. Nesse mesmo ano, Bertillon anexou a dactiloscopia ao sistema antropométrico de sua criação.

**Ano 1904:** Em 29 de Julho, é expedida a primeira carteira de identidade, então denominada "Ficha Passaporte" ou "Cartão de Identidade", ainda usando assinalamentos antropométricos junto com a dactiloscopia.

**Ano 1907:** Pelo decreto Nº 1533-A de 30 de Novembro, foi adotado no Estado de São Paulo, o sistema Dactiloscópico Vucetich, devido ao interesse do Dr. Evaristo da Veiga, sendo presidente do Estado de São Paulo o Dr. Jorge Tibiriça e, Secretário da Justiça e Segurança Pública, o Dr. Washington Luiz Pereira de Souza.

**Ano 1935:** Sob a direção do Dr. Ricardo Gumbleton Daunt, no Serviço de

Identificação de São Paulo, é criado o Arquivo Dactiloscópico Monodactilar e o Laboratório de Locais do Crime.

**Ano 1941:** O Instituto de Identificação da Polícia do Distrito Federal, Rio de Janeiro, passou a denominar-se Instituto Felix Pacheco, pelo Decreto-Lei Nº3793 de 04 de Dezembro. Pelo Decreto-Lei Nº 3689 de 03 de Outubro, é promulgado o Código de Processo Penal, que estabelece em seu art. 6º, inciso VIII, a identificação dactiloscópica nos indiciados em Inquérito Policial.

**Ano 1963:** Em 21 de Setembro é inaugurado, em Brasília-DF, o Instituto Nacional de Identificação, com o objetivo fundamental de centralizar a identificação criminal no país.

**Ano 1975:** Faleceu em São Paulo, o Professor Carlos Kehdy, autor de diversos livros sobre a ciência da Dactiloscopia e professor da Academia de Polícia Civil do Estado de São Paulo.

**Ano 1998:** O Instituto de Identificação do Estado de São Paulo possui um acervo de aproximadamente 40.000.000 prontuários e expede, diariamente, em média 15.000 Cédulas de Identidade e 300 Atestados de Antecedentes Criminais.

**Ano 2004:** O Instituto de Identificação de Goiás promove a digitalização de todo o arquivo Criminal com o padrão WSQ, compatível com o Sistema Afis em fase de instalação da Polícia Federal no Instituto Nacional de Identificação.

## ANEXO B – HARDWARE UTILIZADO


Para o colhimento de digitais foi utilizado o leitor *Fingerprint Reader* da *Microsoft*<sup>®</sup>, que por ser um leitor comum, que pode ser comprado com facilidade e tem um baixo custo (\$30,00 em dólares americanos), se encaixando no perfil do trabalho.



**Figura B.1 – Leitor utilizado no trabalho**

Este leitor tem como características principais o fato de ser ótico, que é o modelo mais usado e também o mais seguro. Este tipo de leitor evita problemas como de reconhecimento mesmo que o usuário esteja com o dedo sujo, pois a digital não é colocada diretamente no sensor, mas em um vidro onde ela é analisada por um laser, além de evitar danos aos jogos de espelhos.

Foi utilizado para extração das imagens o *software Griaule Biometrics* com licença para 90 dias. A Figura B.2 mostra um exemplo de extração de imagem da digital. Este *software* foi feito para pegar minúcias da imagem para identificação, isto é, então ele foi utilizado apenas para obtenção das imagens para criação do banco de dados.



**Figura B.2 – Software de obtenção das imagens.**

A imagem obtida pelo leitor da *Microsoft*<sup>®</sup> é como a mostrada na Figura B.3, um exemplo já no formato bitmap (.bmp).



**Figura B.3 – Imagem obtida com o *Microsoft*<sup>®</sup> Fingerprint Reader.**

**ANEXO C – BANCO DE DADOS ORIGINAL**

A1



A2



A3



A4



A5



A6



A7



A8



A9



A10



A11



A12



A13



A14



A15



A16



A17



A18



A19



A20



A21



A22



A23



A24



A25



A26



A27



A28



A29



A30



A31



A32



A33



A34



A35



A36



A37



A38



A39



A40



A41



A42



A43



A44



A45



A46



A47



A48



A49



A50



A51



A52



A53



A54



A55



A56



A57



A58



A59



A60



A61



A62



A63



A64



B1



B2



B3



B4



B5



B6



B7



B8



B9



B10



B11



B12




B13



B14



B15



B16



B17



B18




B19



B20



B21



B22



B23



B24



B25



B26



B27



B28



B29



B30



B31



B32



B33



B34



B35



B36



B37



B38



B39



B40



B41



B42



B43



B44



B45



B46



B47



B48



B49



B50



B51



B52



B53



B54



B55



B56



B57



B58



B59



B60



B61



B62



B63



B64

**UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO**  
**CENTRO TECNOLÓGICO**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**

**REINALDO LUBE FILHO**  
**ROBERTO MARTINELLI GUERRA**

**SISTEMA DE CONTROLE AUTOMÁTICO DE ACESSO**  
**ATRAVÉS DE IMAGEM DIGITALIZADA DO DEDO**  
**UTILIZANDO *WAVELET* E REDES NEURAIS**

Vitória  
2008