

UNIVERSIDADE REGIONAL DE BLUMENAU
CENTRO DE CIÊNCIAS EXATAS E NATURAIS
CURSO DE CIÊNCIAS DA COMPUTAÇÃO
(Bacharelado)

**PROTÓTIPO DE SOFTWARE PARA CLASSIFICAÇÃO DE
IMPRESSÃO DIGITAL**

TRABALHO DE CONCLUSÃO DE CURSO SUBMETIDO À UNIVERSIDADE
REGIONAL DE BLUMENAU PARA A OBTENÇÃO DOS CRÉDITOS NA
DISCIPLINA COM NOME EQUIVALENTE NO CURSO DE CIÊNCIAS DA
COMPUTAÇÃO — BACHARELADO

ALEX SANDRO DA SILVA

BLUMENAU, JUNHO/1998

1999/1-01

PROTÓTIPO DE SOFTWARE PARA CLASSIFICAÇÃO DE IMPRESSÃO DIGITAL

ALEX SANDRO DA SILVA

ESTE TRABALHO DE CONCLUSÃO DE CURSO, FOI JULGADO ADEQUADO PARA OBTENÇÃO DOS CRÉDITOS NA DISCIPLINA DE TRABALHO DE CONCLUSÃO DE CURSO OBRIGATÓRIA PARA OBTENÇÃO DO TÍTULO DE:

BACHAREL EM CIÊNCIAS DA COMPUTAÇÃO

Prof. Paulo de Tarso Mendes Luna — Orientador na FURB

Prof. José Roque Voltolini da Silva — Coordenador do TCC

BANCA EXAMINADORA

Prof. Paulo de Tarso Mendes Luna

Prof. Dalton Solano dos Reis

Prof. Sérgio Stringari

AGRADECIMENTOS

Agradeço aos meus pais e a minha namorada Cláudia Kátia Nazatto pelo apoio, incentivo e compreensão.

Ao professor Paulo de Tarso Mendes Luna, pelo incentivo, orientação e atenção dispensada durante o trabalho de conclusão.

SUMÁRIO

AGRADECIMENTOS	III
SUMÁRIO.....	IV
LISTA DE FIGURAS	VII
LISTA DE QUADROS.....	IX
RESUMO	X
ABSTRACT	XI
1 INTRODUÇÃO.....	1
1.1 ORIGEM DO TRABALHO	1
1.2 ÁREA	2
1.3 PROBLEMA.....	2
1.4 JUSTIFICATIVAS	2
1.5 OBJETIVO.....	3
1.6 ESTRUTURA	3
2 FUNDAMENTAÇÃO TEÓRICA	4
2.1 DATILOSCOPIA.....	4
2.1.1 <i>POSTULADOS DA DATILOSCOPIA</i>	4
2.1.2 <i>ESTUDO DAS IMPRESSÕES DIGITAIS</i>	5
2.1.3 <i>VISÃO GERAL DAS IMPRESSÕES DIGITAIS</i>	5
2.1.3.1 SISTEMA DATILOSCÓPICO DE VUCETICH	6
2.1.3.2 MINÚCIAS	9
2.1.3.3 NÚCLEO E DELTAS	10
2.2 PROCESSAMENTO DE IMAGENS	10
2.2.1 <i>IMAGENS DIGITAIS</i>	11
2.2.2 <i>FORMATO DE IMAGENS</i>	13
2.2.3 <i>TRATAMENTO DE IMAGENS</i>	14
2.2.4 <i>RECONHECIMENTO DE PADRÕES</i>	14
2.3 REDES NEURAIS.....	16
2.3.1 <i>NEUROCOMPUTAÇÃO</i>	16
2.3.2 <i>O NEURÔNIO</i>	16
2.3.3 <i>O ELEMENTO DE PROCESSAMENTO</i>	18

2.3.4	<i>ANALOGIA COM O CÉREBRO</i>	19
2.3.5	<i>REDES NEURAS ARTIFICIAIS</i>	20
2.3.5.1	CAMADAS.....	21
2.3.5.2	CONEXÕES.....	21
2.3.6	<i>TOPOLOGIAS DE REDES NEURAS ARTIFICIAIS</i>	22
2.3.6.1	REDES DIRETAS (FEEDFORWARD).....	22
2.3.6.2	REDES COM CICLOS	23
2.3.6.3	REDES SIMÉTRICAS.....	23
2.3.7	<i>TIPOS DE REDES NEURAS ARTIFICIAIS</i>	23
2.3.7.1	REDE AUTOASSOCIATIVA	23
2.3.7.2	REDE HETEROASSOCIATIVA	24
2.3.8	<i>MÉTODOS DE CONTROLE DO APRENDIZADO</i>	24
2.3.8.1	APRENDIZADO SUPERVISIONADO	24
2.3.8.2	APRENDIZADO NÃO-SUPERVISIONADO	26
2.3.9	<i>MODELOS DE REDES NEURAS ARTIFICIAIS</i>	27
2.3.9.1	APLICAÇÕES, VANTAGENS E DESVANTAGENS POR MODELO.....	27
2.3.9.2	MODELO PERCEPTRON.....	28
2.3.9.3	MODELO FEEDFORWARD / BACKPROPAGATION	30
2.4	CONTEXTO ATUAL DO TEMA	32
2.5	TRABALHOS CORRELATOS.....	33
2.5.1	<i>DESCRIÇÃO DOS TRABALHOS</i>	33
2.5.2	<i>AVALIAÇÃO COMPARATIVA</i>	33
3	DESENVOLVIMENTO DO TRABALHO	34
3.1	ESPECIFICAÇÃO.....	34
3.1.1	<i>TÉCNICAS E FERRAMENTAS UTILIZADAS</i>	34
3.1.1.1	FASES DE UM PROJETO DE REDES NEURAS	34
3.1.1.1.1	CONCEPÇÃO DA REDE NEURAL	36
3.1.1.1.2	DEFINIÇÃO DA REDE NEURAL.....	36
3.1.1.1.3	TREINAMENTO DA REDE NEURAL.....	38
3.1.1.1.4	UTILIZAÇÃO DA REDE NEURAL	40
3.1.1.1.5	MANUTENÇÃO DA REDE NEURAL	40
3.1.2	<i>APRESENTAÇÃO DA ESPECIFICAÇÃO</i>	41
3.1.2.1	DEFINIÇÃO DA REDE NEURAL	44
3.1.2.2	TREINAMENTO DAS REDES NEURAS.....	46
3.1.2.3	UTILIZAÇÃO DA REDE NEURAL.....	48
3.2	IMPLEMENTAÇÃO	49
3.2.1	<i>DELPHI</i>	49
3.2.1.1	CARACTERÍSTICAS.....	49
3.2.2	<i>DIAGRAMA DE CONTEXTO</i>	50
3.2.3	<i>CÓDIGO DAS REDES NEURAS IMPLEMENTADAS</i>	50

3.2.3.1	REDE BACKPROPAGATION.....	51
3.2.3.2	REDE PERCEPTRON	52
3.2.4	<i>OPERACIONALIDADE DA IMPLEMENTAÇÃO</i>	54
4	ALGUMAS APLICAÇÕES	64
5	CONCLUSÃO.....	66
5.1	EXTENSÕES.....	68
	REFERÊNCIAS BIBLIOGRÁFICAS.....	69

LISTA DE FIGURAS

FIGURA 1- ARCO	7
FIGURA 2 - PRESILHA INTERNA.....	7
FIGURA 3 - PRESILHA EXTERNA.....	8
FIGURA 4 - VERTICILO	8
FIGURA 5 - MINÚCIAS	9
FIGURA 6 - NÚCLEO E DELTAS.....	10
FIGURA 7 - NEURÔNIO BIOLÓGICO	18
FIGURA 8 - NEURÔNIO ARTIFICIAL	19
FIGURA 9 - REDE DE COMPUTAÇÃO NEURAL.....	20
FIGURA 10 - REDE DIRETA COM 4 CAMADAS.....	22
FIGURA 11 - REDE SIMÉTRICA COM UMA CAMADA INTERNA	23
FIGURA 12 - REGRA DELTA	25
FIGURA 13 - ESQUEMA DE TREINAMENTO DO PERCEPTRON.....	26
FIGURA 14 - APRENDIZADO NÃO-SUPERVISIONADO.....	26
FIGURA 15 - REDE NEURAL PERCEPTRON.....	29
FIGURA 16 - FUNÇÃO DE TRANSFERÊNCIA.....	30
FIGURA 17 - REGRA DE APRENDIZAGEM.....	30
FIGURA 18 - FUNÇÃO SOMADORA DO EP	31
FIGURA 19 - CICLO DE VIDA DE UMA REDE NEURAL.....	35
FIGURA 20 - ESTAGIO DA CONCEPÇÃO	36
FIGURA 21 - DESENHO DA REDE.....	37
FIGURA 22 - FLUXO DE TREINAMENTO.....	39
FIGURA 23 - FLUXOGRAMA DE TREINAMENTO E TESTES	41
FIGURA 24 - PROCESSO DE CLASSIFICAÇÃO DA IMPRESSÃO DIGITAL.....	42
FIGURA 25 - PADRÃO DEFINIDO REPRESENTANDO UMA LINHA DE 0°	44
FIGURA 26 - PADRÃO DEFINIDO REPRESENTANDO UM ESPAÇO (INTER-LINHA) DE 0°	44
FIGURA 27 - PADRÃO DEFINIDO REPRESENTANDO UMA LINHA DE 45°	45
FIGURA 28 - IMPRESSÃO DIGITAL	45
FIGURA 29 - MAPA DE DIREÇÕES CORRESPONDENTE A IMPRESSÃO DIGITAL ANTERIOR.....	46
FIGURA 30 – FLUXOGRAMA DA ETAPA DE TREINAMENTO.....	47
FIGURA 31 - PADRÃO DEFINIDO REPRESENTANDO UMA LINHA DE 22.5° COM RUÍDO	48
FIGURA 32 - DIAGRAMA DE CONTEXTO	50
FIGURA 33 - TELA INICIAL.....	55
FIGURA 34 - TELA DE TREINAMENTO DAS ID	55
FIGURA 35 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	56
FIGURA 36 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	56

FIGURA 37 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	57
FIGURA 38 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	57
FIGURA 39 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	58
FIGURA 40 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	58
FIGURA 41 - TELA DE TREINAMENTO DAS DIREÇÕES PREFERENCIAIS.....	59
FIGURA 42 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	59
FIGURA 43 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	60
FIGURA 44 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	60
FIGURA 45 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	61
FIGURA 46 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	61
FIGURA 47 - TELA DE TREINAMENTO DAS CLASSES DE IMPRESSÕES DIGITAIS.....	62
FIGURA 48 - TELA INICIAL.....	62
FIGURA 49 - TELA INICIAL.....	63
FIGURA 50 - TELA DEMONSTRANDO O MAPA DE DIREÇÕES.....	63

LISTA DE QUADROS

QUADRO 1 - SÍMBOLOS DOS TIPOS DE IMPRESSÕES DIGITAIS	9
QUADRO 2 - ANALOGIA COM O CÉREBRO	19
QUADRO 3 - APLICAÇÕES - REDES NEURAIS.....	28

RESUMO

Neste trabalho é apresentado um protótipo de uma metodologia para a extração do mapa de direções e classificação de impressões digitais, utilizando redes neurais. No processo de classificação a imagem da impressão digital é segmentada em blocos e de cada bloco extrai-se um conjunto de parâmetros que são apresentados como entrada da rede neural. Esta tem como saída a direção preferencial encontrada para cada bloco referido. Após isso, são apresentados os resultados dessa rede neural, mapa de direções, a uma nova rede neural, que apresenta como saída a classificação da impressão digital.

ABSTRACT

In this work a prototype of a methodology is presented for the extraction of the map of directions and classification of fingerprints, using neural network. In the classification process the image of the fingerprint is segmented in blocks and of each block a group of parameters is extracted that are presented as entrance of the neural network. This has as exit the preferential direction found for each referred block. After that, the results of that neural network are presented, map of directions, to a new neural network, that presents as exit the classification of the fingerprint.

1 INTRODUÇÃO

1.1 ORIGEM DO TRABALHO

A identificação do indivíduo é feita através de vários recursos, aos quais ele é submetido para constatação de sua identidade. Como consequência temos a identificação baseada em um conjunto de caracteres peculiares a cada indivíduo, que são usadas para distingui-lo de seus semelhantes.

São vários os processos ou meios usados para a identificação do indivíduo, a saber: o visual, a voz, a arcada dentária, a escrita e as impressões digitais.

A busca de um processo seguro de identificação de indivíduos, vem de tempos remotos, desde quando eram utilizados meios, classificados como bárbaros pela sua crueldade: ferros em brasa, amputação, ferragens nas orelhas, tatuagens e injeções de parafina. Contudo, nenhum destes métodos demonstrou eficácia e as pesquisas prosseguiram. Em 1891, Don Juan Vucetich, argentino naturalizado, descobriu a “datiloscopia” (papiloscopia), que é o processo de identificação através de impressões digitais. Usado na identificação civil e criminal, foi introduzido no Brasil, por Félix Pacheco, em 1901 [JAN96].

A melhor maneira de se provar quem é, ainda é por meio das impressões digitais. Elas se formam no sexto mês de gravidez e nos acompanham os indivíduos por toda sua vida. As características pessoais mudam, mas as impressões digitais permanecem. Mesmo quando os dedos são cortados, elas se recompõem. Embora seu uso científico e criminal começasse a partir do século 19, as impressões digitais já eram utilizadas como assinatura desde a pré-história. A impressão digital é um conjunto de cristas papilares (os desenhos) que apresenta montanhas (as linhas pretas no papel) e vales (os espaços em branco) [JAN96].

Até os dias atuais é usada a impressão digital do polegar direito ou esquerdo, na ausência do primeiro, como a assinatura do analfabeto. É o processo infalível de identificação de indivíduos, de suas obras e feitos, quando ali deixam suas marcas digitais.

Desde a sua descoberta, não se registrou nenhuma duplicidade de impressões digitais. Existem impressões digitais semelhantes na forma, contudo, nunca idênticas em número de pontos característicos de identificação, o que as tornam individuais e pessoais [JAN96].

1.2 ÁREA

Áreas relacionadas ao trabalho proposto são:

- a) Datiloscopia – uma que os conhecimentos específicos desta área serão incorporados ao protótipo;
- b) Computação Gráfica – no que diz respeito ao processamento de imagens, necessária a preparação prévia dos dados de entrada.
- c) Inteligência Artificial (Redes Neurais) – tecnologia base utilizada;

1.3 PROBLEMA

Certas capacidades do nosso cérebro, tais como reconhecimento de imagens, são tarefas que o nosso cérebro executa com rapidez. Neste aspecto, o neurônio humano é o elemento de processamento básico nos modelos de redes neurais. Sua riqueza de interconexões e forma funcional escondem provavelmente as chaves para a compreensão das funções mais elevadas do nosso cérebro, que constituem as ambicionadas metas do estudo da Inteligência Artificial. Este novo paradigma, chamado de neurocomputação, inclusive toma emprestado uma boa parte da terminologia da microbiologia [LOE91].

O campo de pesquisa em processamento digital de imagens tem evoluído consideravelmente nos últimos anos. Este avanço tem possibilitado resolver eficientemente inúmeros problemas nesta área. Neste mesmo campo, a aplicação de técnicas baseadas em redes neurais vem contribuindo muito para que tarefas como inspeção visual e classificação de objetos possam ser automatizadas. Entretanto as aplicações existentes não demonstram como estas tecnologias são utilizadas na prática.

Dentro desse escopo, este trabalho propõe a construção de um Protótipo de Reconhecimento de Impressões Digitais.

1.4 JUSTIFICATIVAS

O sentido da visão é frequentemente utilizado como instrumento de controle de acesso em situações onde, por exemplo, é verificado se a imagem de uma pessoa, vista por alguém que controla o acesso a algum lugar, confere com a imagem registrada em uma foto. Uma situação menos freqüente de uso do sentido da visão é aquela em que se verifica se uma

impressão digital, colhida em algum lugar, confere com outra depositada anteriormente em um arquivo. A automação deste processo com o uso do computador, que normalmente requer profissionais capacitados, pode facilitar o reconhecimento de uma impressão digital e mesmo viabilizar seu uso como um eficiente mecanismo de controle de acesso. Tal automação pode ser conseguida com o uso de Redes Neurais Artificiais, como pretende ilustrar esse trabalho.

1.5 OBJETIVO

O objetivo principal deste trabalho é desenvolver um protótipo de Software que utiliza a tecnologia das Redes Neurais, em especial os modelos *Perceptron* e *Backpropagation*, para automatizar as tarefas de classificação de impressões digitais.

1.6 ESTRUTURA

A seguir serão descritos brevemente cada capítulo do trabalho.

O capítulo de introdução apresenta uma visão geral deste trabalho, sua importância e objetivos.

O segundo capítulo apresenta uma fundamentação teórica das áreas envolvidas, que são: Datiloscopia, Processamento de Imagens e Redes Neurais. Neste capítulo são discutidos conceitos, técnicas e ferramentas mais relevantes envolvidas com o tema.

No terceiro capítulo é apresentado o desenvolvimento da trabalho, comentando as técnicas e as ferramentas envolvidas.

No capítulo quatro encontra-se algumas das possíveis aplicações de sistemas de reconhecimento de impressão digital.

No quinto capítulo são apresentadas as principais conclusões e sugestões para futuros trabalhos.

2 FUNDAMENTAÇÃO TEÓRICA

A seguir serão apresentados alguns conceitos e técnicas mais relevantes envolvidas com o tema. Também serão relatados o estado da arte sobre o tema e os trabalhos correlatos identificados na pesquisa.

2.1 DATILOSCOPIA

É uma ciência que trata da identificação de pessoas através das impressões digitais. A identidade é o modo de determinar a individualidade das pessoas. Identidade, em um conceito mais amplo, é a condição pela qual cada ser ou cada coisa se individualiza e se diferencia de seus semelhantes [JAN96].

É dividida em civil, criminal e clínica [KEH84]. A Datiloscopia civil trata da identificação das pessoas para expedição de documentos. A Datiloscopia criminal reveste-se de três aspectos, a saber: identificação do indiciado em inquérito policial, expedição de documentos de idoneidade e aproveitamento das impressões papilares encontradas nos locais do crime. Enquanto a datiloscopia clínica estuda as perturbações que se verificam nos desenhos digitais.

2.1.1 POSTULADOS DA DATILOSCOPIA

Postulado é uma proposição que se aceita sem demonstração. São os seguintes os postulados da Datiloscopia: perenidade, imutabilidade, variabilidade e classificabilidade [TAV91].

- d) Perenidade é a propriedade que tem o desenho digital de existir desde o sexto mês de vida fetal até a putrefação cadavérica;
- e) Imutabilidade é a propriedade que tem o desenho digital de não mudar, desde o sexto mês de vida pré-natal até putrefação cadavérica;
- f) Variabilidade é a propriedade que tem o desenho digital de variar de dedo para dedo e de pessoa para pessoa. A variabilidade é garantida pelos “pontos característicos”;
- g) Classificabilidade é a propriedade que tem o desenho digital de poder ser classificado.

2.1.2 ESTUDO DAS IMPRESSÕES DIGITAIS

Diferença entre desenho digital e impressão digital [KEH84]:

- a) o desenho digital é formado por um conjunto de cristas e sulcos que se encontram na polpa digital. Localizam-se na derme e se reproduzem na epiderme, formando configurações diversas;
- b) a impressão digital é a reprodução do desenho digital, em qualquer suporte. Tem a denominação de suporte toda a superfície que receba impressões digitais. Essa superfície deve ser limpa e lisa.

Uma impressão digital é formada pelos seguintes elementos: linhas pretas, linhas brancas, delta, pontos característicos, poros, linhas brancas albedactiloscópicas [TAV91]:

- h) linhas pretas correspondem às cristas papilares;
- i) linhas brancas correspondem aos sulcos interpapilares;
- j) delta é um ângulo ou triângulo formados pelas cristas papilares;
- k) pontos característicos são acidentes que se encontram nas cristas papilares. Tem a finalidade de estabelecer a identidade das impressões papilares;
- l) poros são aberturas dos canais sudoríparos. Na polpa digital, os poros aparecem numa quantidade variável entre 9 e 18 por milímetro quadrado. A perícia feita através dos poros é denominada “poroscopia”.
- m) as linhas brancas albedactiloscópicas são formadas pela interrupção de duas ou mais cristas papilares. Não devem ser confundidas com as linhas brancas correspondentes aos sulcos interpapilares; estas acompanham as linhas pretas em todo o seu trajeto e refletem todos os seus acidentes. As linhas brancas albedactiloscópicas não servem como elemento de identificação, porque podem aumentar em número, diminuir, mudar de forma, etc...; enfim, não são permanentes.

2.1.3 VISÃO GERAL DAS IMPRESSÕES DIGITAIS

As impressões digitais de pessoas ou de dedos diferentes de uma mesma pessoa diferenciam-se sob dois critérios principais. O primeiro critério está relacionado ao TIPO da impressão e o segundo critério está relacionado à distribuição planar das MINÚCIAS. O critério de TIPO representa uma visão macroscópica da impressão digital, definida pelo comportamento das linhas datilares nos dedos. Em função deste comportamento, uma

impressão digital é classificada como Arco, Verticilo, Presilha Externa ou Presilha Interna. Esta visão macroscópica permite, num processo de comparação de duas impressões digitais, afirmar a não identidade no caso de TIPOs diferentes. Quando os TIPOs de duas impressões digitais (Padrão × Candidato) são iguais, o segundo critério, das MINÚCIAS, permite afirmar ou não a identidade em função da ocorrência ou não de um mapeamento posicional entre os diversos tipos de MINÚCIAS.

2.1.3.1 SISTEMA DATILOSCÓPICO DE VUCETICH

O sistema datiloscópico de Juan Vucetich foi lançado na cidade de La Plata (Argentina), no dia 1º de setembro de 1891, como o nome de “Icnofalangometria” [KEH84].

Em 1894, o Dr. Francisco Latzina publicou, no jornal “La Nación”, um artigo criticando favoravelmente o sistema de Vucetich; nessa ocasião, sugeriu a mudança de nome de “icnofalangometria” para o de “datiloscopia” [KEH84].

Esta palavra é constituída de elementos gregos :

Daktylos - dedos e *skopêin* - examinar.

No sistema de Vucetich há quatro tipos fundamentais denominados arco, presilha interna, presilha externa, verticilo. Cada um destes tipos apresenta duas características, sendo uma pertinente ao delta e a outra à linhas do sistema nuclear [TAV91].

- a) o arco apresenta ausência de delta e as linhas atravessam o campo da impressão de um lado ao outro, assumindo forma mais ou menos abaulada [Figura 1].



Figura 1- Arco

- b) a presilha interna tem um delta à direita do observador e as linhas nucleares correm para a esquerda do observador [Figura 2].



Figura 2 - Presilha Interna

- c) a presilha externa tem um delta à esquerda do observador e as linhas nucleares correm para a direita do observador [Figura 3].



Figura 3 - Presilha Externa

- d) o verticilo tem dois deltas, sendo um à direita e outro à esquerda do observador e as linhas nucleares ficam encerradas entre os dois deltas, assumindo configurações variadas [Figura 4].



Figura 4 - Verticilo

Símbolos - os tipos fundamentais de Vucetich são representados, abreviadamente, por meio de símbolos, conforme Quadro 1 [TAV91]:

Arco	A	1
Presilha interna	I	2
Presilha externa	E	3
Verticilo	V	4

Quadro 1 - Símbolos dos Tipos de Impressões Digitais

As letras são empregadas para representar os tipos fundamentais dos polegares; os algarismos representam os tipos fundamentais dos demais dedos.

2.1.3.2 MINÚCIAS

As linhas datilares em uma impressão digital, em seu caminho de um lado a outro da impressão, independente do TIPO, podem interromper-se ou bifurcar-se em pontos escolhidos aleatoriamente pela natureza [Figura 5]. A ocorrência e distribuição planar destes fins-de-linha e bifurcações é o que caracteriza, de forma única, uma impressão digital e a torna diferente das demais [TAV91].




Figura 5 - Minúcias

2.1.3.3 NÚCLEO E DELTAS




Figura 6 - Núcleo e Deltas

As impressões digitais dos Grupos V, E e I apresentam duas características adicionais para um refinamento da classificação e que auxiliam o processo de comparação. O NÚCLEO de uma impressão digital representa o "centro de gravidade" da impressão. Está localizado, em impressões digitais do Tipo V na parte superior da volta mais interna da linha datilar. Em impressões digitais dos Tipos E e I está localizado no ombro da laçada mais interna da impressão (na Figura 6 a posição do núcleo está marcada como +). A homogeneidade das linhas em Arcos normalmente impede o posicionamento automático invariante do núcleo [Figura 6].

Os DELTAS representam o ponto de divergência das linhas datilares mais internas que envolvem ou tendem a envolver a região nuclear de uma impressão digital. Verticilos apresentam normalmente dois deltas, Presilhas Externas apresentam um delta à esquerda do observador e as Presilhas Internas um delta à direita do observador.

2.2 PROCESSAMENTO DE IMAGENS

O processamento de imagens é uma área de estudos da computação que tem evoluído muito nos últimos anos. Seu grande crescimento se deve principalmente ao desenvolvimento de equipamentos, cada vez mais sofisticados e baratos, utilizados para a captura e tratamento de imagens digitais [HAR83].

Muitos problemas práticos podem ser resolvidos com a ajuda de minicomputadores, mais precisamente com máquinas com arquitetura especial. *Hardware* dedicado, por outro lado, requer algoritmos apropriados para um *design* com base em componentes de microprocessador padrão [HAR83].

O Processamento Digital de Imagens é um estudo que está inserida dentro do Processamento Gráfico, junto a Computação Gráfica.

A área de Processamento Digital de Imagens teve início em meados da década de 60, com a motivação criada pelos programas espaciais da NASA nos EUA. O aumento da capacidade de memória e velocidade dos computadores contribui para dar impulso à nova tecnologia, que passou a ser aplicada em outras áreas como: medicina, microscopia, ótica eletrônica, transmissão digital de sinais de TV ou fac-símile e em sensores visuais de robôs. Em 1975, a invenção do tomógrafo computadorizado por G. N. Hounsfield, abriu amplas perspectivas de utilização das técnicas digitais de imagens radiográficas [OSO91].

2.2.1 IMAGENS DIGITAIS

O processo de digitalização consiste em realizar a aquisição de uma imagem, a qual é passada para o computador em formato adequado para que este possa manipulá-la. As informações visuais são convertidas em sinais elétricos por sensores óticos, estes sinais são quantificados em valores binários armazenados na memória do computador. No processo de digitalização, os sinais são amostrados espacialmente e quantificados em amplitude, de forma a obter a imagem digital [OSO91].

No processamento de imagens, a imagem digital é definida como sendo uma matriz de $M \times N$ elementos. Cada elemento da imagem digital é denominado de pixel (*picture element*), tendo associado a ele uma informação referente a luminosidade e a cor [OSO91].

Existem vários dispositivos associados às várias aplicações que manipulam imagens. Como exemplo, pode-se citar: o radar, usado na obtenção de imagens de objetos distantes; aparelhos médicos baseados em ultra-som, usados para analisar o interior do corpo humano e a câmara de TV usada na obtenção de imagens locais. Basicamente o processo de formatação das imagens nestes diversos dispositivos é o mesmo [OSO92].

Os digitalizadores de imagens são constituídos basicamente pelos seguintes elementos:

- a) **ILUMINADOR:** dispositivo responsável pela iluminação do objeto alvo da digitalização;
- b) **SENSOR:** elemento fotossensível capaz de traduzir uma intensidade luminosa incidente, em valores de corrente elétrica proporcionais a esta luminosidade;
- c) **CONVERSOR A/D:** o valor contínuo da corrente elétrica gerada pelo sensor é convertido em um valor discreto (análogo \square digital). Este valor discreto pode então ser armazenado sob a forma numérica na memória de um computador.

Os dispositivos baseados em câmeras de vídeo são capazes de capturar cenas de natureza tridimensional, já o segundo tipo de digitalizadores, os *scanners*, não possuem a capacidade para adquirir este tipo de imagens. O objetivo alvo da digitalização por um *scanner* tem que ser plano, podendo ser uma fotografia, impresso ou qualquer outro tipo de objeto plano. Os *scanners* são muito utilizados na atualidade, podendo ser de três tipos: de mesa, manual ou “*flying spot scanners*” [OSO92].

O resultado do processo de digitalização é a obtenção de uma imagem digital armazenada na memória do computador. Esta imagem pode então ser visualizada ou armazenada em um dispositivo de armazenamento secundário, para posterior processamento.

Existem basicamente dois problemas a serem tratados: a especificação do formato de armazenamento destas imagens e a forma de codificação das mesmas. Estes itens tem que ser analisados cuidadosamente, pois tomando-se uma imagem que represente a realidade, esta pode chegar a ocupar 3 Mbytes de memória (1024 x 1024 *pixels*, com 24 bits/pixel) e neste caso o emprego de algum tipo de técnica de codificação visando a compactação dos dados para o armazenamento, é extremamente aconselhável.

A primeira maneira de armazenar uma imagem é através da gravação linha a linha, coluna a coluna, sem o uso de qualquer tipo de compactação. Neste caso é possível armazenar cada pixel para imagens coloridas. Além da imagem propriamente dita, também terá que ser armazenado o número de linhas e colunas da matriz imagem, de forma que esta possa ser novamente reconstituída. Este sem dúvida não é o melhor método, mais é o mais simples. Um método um pouco mais sofisticado, consiste em realizar a compactação a nível de bytes, ou seja, caso a imagem possua um número de bits/pixel que não seja múltiplo exato do número

de bits de um byte, compacta-se a imagem de forma que todos os bits de cada byte sejam utilizados. Nesta técnica, alinham-se as informações a respeito de cada pixel, uma após a outra, sem considerar a organização da memória orientada a bytes, ocupando-se todos os bits [OSO92].

2.2.2 FORMATO DE IMAGENS

Imagens digitais são úteis quando são armazenadas de uma forma que possam ser utilizadas por outras aplicações. Então é necessário colocar estas imagens em uma forma padronizada para que elas possam ser manipuladas por um grande número de aplicações. Programas gráficos podem ser classificados pela forma com a qual armazenam ou apresentam as imagens. Para esta abordagem há duas categorias: formato de varredura e formato vetorial. O formato de varredura é composto por uma série de elementos de imagens, ou pixels, que cobrem uma área apresentada. Imagens de varredura são na maioria das vezes geradas por uma varredura periódica de um feixe de elétrons sobre a superfície de uma imagem que tem um determinado padrão. Os pixels em uma imagem por varredura não são necessariamente relacionados uns aos outros. Também o conceito de forma não é inerente a uma imagem capturada por varredura. Imagens capturadas por varredura são usadas frequentemente em apresentações gráficas, onde considerações artísticas e qualidade de imagem são importantes [FAC93].

Já o formato vetorial envolve o uso de segmentos de linha orientados ao invés de pixels para representar uma imagem. Uma imagem em formato vetorial é formada por formas geométricas que por sua vez são formadas por segmentos de linha. Conectividade e hierarquia são as principais características de imagens em formato vetorial. Neste formato é fácil verificar quais segmentos de linha fazem parte de um objeto [FAC93].

Existe uma série de especificações de formatos de arquivos utilizados na descrição de imagens. Cada fabricante de um equipamento ou *software* para aquisição e manipulação de imagens cria um novo formato adequado a sua aplicação.

A solução para este número crescente de formatos diferentes e incompatíveis entre si, é a adoção de um formato padrão e a criação de conversores deste formato para os outros formatos de arquivos (e vice-versa) que possam ser necessários.

Atualmente alguns dos formatos mais utilizados para a descrição e armazenamento de imagens (usados principalmente junto a *softwares de desktop publishing*) são o BMP, GIF, TIFF, CUT, PCX e NAPLPS [OSO91].

Quando uma imagem vai ser exibida em um dispositivo de saída, este dispositivo pode ou não possuir a capacidade de exibição “imediata” da imagem. Em alguns casos pode ser necessário alterar a resolução espacial da imagem ou a quantificação dos valores de cada pixel, para que então esta possa ser exibida.

2.2.3 TRATAMENTO DE IMAGENS

As imagens digitais podem sofrer algumas modificações, através de um tratamento visando a alteração de suas características, tanto de resolução quanto de quantização. Uma das primeiras técnicas de tratamento de imagens consiste em alterar as características de representação das intensidades luminosas dos seus pontos. As imagens coloridas são consideradas como um caso especial, podendo ser tratadas tomando-se apenas uma escala de intensidades de uma dada cor por vez.

As imagens digitais podem sofrer uma série de operações denominadas operações com filtros. Estas operações realizam tarefas tais como: ressaltar elementos, suavizar ou aumentar o contraste, detectar bordas, remover ruído, etc. Os filtros podem ser implementados para realizar transformações das imagens [OSO91].

2.2.4 RECONHECIMENTO DE PADRÕES

O objetivo de reconhecimento de padrões junto ao processamento de imagens é o de extrair, detectar e identificar elementos presentes em uma cena. Desta maneira, procura-se imitar o ser humano e suas habilidades, tentando criar dispositivos e algoritmos capazes de realizar as mesmas funções realizadas pelo homem como: localizar objetos, classificar padrões e detectar relações entre estes. A principal vantagem é a de capacitar máquinas a realizarem tarefas até então só possíveis de serem realizadas por seres humanos. As aplicações do reconhecimento de padrões incluem funções como: compactação de dados, aumento da capacidade de aquisição de dados pelo computador, sensoriamento remoto, controle de qualidade, classificação de objetos e uma série de outras aplicações científicas e comerciais.

O reconhecimento de padrões abrange uma gama muito extensa de aplicações e tipos diferentes de objetivos, estando subdivididos em duas principais áreas, de acordo com o tipo de objetivo a ser alcançado: obtenção de descrições (segmentação, vetorização e detecção) e obtenção de classificação (casamento de padrões, identificação de um elemento pertencente a uma classe).

A segmentação da imagem é de grande importância para a análise da imagem. Muitos trabalhos têm sido feitos nesta área. Quando uma figura é segmentada normalmente ocorrem dois problemas [HAR83]:

- a) Longo tempo computacional e;
- b) O aperfeiçoamento dos resultados.

O primeiro problema é devido ao grande volume de dados que precisam ser inspecionados e devido a complexidade dos algoritmos “poderosos”, a segunda dificuldade vem do fato que a verificação ótica do homem é sempre subjetiva enquanto o mapeamento do processo de análise da imagem humana para programas eficientes de computador é restrita a alguns aspectos especiais. A diferença essencial entre o reconhecimento do homem e da máquina é o grande conhecimento humano em introduzir a sua análise da imagem [HAR83].

Três estágios do conhecimento podem ser distinguidos: a representação e armazenamento dos dados, o desenvolvimento de programas fazendo uso dos dados e a edição dos conhecimentos dos dados por aprendizado.

Pesquisas convencionais para a análise e reconhecimento de imagens consistem na segmentação da imagem dentro de regiões significativas, extraíndo seus limites e sua estrutura, computando variadas figuras e propriedades (ex. perímetro, centro, etc..) e princípios (ex. linha, curva, etc..) e as relações entre as regiões, finalmente, desenvolvendo regras decisivas de descrição, interpretação e / ou classificação da imagem e suas sub-regiões. Num sistema convencional, cada uma destas operações envolve decisões tortuosas (ex. sim ou não, preto ou branco, 0 ou 1) para fazer regiões, figuras, princípios, propriedades, relações e interpretações tortuosas [HAR83].

2.3 REDES NEURAIS

Na realidade, a teoria de redes neurais já começara em 1943 com o clássico artigo de McCulloch e Pitts, no qual os autores, pela primeira vez, conceberam o cérebro como um computador, consistindo de elementos computacionais bem definidos: os neurônios [FAU94].

Redes Neurais são verdadeiras máquinas concebidas para trabalharem segundo o mesmo processo de um sistema nervoso. Seus elementos de processamento são neurônios artificiais, altamente interconectados, que elaboram a soma ponderada das entradas e aplicam o resultado a uma função de transferência não-linear, para gerar uma saída. Essencialmente, estes modelos consistem dos elementos de processamento, uma topologia de interconexões, e esquemas de aprendizagem obtidos através de modelos matemáticos [LOE91].

2.3.1 NEUROCOMPUTAÇÃO

O cérebro humano é composto por células denominadas Neurônios. O cérebro possui acima de 100 bilhões de neurônios e estes dividem-se em 100 tipos diferentes. Os neurônios são separados em grupos denominados Redes. As redes possuem milhares de neurônios altamente conectados. Então, o cérebro pode ser visto como um conjunto de redes de neurônios [TUR93].

O cérebro humano é o dispositivo mais complexo conhecido pelo homem. A capacidade de pensar, memorizar e resolver problemas tem levado muitos cientistas a tentar modelar a sua operação. Diversos pesquisadores têm buscado criar um modelo computacional que represente a funcionalidade do cérebro, de uma maneira simples. Um destes modelos resultou na Neurocomputação, que tem como objeto de estudo as redes computacionais neurais.

2.3.2 O NEURÔNIO

O neurônio, basicamente, capta o estímulo nos dendritos e o transmite pelo axônio para que atinja um outro neurônio ou outros tipos de células. A captação do estímulo é realizada por receptores sensoriais especializados. Existem diversos tipos desses receptores: mecânicos, térmicos, nociceptores, químicos,... [TAF95].

Os estímulos entram nos neurônios através das sinapses, que conectam os dendritos (ramificações de entrada) de um neurônio com axônios de outros neurônios ou com o sistema nervoso, as quais regulam as quantidades de informações que passam dos dendritos para o neurônio. Os sinais são então passados para o somador (corpo celular), que os adiciona e os aplica a um sensor de limiar, que determina o nível de energia mínima de entrada acima do qual o neurônio dispara [Figura 7].

Se a soma dos sinais é maior que o nível de limiar, o neurônio envia energia através do axônio, de onde a energia é transmitida para outras sinapses (se bem que, muitas vezes, os axônios conectam-se diretamente com outros axônios ou corpos celulares); ou também pode realimentar a sinapse original, mas se a soma for menor do que o limiar nada acontece.

As sinapses têm um papel fundamental na memorização da informação, pois a maioria destas é que armazena a informação. Pode-se imaginar que em cada sinapse a quantidade de neurotransmissores que podem ser liberados para uma mesma frequência de pulsos do axônio representa a informação armazenada pela sinapse.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 100 bilhões neurônios, e o número de sinapses é de mais de 100 trilhões, possibilitando a formação de uma rede muito complexa [FAU94].




Figura 7 - Neurônio Biológico

2.3.3 O ELEMENTO DE PROCESSAMENTO

Um processo similar ocorre nos elementos de processamento em um sistema de computação neural, onde os sinais entram nos elementos de processamento através das conexões ponderadas. A informação está armazenada nestas conexões. Cada sinal que entra pelo sistema, que pode ser positivo ou negativo, é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade. É feita a soma ponderada dos sinais, que produz um certo nível de atividade [Figura 8].

Um resposta de saída é gerada somente se esse nível de atividade exceder um certo limite (*threshold*). Caso contrário, nenhuma saída é gerada para o particular elemento de processamento.

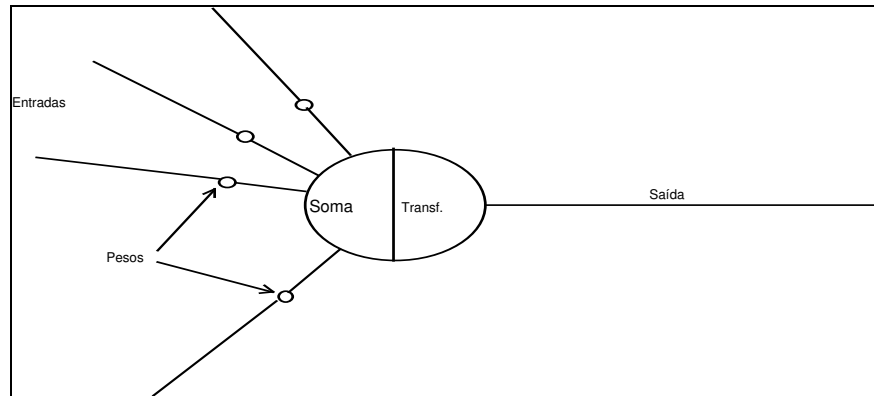


Figura 8 - Neurônio Artificial

As conexões ponderadas entre elementos processadores são chamadas de interconexões. A informação está armazenada em um padrão de interconexões, que constitui a memória distribuída da rede. As interconexões também estão envolvidas no processo de aprendizado, que é feito pelo ajuste do peso da interconexão [FAU94].

A operação dos elementos processadores envolve os seguintes passos:

- a) classificação dos sinais de entrada;
- b) computação das somas ponderadas individuais;
- c) combinação das somas ponderadas individuais;
- d) aplicação da função de transferência na soma.

2.3.4 ANALOGIA COM O CÉREBRO

Segue uma analogia do neurônio com o elemento de processamento [Quadro 2].

NEURÔNIO	ELEMENTOS DE PROCESSAMENTO
Dendritos	Entradas
Sinapses	Conexões ponderadas
Somador	Função somadora
<i>Threshold</i>	Função de transferência
Axônio	Saída global

Quadro 2 - Analogia com o Cérebro

2.3.5 REDES NEURAIIS ARTIFICIAIS

Uma rede de computação neural é um modelo matemático que consiste em várias unidades simples, semelhantes aos neurônios, denominados elementos de processamento. Estes elementos são organizados em camadas, onde cada elemento tem conexões ponderadas com outros elementos, sendo que estas conexões podem tomar diferentes configurações, dependendo da aplicação particular desejada [LOE96].




Figura 9 - Rede de Computação Neural

A rede neural é, geralmente, constituída de uma camada de entrada, que recebe os estímulos, e de uma camada de saída, que produz a resposta. Algumas redes podem ter uma ou mais camadas internas (escondidas). A capacidade computacional de uma rede neural está nas conexões entre os elementos processadores [Figura 9].

Uma rede neural artificial pode ser organizada de diferentes maneiras, à semelhança das redes biológicas. Entretanto, nas redes biológicas o processamento das informações é paralelo. Em contrapartida, em redes neurais artificiais simuladas por software, com computação convencional (hardware com arquitetura de Von Neumann), o processamento é limitado por ser serial [TUR93].

Basicamente, uma rede neural artificial é composta de uma coleção de neurônios agrupados em camadas, envolvendo a seguinte estrutura:

- a) número de camadas de neurônios;
- b) número de neurônios por camada;
- c) tipo de conexões;
- d) grau de conectividade.

2.3.5.1 CAMADAS

Basicamente as camadas de uma rede neural pode ser classificada como:

- a) Camada de Entrada: processamento dá-se em valores numéricos, onde em alguns casos cada valor de entrada corresponde a um único atributo. O pré-processamento faz-se necessário quando do tratamento de problemas envolvendo atributos qualitativos ou imagens, a fim de convertê-los para valores numéricos equivalentes [TUR93].
- b) Camada de Saída: Nesta camada encontra-se a solução para o problema proposto. Assim como a camada de entrada, esta não foge a regra, podendo somente assumir valores numéricos. Em caso de utilização de pré-processamento na camada de entrada, não se exige necessariamente que isto ocorra na de saída, porém é trivial a ocorrência em ambas camadas.

2.3.5.2 CONEXÕES

Quanto as conexões podemos ter as seguintes considerações:

- a) Peso das Conexões: Os pesos são elementos fundamentais à rede. Eles exprimem a força relativa, em valor numérico, dos dados introduzidos inicialmente ou às várias conexões que transferem dados de uma camada para outra. São eles que exprimem a importância relativa de cada entrada de um neurônio artificial [FAU94].
- b) Tipos de Conexões: Rede *FeedBack*, o resultado do processamento pode ser passado tanto para a próxima camada quanto para a camada precedente; rede *Feedforward*, o resultado do processamento passa somente para a próxima camada; rede *Feedlateral*, o resultado do processamento passa para os elementos da mesma camada, uma vez que ela apresenta conexões laterais [TAF95];
- c) Função Soma: Efetua cálculos de multiplicação e soma a fim de estabelecer a média dos pesos que compreendem as conexões dos neurônios da camada de entrada [TAF95];

- d) Função de Transferência: Com base no resultado da função soma, o neurônio produz ou não determinada saída. A partir de então a função de transferência modifica o valor de saída do neurônio para que o mesmo respeite uma determinada faixa de domínio [TAF95].

2.3.6 TOPOLOGIAS DE REDES NEURAIIS ARTIFICIAIS

A seguir serão apresentadas as topologias existentes nas redes neurais.

2.3.6.1 REDES DIRETAS (FEEDFORWARD)

São aquelas cujo grafo não tem ciclos. Frequentemente, é possível representar estas redes em camadas; neste caso, são chamadas redes em camadas. Os elementos que recebem sinais de excitação pertencem à camada de entrada. Os elementos que têm sua saída como saída da rede pertencem à camada de saída. Os elementos que não pertencem a nenhuma destas camadas são internos à rede e pertencem a uma ou mais camadas internas (*hidden layers*) [Figura 10].




Figura 10 - Rede direta com 4 camadas

2.3.6.2 REDES COM CICLOS

São aquelas cujo grafo de conectividade contém ao menos um ciclo e cujos elementos de processamento apresentam a possibilidade de realimentarem outros elementos. Quando, além disto, envolvem neurônios dinâmicos, são chamadas de recorrentes.

2.3.6.3 REDES SIMÉTRICAS

São aquelas cuja matriz de conectividade é uma matriz simétrica [Figura 11].




Figura 11 - Rede Simétrica com uma camada interna

2.3.7 TIPOS DE REDES NEURAIS ARTIFICIAIS

As redes computacionais são associativas e podem ser de dois tipos: Autoassociativa e Heteroassociativa.

2.3.7.1 REDE AUTOASSOCIATIVA

Em uma rede autoassociativa, quando o sistema é estimulado por uma informação ruidosa, a rede é capaz de produzir um padrão que tenha um mínimo de ruído. O comportamento deste tipo de rede pode ser descrito pela seguinte expressão:

$$f(X + \#) \rightarrow x(n)$$

onde a função $f(X + \#)$ mapeia o padrão de entrada X , mais algum ruído $\#$ para o padrão de saída x . Dada uma entrada ruidosa, a rede é capaz de inferir uma saída clara livre de ruído [TAF95].

2.3.7.2 REDE HETEROASSOCIATIVA

Uma rede heteroassociativa difere da anterior no tipo de interpretação que ela faz de uma informação ruidosa. Fornecido um padrão ruidoso, este tipo de rede é capaz de produzir uma classe de padrão a que não pertence, necessariamente da mesma classe do padrão original à expressão:

$$f(X + \#) \rightarrow x + \$ (n)$$

onde $f(X + \#)$ representa a função de uma heteroassociativa. Fornecida uma entrada ruidosa, é gerada um versão do padrão x com algum desvio $\$$ relacionado com o ruído $\#$ [TAF95].

2.3.8 MÉTODOS DE CONTROLE DO APRENDIZADO

A monitoração é o processo de controle do aprendizado da rede. Este processo de aprendizado acontece, basicamente, de duas formas: o aprendizado supervisionado e o aprendizado não-supervisionado [TAF95].

2.3.8.1 APRENDIZADO SUPERVISIONADO

O treinamento supervisionado do modelo de rede Perceptron consiste em ajustar os pesos e os *thresholds* de suas unidades para que a classificação desejada seja obtida. Para a adaptação do *threshold* juntamente com os pesos, pode-se considerá-lo como sendo o peso associado a uma conexão, cuja entrada é sempre igual a -1 e adaptar o peso relativo a essa entrada.

Quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada, são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir esta distância. Este procedimento é conhecido como Regra Delta [Figura 12].




Figura 12 - Regra Delta

Desse modo, tem-se o seguinte esquema de treinamento:

- a) Inicie todas as conexões com pesos aleatórios;
- b) Repita até que o erro E seja satisfatoriamente pequeno ($E = e$);
- c) Para cada par de treinamento (X, D) , calcule a resposta obtida O ;
- d) Se o erro não for satisfatoriamente pequeno ($E > e$), então atualize os pesos ($W_{\text{novo}} = W_{\text{anterior}} + \eta E X$).

Onde:

- a) o par de treinamento (X, D) corresponde ao padrão de entrada e a sua respectiva resposta desejada;
- b) o erro E é definido como a diferença entre a resposta desejada e a resposta obtida ($D - O$);

- c) a taxa de aprendizado η é uma constante positiva que corresponde à velocidade do aprendizado [Figura 13].




Figura 13 - Esquema de treinamento do Perceptron

2.3.8.2 APRENDIZADO NÃO-SUPERVISIONADO

As redes não-supervisionadas, por sua vez, tem a capacidade de determinar uma correlação entre os possíveis padrões de entrada e são particularmente úteis nos problemas em que as entradas variam com o tempo de forma conhecida [Figura 14]. Podemos considerar este mecanismo de aprendizado como sendo a capacidade que a rede possui de abstrair correlações entre os estímulos de modo a obter as respostas desejadas [MAR96].




Figura 14 - Aprendizado Não-Supervisionado

2.3.9 MODELOS DE REDES NEURAIS ARTIFICIAIS

A seguir serão apresentados os principais modelos de redes neurais e algumas aplicações.

2.3.9.1 APLICAÇÕES, VANTAGENS E DESVANTAGENS POR MODELO

Modelo	Aplicações Básicas	Ano	Vantagens	Desvantagens
Adaline/Madaline	Filtragem de sinal adaptativo, equalização adaptativa	1960	Rápida e Fácil de implementar	Somente é possível classificar espaços linearmente separáveis
Adaptative Resonance Theory (ART)	Reconhecimento de Padrões	1983	Capaz de aprender novos padrões	Naturaza dos exemplares categóricos podem mudar com o aprendizado
Backpropagation Perceptron	Reconhecimento de padrões, filtragem de sinal, controle robótico, compressão de dados, segmentação de sinal, etc.	1974 - 1986	Operação rápida, bem compreendida e com muitas aplicações de sucesso	Tempo de treinamento longo
BAM – Memória Associativa Bidirecional	Heteroassociativa (memória endereçada por conteúdo)	1987	Simples, prova clara da estabilidade dinâmica	Capacidade de armazenamento e precisão recuperação pobres
Boltzmann Machine, Cauchy Machine	Reconhecimento de padrões (imagens, sons, radar), otimização	1984	Capaz de formar representação ótima das características dos padrões	Tempo de aprendizado longo
Brain-State-in-a-Box (BSB)	Revocação autoassociativa	1977	Bom desempenho	Incompleta em termos de aplicações em potencial
Hopfield	Evocação autoassociativa, otimização	1982	Simples e estabilidade dinâmica	Incapaz de aprender novos estados
Neocognitron	Reconhecimento de caracteres manuscritos / imagens	1975	Capaz de reconhecer padrões independente da escala, translação e rotação	Estrutura complexa
Quantização de Vetor de aprendizagem	Revocação autoassociativa (complementação de um padrão a outro parcial apresentado), compressão de dados	1981	Capaz de auto-organizar vetores	Treinamento lento
Recurrent	Controle robótico, reconhecimento	1987	Excelente para	Rede complexa

	de fala, previsão do elemento sequencial		classificação, mapeamento de informações variando no tempo	
Redes de ligações funcionais	Classificação, mapeamento	1988	Rápida para treinar	Não é claro o modo de identificar funções adotadas
Time-Delay	Reconhecimento de fala	1987	Rápida operação	Janela fixada para a atividade temporal representada

FONTE: [LOE96]

Quadro 3 - Aplicações - Redes Neurais

2.3.9.2 MODELO PERCEPTRON

Perceptron foi a primeira rede neural a emergir. Possui o conceito substancial de neurônio artificial o qual é ainda hoje usado, onde cada neurônio computa uma soma ponderada de suas entradas, e passa esta soma em uma função não-linear com limiarização. Credita-se a Frank Rosenblatt a criação do Perceptron, projetado para o reconhecimento de padrões e para servir como ferramenta de pesquisa de modelagem de possíveis mecanismos cerebrais [LOE96].

A rede neural perceptron é formada pelos seguintes elementos [TAF95]:

- a) camada de entrada: cada elemento da camada de entrada faz a distribuição do sinal que ele recebe para todas as unidades de processamento;
- b) neurônios: são constituídos de unidades sigma (Σ) e de funções de transferência (T). As unidades sigma fazem a soma ponderada dos sinais vindos pelas conexões como os elementos de entrada. As funções de transferência determinam a saída de cada neurônio (unidade de processamento) em função da soma ponderada.




Figura 15 - Rede Neural Perceptron

Na rede apresentada pela Figura 15 temos:

- a) x : sinais de entrada
- b) w : peso da conexão entre a unidade de entrada i e a unidade de sigma j , onde $i=[1,n]$ e $j=[1,m]$
- c) s : soma ponderada da unidade sigma
- d) y : sinal de saída do neurônio

As redes perceptron tem apenas uma camada de processamento. Não existe um procedimento para ajustamento de pesos em redes Perceptrons com mais de uma camada (ao menos quando Perceptron foi criado). Estes problemas foram superados em modelos de redes que surgiram a partir dos anos 80 com o desenvolvimento de técnicas de aprendizado como, por exemplo Backpropagation. Mas, estas redes receberam outros nomes. Deixaram de ser Perceptrons [TAF95].

Para o funcionamento da rede, um padrão de entrada é apresentado à camada de entrada do Perceptron com n unidades, o que significa um vetor de comprimento n , um valor para cada elemento na camada de entrada. Calcula-se a entrada como sendo a soma ponderada de todas as ativações da primeira camada (esta soma ponderada é obtida pelo produto do vetor de entrada da primeira camada e a matriz de pesos). Deste valor obtido é subtraído um valor limiar (que é fixado para cada elemento). O resultado é aplicado à função de

transferência para obter a ativação do elemento. Portanto a ativação do j-ésimo elemento de processamento é dado por [Figura 16]:

$$s_j = \sum_i w_{ij} \cdot x_{ij} + w_{0j}$$

$$y_j = f(s_j) = \begin{cases} +1 & \text{se } s \geq 0 \\ -1 & \text{se } s < 0 \end{cases}$$

Figura 16 - Função de Transferência

Onde

- a) Y_j – é a ativação do j-ésimo elemento
- b) f – é a função de transferência
- c) X_{ij} – é a i-ésima entrada do elemento
- d) W_{ij} – é o peso na conexão da entrada i para o j-ésimo elemento; $j=0$ é o viés que controla o valor limiar.

O Perceptron suporta um aprendizado supervisionado, o que significa que para treinar a rede um conjunto de dados de treinamento deve ser construído e padrões de treinamento devem ser definidos.

No caso do Perceptron, a regra de aprendizagem é muito simples. É modificado cada peso (conexão) de acordo com a expressão [Figura 17]:

$$w_{ij} \leftarrow w_{ij} + \mu \cdot x_{ij} \delta_j$$

Figura 17 - Regra de Aprendizagem

2.3.9.3 MODELO FEEDFORWARD / BACKPROPAGATION

O modelo Feedforward com aprendizado Backpropagation, surgiu por meados da década de 80 e constitui, segundo pesquisadores, a mais difundida e largamente usada entre todas arquiteturas e modelos de redes neurais conhecidas [WIL95]. As inovações

incorporadas em relação aos modelos existentes até então foram as múltiplas camadas, com a possibilidade de valores de entradas e saídas contínuos (ex. 1.0001 à 2.9999).

O modelo apresenta limitações quanto ao número de camadas, pois a partir de certa quantidade, as camadas anteriores são repetidas, de forma a não demonstrar avanço no processo de convergência [LOE96]. Tal modelo utiliza-se de valores contínuos (ex. 0.0001 à 0.9999), o que difere do modelo *Perceptron* que utiliza valores discretos (ex. 0 ou 1).

Uma aplicação modelada nesta topologia, necessita de padrões de entrada e saída, para a qual a rede converge e se estabiliza, constituindo o que denomina-se de treinamento ou aprendizado da rede. Este modelo utiliza-se de aprendizado supervisionado, ou seja, a cada padrão de entrada está associado a uma saída desejada.

Os Elementos de Processamento das camadas ocultas dão ao modelo a capacidade de abstração e generalização, ou seja, é capaz de classificar um padrão complexo mesmo quando este não pertenceu ao conjunto de treinamento. A rede é, portanto imune a pequenas falhas.

A forma sistemática pela qual os valores são passados de uma camada a outra é a seguinte: a soma ponderada de cada elemento de processamento com os pesos associados às conexões existentes entre os neurônios, feita pelo módulo somador, é levada ao módulo de ativação que gera um sinal de saída [Figura 18]. Este sinal de saída será a entrada dos elementos da próxima camada.

$$Y_j = \sum_{i=1}^n X_i \cdot W_{ij}$$

Figura 18 - Função somadora do EP

Onde:

- a) Y_j = saída da rede neural do elemento j;
- b) Σ = somatório dos valores de entradas multiplicados por seus pesos;
- c) X_i = valor de entrada do índice i;
- d) W_{ij} = peso associado ao elemento j de índice i.

O treinamento deste modelo de rede consiste em ajustar os pesos de conexões das camadas para que o conjunto de entradas atinja o conjunto de saídas desejadas. O algoritmo de treinamento introduz os pares de entradas na rede, calcula as saídas (função soma e transferência) e verifica se as saídas obtidas com o cálculo estão próximas das saídas desejadas, considerando a taxa de erro. Caso o erro seja superior ao parametrizado para o modelo, os pesos serão corrigidos da saída para a entrada. Estas operações são repetidas quantas vezes forem necessárias até que a rede assimile os padrões (pares de entrada) a ela submetida.

A revocação é feita diante dos pesos das conexões armazenadas em arquivos. Nesta etapa, um novo padrão de entrada é oferecido (como par de entrada) a rede, ela computa e gera uma saída.

Sua rápida operacionalização, apresentando capacidade de generalização, robustez e abstração são suas principais vantagens. O fato de requerer um longo tempo de treinamento, em função da necessidade de estabilização e convergência da rede é sua desvantagem, segundo Loesch [LOE96].

2.4 CONTEXTO ATUAL DO TEMA

Existem alguns produtos com *software* e *hardware*, que utilizam este método para controle de acesso a computadores, anunciados no mercado por cerca de 100 dólares cada kit, a exemplo o kit da Compaq. Existem ainda, criadas por diversas empresas que atuam no ramo de segurança ou simplesmente empresas de software, DLL's que integram o leitor de impressão digital com qualquer sistema específico. Enfim, várias aplicações comerciais estão em desenvolvimento, entretanto, esta é uma área na qual o "como fazer" é um segredo industrial de cada fabricante. Os poucos trabalhos acadêmicos existentes sobre o tema, teses de doutorado e de mestrado, enfocam apenas partes específicas do problema ou são superficiais.

Outro produto que ganha funções em reconhecimento de impressões digitais é o Smartcard. O cartão traz embutido em memória um reconhecedor de impressões digitais, e pode servir como um excelente mecanismo de acesso, a exemplo o Smartcard da Siemens. O

reconhecimento é realizado de um *chip* contido no cartão que é conectado diretamente com um porta paralela do microcomputador.

2.5 TRABALHOS CORRELATOS

Seguem a descrição de alguns trabalhos correlatos encontrados.

2.5.1 DESCRIÇÃO DOS TRABALHOS

Os trabalhos correlatos encontrados foram:

- a) Dissertação de Mestrado – Hugo Vieira Neto – Reconhecimento Automático de Impressões Digitais - Um protótipo foi inteiramente projetado e construído para o desenvolvimento do sistema onde são considerados estágios de pré-processamento, segmentação, extração de características e classificação das impressões digitais.
- b) Dissertação - Álvaro Matos - Especificação, Implementação e Validação de um Algoritmo para Comparação de Impressões Digitais (1993 - Curitiba).

2.5.2 AVALIAÇÃO COMPARATIVA

Poucos trabalhos tratam do assunto e nenhum dos trabalhos e produtos encontrados esclarecem as técnicas utilizadas. Todos são superficiais na forma em que a solução para o problema foi proposta, apenas comenta-se que o problema foi solucionado. Não existem padrões para o reconhecimento, portanto as técnicas são segredos de cada fabricante.

3 DESENVOLVIMENTO DO TRABALHO

3.1 ESPECIFICAÇÃO

Assim como existem modelos para o processo de desenvolvimento de software os quais especificam as atividades a serem seguidas para a geração de um produto, existem também procedimentos para o desenvolvimento de redes neuronais artificiais largamente aceitos e que são comumente adotados. A computação neural é também uma abordagem para o processamento de informações destinada a aplicação em problemas para os quais algoritmos e regras nem sempre são conhecidos, e os softwares para implementá-los são caros, consomem muito tempo ou são inconvenientes para desenvolver, daí a importância do uso de uma metodologia de base para desenvolver [ROB90].

3.1.1 TÉCNICAS E FERRAMENTAS UTILIZADAS

Seguem as principais fases de uma rede neural.

3.1.1.1 FASES DE UM PROJETO DE REDES NEURAIIS

A aplicação dessa tecnologia tem variado muito, mas, de uma forma geral, o objetivo é quase sempre o mesmo, reconhecer e classificar padrões, e, possivelmente, também prever e generalizar informações. Sabe-se que um projeto utilizando redes neurais deve ser orientado para esse tipo de finalidade. Seria inconveniente desenvolver um projeto dessa ordem para, por exemplo, cadastrar clientes de uma loja. Seria mais condizente, porém, aplicar esse tipo de tecnologia para classificar o perfil dos clientes cadastrados dessa loja. O campo de aplicação de redes neurais é extenso. Deve-se tomar muito cuidado não somente ao aplicá-las, mas, também com o onde, o como e o quando aplicá-las. A rede, apesar de vasta aplicação, possui seus limites e sua área específica de atuação.

Uma vez diante de um projeto de uma rede neural, não pode-se mais pensar em procedimentos, regras ou fórmulas algorítmicas de processamento de dados, mas em tipos de dados de entrada, dados de saída e tratamento de dados.

A rede baseada nos dados terá dois momentos de explicitação do processamento: o momento de aprendizado e o momento de utilização (a aplicação da rede de fato). Deve-se

atentar para o fato de que, esses dois momentos de operação de uma rede neural, apesar de serem próximos, são bem distintos e aplicados em períodos diferentes no projeto da rede. O aprendizado é um processo de ajuste dos pesos das conexões em resposta à quantidade de erros gerada pela rede. Ou seja, a rede possui a propriedade de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada anteriormente. Já o processo de utilização é a maneira pela qual a rede responde a um estímulo de entrada. A principal diferença entre a utilização e o aprendizado é que nenhum ajuste de pesos é efetuado, e, da mesma forma, não há cálculo para a quantidade de erros ocorridos [TAF95].

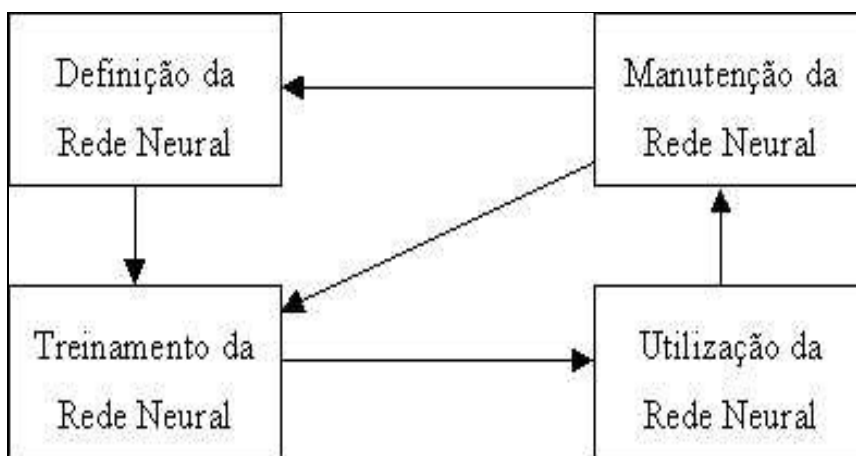


Figura 19 - Ciclo de vida de uma rede neural

Apesar do projeto de rede possuir essas duas fases distintas, aprendizado e utilização, o mesmo pode ser organizado num processo de implementação de 4 fases diferentes para consolidar uma utilização mais segura. O ciclo de vida de uma rede, como é o conhecido, é composto pelas seguintes fases: Definição, Treinamento, Utilização e Manutenção [Figura 19].

Essas fases do projeto podem ser divididas em muitas outras fases intermediárias. Essas 4 fases, porém, definem de uma forma mais generalizada os contextos diferentes em que uma rede pode-se encontrar.

3.1.1.1.1 CONCEPÇÃO DA REDE NEURAL

As fases de Definição e Treinamento são as fases iniciais do projeto, seguidas, depois, das fases de Utilização e Manutenção da rede. Seria interessante acrescentar, ainda, uma fase que antecederesse a todas as outras 4 fases, a fase de concepção [Figura 20].




Figura 20 - Estagio da Concepção

Essa fase constitui o planejamento da construção da aplicação, ou seja, a validação da proposta e a seleção do paradigma neural. Neste ponto devem ser colocados em pauta, e devidamente julgados, aspectos que, por quaisquer outros motivos, não recaiam por surpresa, posteriormente, sobre o projeto. Aspectos como tecnologia inadequada, dados incompletos, ou dados com ruídos [TAF95].

3.1.1.1.2 DEFINIÇÃO DA REDE NEURAL

A fase de Definição é delicada, pois envolve, além da escolha do modelo da rede, a obtenção do conjunto de variáveis significativas para a resolução do problema. Essa obtenção envolve, além da identificação das variáveis que estão relacionadas com o problema, a remoção de variáveis não confiáveis para o processo, ou cujo uso seja impraticável por razões técnicas ou econômicas [TAF95].

A definição também é entendida como uma seleção do paradigma neural na qual são levados em consideração os seguintes aspectos da rede:

- a) tamanho da rede – selecionado o tamanho da rede, será delimitado também o escopo do problema. Por isso, a escolha e a visualização desse escopo é essencial para selecionar o tamanho da rede neural.
- b) tipo de problema a ser resolvido – este é mais um ponto importante pois o tipo de saída limita o paradigma a ser selecionado, A saída pode ser interpretada de diversas formas: classificação, padronização e otimização.
- c) classificação – faz o mapeamento da entrada em categorias discretas.
- d) padronização – neste tipo de saída, neurônios múltiplos potencialmente ativos formam um padrão de respostas às entradas apresentadas.
- e) otimização – é um padrão especial interpretado como conjunto de decisões. A saída deverá representar a entrada, porém com bem menos neurônios, ou seja, houve uma compactação.
- f) tipo de associação – o tipo de associação é dividido basicamente em dois: memória auto-associativa (aprendizado não supervisionado) e memória hetero-associativa (aprendizado supervisionado).

Para o desenho da rede é preciso especificar os valores e as condições iniciais para o paradigma selecionado. Essas especificações acontecem em 3 níveis: neurônio, rede e treinamento [Figura 21].




Figura 21 - Desenho da rede

Para o nível de neurônios é escolhido o tipo de entrada, a integração dessas entradas e a função de transferência do neurônio. No nível de rede, a escolha é feita para o número de camadas, os números e os tipos dos neurônios de entrada, saída e intermediários, além do tipo de conectividade. Deve-se tomar certo cuidado com a escolha do número de camadas, pois, quando o número de camadas intermediárias é muito grande, pode acabar fazendo com que a rede memorize os dados em vez de generalizá-los. E finalmente, para o nível de treinamento é escolhido o algoritmo de aprendizado juntamente com o parâmetro de aprendizado.

3.1.1.1.3 TREINAMENTO DA REDE NEURAL

A fase de treinamento compreende, inicialmente, a definição de um dos dois conhecidos de métodos de treinamento: o aprendizado supervisionado e o aprendizado não-supervisionado [TAF95].

- a) aprendizado supervisionado – requer, para o treinamento, pares de dados constituídos de um padrão de entrada e um padrão de saída (valor desejado na saída);
- b) aprendizado não-supervisionado – o treinamento não-supervisionado classifica padrões de entrada internamente, não exigindo a definição de valores desejados na saída.

Quando fala-se de pares de dados para o modelo supervisionado, fala-se de dois vetores de dados. Cada vetor de entrada possui um vetor correspondente de saída. Estes dois vetores distintos, não necessariamente de mesmo tamanho, possuem uma relação entre si.

Quando fala-se de treinamento não-supervisionado, não existe a necessidade do segundo vetor pois, como não existe uma supervisão (a saída Y para a entrada X), não existe também a necessidade de existir o vetor de saídas.

O treinamento, pode-se assim dizer, inicia quando um exemplo é mostrado à rede e termina quando todas as conexões estão devidamente ajustadas (treinadas) para reconhecer todos os exemplos mostrados à rede. A partir deste momento a rede neural está pronta para a fase de testes e, a seguir, para a execução [Figura 22].

Quanto ao conjunto de dados que será submetido à rede, pode-se dizer que, quanto mais completo o conjunto, mais tempo computacional será utilizado para ajustar as conexões e, certamente, melhor será o seu treinamento.

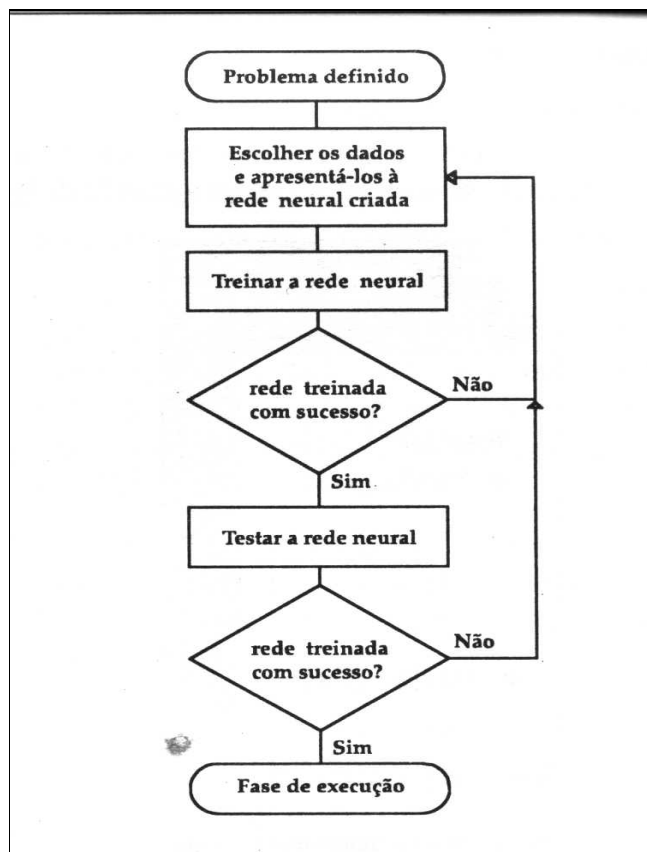


Figura 22 - Fluxo de treinamento

Com o intuito de se obter uma qualidade representativa dos dados para formar um bom conjunto deve-se levar em conta aspectos como:

- a) tipos dos dados a serem coletados – buscar dados que tenham um grau de pertinência elevado em relação ao escopo do problema;
- b) quantidade desses dados para obter um número elevado de conjuntos de dados para que, submetidos à rede, efetuem um bom treinamento. Vale a regra: quanto maior a experiência melhor o desempenho;
- c) preparação dos dados – dependendo do tipo dos dados que serão submetidos a rede, estes devem sofrer uma preparação para melhor representar a informação.

Essa fase (treinamento) costuma receber atenção especial, pois quanto melhor o conjunto de treinamento, melhor o resultado da atuação da rede.

3.1.1.1.4 UTILIZAÇÃO DA REDE NEURAL

Essa fase é a execução da rede, iniciando quando uma entrada é apresentada à rede e terminando com o rede gerando uma saída.

Antes de prosseguir com a utilização em campo, é indispensável, no mínimo, um teste na rede para nela verificar a incidência ou não de erros. Para tal atitude, é recomendável a apresentação de uma série de casos teste e avaliar profundamente as respostas geradas. Para os testes devem-se utilizar casos já experimentados e casos completamente novos, ou seja, ainda não vistos pela rede. Usem-se também casos de rotina e casos extremos. Contudo, é bom lembrar que, para avaliar as respostas da rede deve-se antes determinar um limite de aceitação da resposta da rede. Se a fase de testes for satisfatória, considera-se a rede bem treinada para a finalidade em questão [TAF95].

Dependendo da maneira que se utiliza a rede, ela apontará ou não uma performance satisfatória, e, mostrando-se inadequada, deverá ser avaliada em termos de origem do problema, que por sua vez, poderá ocorrer tanto na fase de definição da rede quanto na fase de treinamento, sem excluir, em última análise, a fase de concepção.

Lembramo-nos que, apesar de terem sido feitos testes para qualificar um treinamento, nada impede que apareçam falhas durante a fase de utilização. Afinal, uma rede neural não é treinada para 100% de acertos, uma vez que não foi treinada com 100% dos casos possíveis. A inviabilidade para tamanha precisão é muito alta.

3.1.1.1.5 MANUTENÇÃO DA REDE NEURAL

Sobre a manutenção, pode-se dizer que a maioria das redes são treinadas para solucionar problemas dinâmicos. Uma avaliação contínua, portanto, é necessária e indispensável para garantir uma boa utilização. À medida que o tempo avança, poderão surgir novos conjuntos de dados reais ainda desconhecidos pela rede, e, dessa forma,. Será necessário um novo aprendizado ou, dependendo do caso, até mesmo uma nova definição [TAF95].

Caso os testes indiquem erros significativos, o projetista da rede neural deve resolver o problema iniciando pelo processo de treinamento [Figura 23]. Examine a qualidade dos casos usados, a representatividade, os parâmetros do algoritmo usado para treinar. Preste atenção também na arquitetura utilizada na rede, sua conectividade e as características dos neurônios.

Sendo uma manutenção, um processo dinâmico, é bom prestar atenção em detalhes como a queda de precisão durante o processo de utilização, como também nos problemas que possam vir a ser detectados na avaliação do sistema realizado de tempos em tempos.

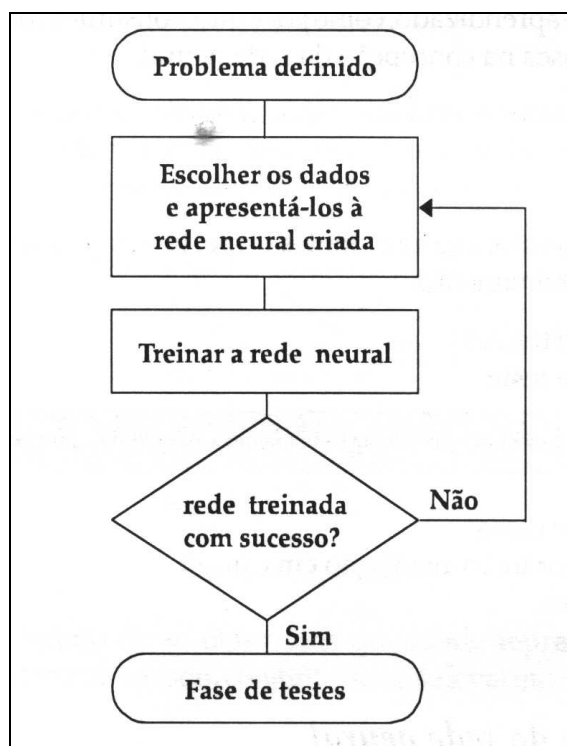


Figura 23 - Fluxograma de Treinamento e Testes

3.1.2 APRESENTAÇÃO DA ESPECIFICAÇÃO

As impressões digitais são diferenciadas sob dois critérios principais. O primeiro critério está relacionado ao TIPO da impressão e o segundo critério está relacionado à distribuição planar das MINÚCIAS. O critério de TIPO representa uma visão macroscópica da impressão digital, definida pelo comportamento das linhas datilares nos dedos. Em função deste comportamento, uma impressão digital é classificada, como Arco, Verticilo, Presilha Externa ou Presilha Interna. Esta visão macroscópica permite, num processo de comparação

de duas impressões digitais, afirmar a não identidade no caso de TIPOS diferentes. Quando os TIPOS de duas impressões digitais são iguais, o segundo critério, das MINÚCIAS, permite afirmar ou não a identidade em função da ocorrência ou não de um mapeamento posicional entre os diversos tipos de MINÚCIAS.

Neste trabalho, está se propondo uma automatização da classificação do TIPO da impressão digital. Essa automatização envolve desde a aquisição da imagem de uma impressão digital até as operações de classificação do tipo da mesma [Figura 24].

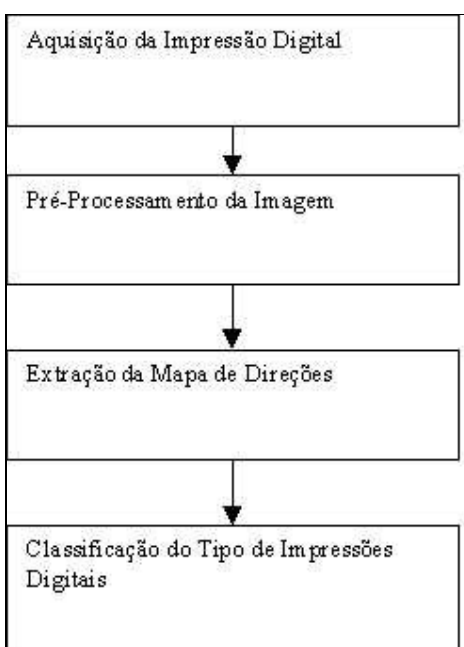


Figura 24 - Processo de classificação da impressão digital

No processo de aquisição, as imagens são obtidas a partir da digitalização de impressões digitais adquiridas por meio tradicional (tinta em ficha de papel). As impressões digitais são capturadas através de um *scanner*, obtendo-se uma imagem de 120 x 120 *pixels* com 256 níveis de cinza, em formato BMP.

No processo de pré-processamento, a imagem deve então ser binarizada (preto e branco). Para tal foi utilizado um algoritmo desenvolvido para essa tarefa, que efetua a

binarização da imagem, ou seja, analisa o grau de luminosidade do pixel, onde se for igual a 0 (zero) é considerado preto senão é considerado branco.

Num processo seguinte é ocorrida a extração do mapa de direções da imagem binarizada. Uma opção vantajosa, face às características do problema em questão (obtenção do mapa de direções), é a utilização de uma rede neural dada a sua reconhecida capacidade de generalização e pouca sensibilidade a ruído. Outro ponto positivo é a redução da imagem, facilitando o próximo passo, que é o reconhecimento do tipo da impressão digital.

Para que a rede possa apresentar o resultado desejado, os dados de entrada na rede devem ser escolhidos de forma a criar classes com características independentes entre si. Após um exaustivo estudo e testes com diferentes padrões de entrada correspondentes as principais características presentes nas impressões digitais (linhas e formas), verificou-se a possibilidade de uma separação em classes de padrões de direções principais das linhas. Chegou-se a esta conclusão pelo fato de que os espaços entre as linhas possuem em média a mesma largura das linhas. Logo, o espaço inter-linhas também pode ser considerado um padrão de direção.

O tamanho do bloco escolhido para servir como entrada da rede neural, após o testes de outras possibilidades, foi de 6 x 6. Esta escolha foi baseada na largura média das linhas nessa resolução (2 a 3 *pixels*).

A próxima etapa do processo é a identificação do tipo da impressão digital através do mapa de direções. Para tal também foi escolhida uma rede neural, dada sua grande capacidade de generalização. Uma vez que a tarefa em questão era mais complexa que a anterior optou-se por uma arquitetura de rede de maior capacidade, no caso uma *Feedforward Backpropagation*.

Para que essa rede apresente um resultado satisfatório, o mapa de direções deve permitir a distinção correspondente da impressão digital, pois os dados deste serão os dados de entrada para a rede neural nesta etapa. Assim, a rede será treinada para reconhecer os quatro tipos de impressões digitais.

3.1.2.1 DEFINIÇÃO DA REDE NEURAL

Foram selecionados para esse projeto dois modelos de redes neurais:

- a) Perceptron;
- b) Backpropagation.

Para a realização do processo de extração da mapa de direções, foi escolhida uma estrutura neural *Feedforward*, baseada no algoritmo *Perceptron* para seu treinamento.

Esta rede apresenta como entrada 36 neurônios, que representam um bloco de 6 x 6 *pixels*, e na saída apresenta 16 neurônios que representam 8 classes distintas relativas as direções principais das linhas e 8 classes relativas as direções principais das inter-linhas (espaços entre as linhas), exemplificadas nas figuras 25, 26 e 27. Tais classes estão relacionadas as seguintes direções: 0°, 22.5°, 45°, 67.5°, 90°, 112.5°, 135°, 157.5°. Essas classes são codificados pelos dígitos de 1 a 16. Essa escolha de treinar os espaços como classes independentes, ou seja, separadas das linhas, foi detectada na fase de treinamento. Pois não obteve-se um bom resultado com o treinamento sem a separação, a rede não tornava-se genérica suficiente para reconhecer os padrões.



Figura 25 - Padrão definido representando uma linha de 0°



Figura 26 - Padrão definido representando um espaço (inter-linha) de 0°




Figura 27 - Padrão definido representando uma linha de 45°

O treinamento da rede foi efetuado para se ter na saída desta apenas um neurônio ativo representando cada uma dessas classes. Para aplicação em questão, este nível de precisão foi julgado suficiente, pois de um lado ele permite discriminar com razoável definição as direções principais das linhas que constituem as impressões digitais de outro, aproveitar ao máximo a resolução angular (linhas, em média, com 2 a 3 *pixels* de largura) contida em cada bloco de 6 x 6 *pixels*.

Após o processo de definição do mapa de direções a entrada passa de uma imagem da impressão digital para uma imagem de um mapa de direções conforme ilustrado nas figuras 28 e 29:



Figura 28 - Impressão Digital




Figura 29 - Mapa de Direções correspondente a impressão digital anterior

Numa segunda etapa, para realização do processo de classificação dos tipos de impressões digitais, foi escolhida uma estrutura neural *Feedforward*, baseada no algoritmo *Backpropagation* para seu treinamento.

A rede apresenta como entrada 400 neurônios que representam a matriz do mapa de direções (20 x 20) gerada pela rede anterior (*Perceptron*).

O treinamento da rede foi efetuado para que se tenha como resultado um número entre 0 e 1, de forma que o valor resultante possa identificar o tipo de impressão digital (Arco 0 – 0.25, Presilha Externa 0.25 – 0.50, Presilha Interna 0.50 – 0.75, Verticilo 0.75 – 1.00).

3.1.2.2 TREINAMENTO DAS REDES NEURAIIS

Na figura 30 é apresentado um fluxograma demonstrando o treinamento das redes neurais.

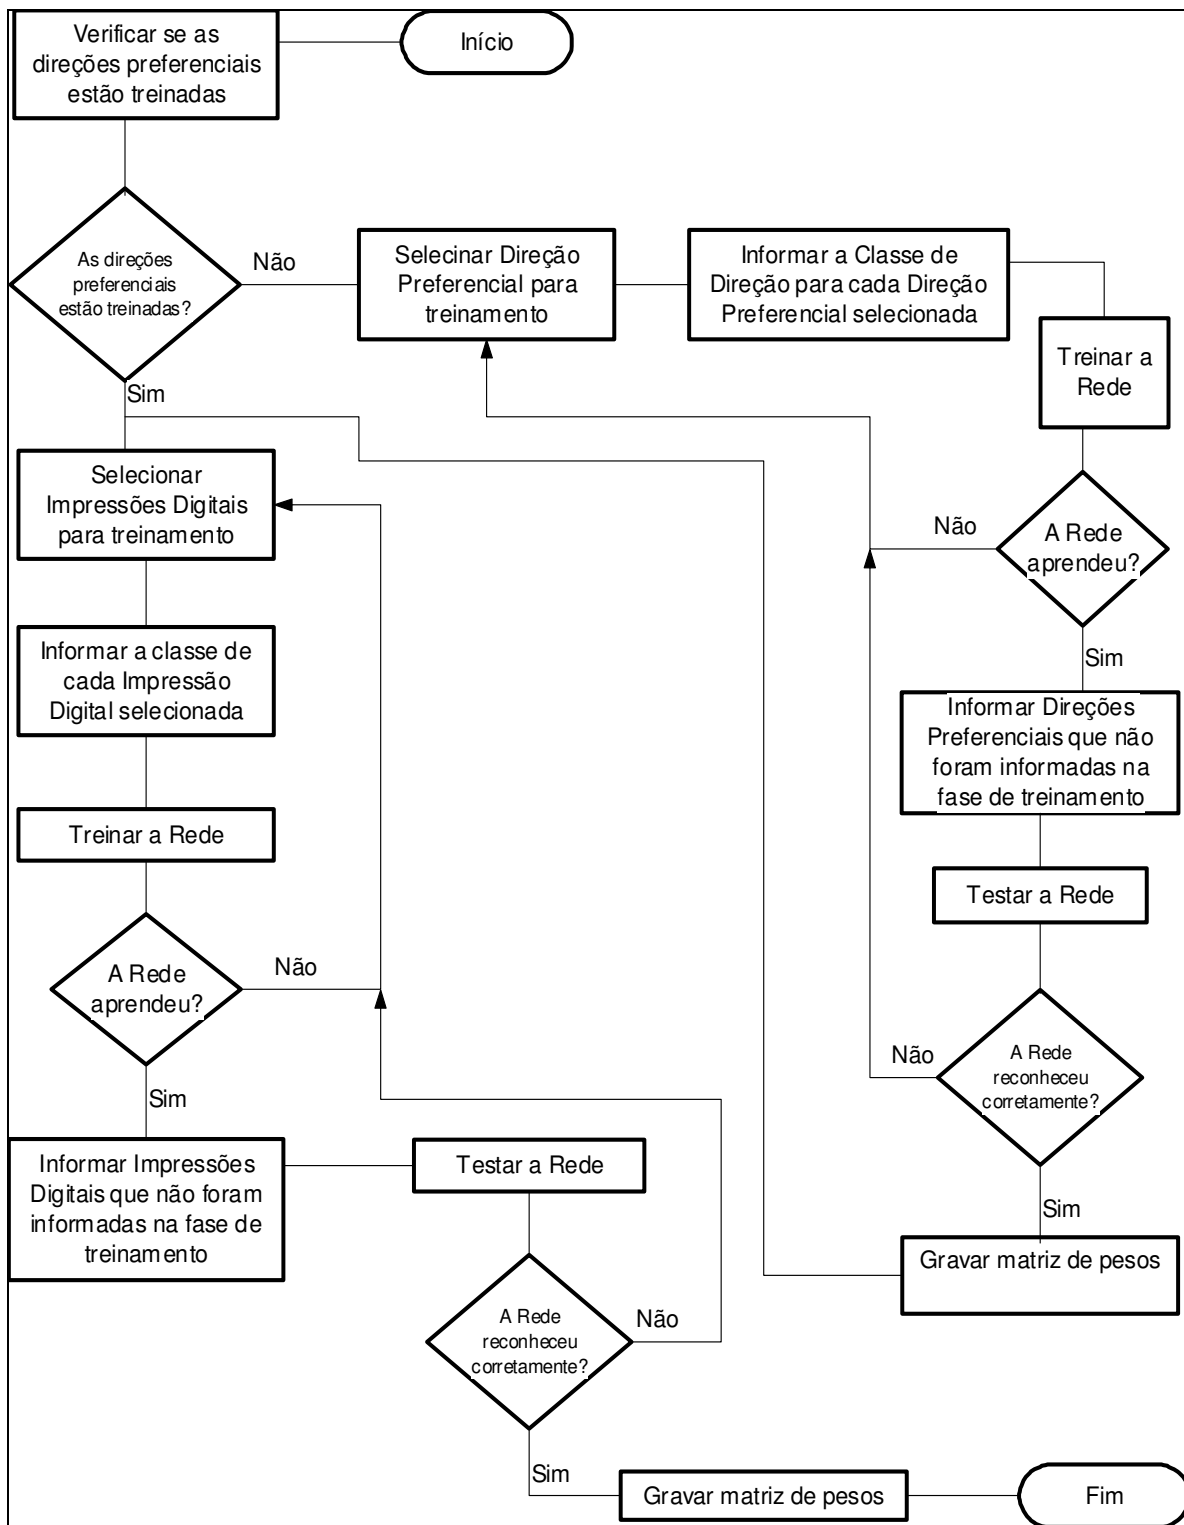


Figura 30 – Fluxograma da etapa de treinamento

Para o treinamento da primeira etapa, extração do mapa de direções, foi utilizado um aprendizado supervisionado. Foram criados blocos de imagens binárias, de tamanho de 6 x 6 *pixels*, correspondendo a cada um dos definidos padrões de direção. Estas imagens indicam a presença de linhas com 2 e 3 *pixels* de largura, representando a média da largura das linhas encontradas nas imagens binarizadas das impressões digitais. Foram utilizados padrões com deslocamento de linhas e com vários níveis de ruídos. Desta forma gerou-se diversos blocos de imagens com 3 *pixels* invertidos em média para cada padrão obtido [Figura 31]. Esta estratégia foi utilizada para possibilitar um treinamento exaustivo, utilizando-se um grande número de padrões de imagens. Com isso, obteve-se um grupo de 320 padrões que resultam em 16 classes distintas de direções.




Figura 31 - Padrão definido representando uma linha de 22.5° com ruído

Para o treinamento da segunda etapa, identificação do tipo de impressão digital, foi utilizado também um aprendizado supervisionado. Como entrada foi utilizado o mapa de direções gerado na etapa anterior. Com isso, obteve-se um grupo de 80 padrões (matrizes) que podem ser classificados nos 4 tipos de impressões digitais (Arco, Presilha Externa, Presilha Interna e Verticilo).

3.1.2.3 UTILIZAÇÃO DA REDE NEURAL

Para avaliação do desempenho da rede na primeira etapa (extração do mapa de direções) foram selecionadas uma seqüência de impressões digitais para teste. As imagens foram segmentadas em blocos de 6 x 6 *pixels*. E resultaram em uma seqüência de blocos similares aos blocos apresentados na fase de treinamento. O reconhecimento da direção preferencial de cada bloco foi obtido com sucesso, bem como a geração da matriz com os códigos das direções preferenciais.

Num processo seguinte foi avaliado o desempenho da rede neural *Backpropagation*, por meio da apresentação de vários mapas de direções que não haviam sido treinados. Esta rede também acertou a classificação de todos os padrões de impressões digitais.

3.2 IMPLEMENTAÇÃO

Seguem algumas considerações sobre as técnicas e ferramentas utilizadas para fazer a implementação a partir da especificação.

3.2.1 DELPHI

A programação, a tempos atrás, era uma atividade restrita a usuários “experts” em computação, pois exigia não apenas lógica, mas um profundo conhecimento dos recursos e das limitações das ferramentas disponíveis. A nova geração de ferramentas de programação visual está surgindo para possibilitar usuários, com algum conhecimento em desenvolvimento de aplicações, desenvolverem seus próprios programas, tornando menos abstrato a relação homem/máquina [RUB95].

O ambiente de desenvolvimento escolhido para a implementação do protótipo foi o Delphi 3.0 (Borland), tendo em vista a familiaridade do autor do trabalho com este ambiente e sua adequação a implementação dos procedimentos já citados.

3.2.1.1 CARACTERÍSTICAS

Duntemann [DUN95], Rubenking [RUB95] e Matcho [MAT96] descrevem algumas características do Delphi:

- a) descendente do Turbo Pascal;
- b) programação orientada a objetos;
- c) programação baseada em eventos;
- d) linguagem compilada e não interpretada;
- e) desenvolvimento rápido de aplicações (RAD);
- f) padrão SQL em banco de dados;
- g) conectividade através de ODBC.

O Delphi contém um conjunto de recursos que vai desde seu criador de formulários (*Form Designer*) até o suporte transparente a todos os formatos mais comuns de banco de dados. Alguns dos principais recursos segundo Matcho [MAT96] e Osier [OSI97]:

- a) componentes reutilizáveis e ampliáveis;
- b) suporte a OCX;
- c) modelos de aplicativos e de formulário;
- d) ambiente personalizado de desenvolvimento;
- e) programas compilados;
- f) recursos eficientes de acesso a dados;
- g) criação de bibliotecas de funções, as DLLs;
- h) assistente para criação de formulários.

Entre os recursos citados acima, destacam-se dois: os componentes reutilizáveis e ampliáveis; e a criação de DLLs, pois com o surgimento dos mesmos aprimoraram-se as formas de programação em módulos [MAT96].

3.2.2 DIAGRAMA DE CONTEXTO

Segue o Diagrama de Contexto apresentado na Figura 32.

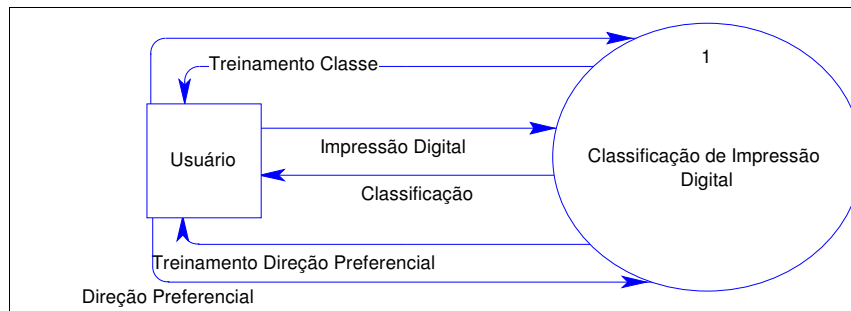


Figura 32 - Diagrama de Contexto

3.2.3 CÓDIGO DAS REDES NEURAIIS IMPLEMENTADAS

A seguir serão apresentados os algoritmos de aprendizado das redes neurais *Backpropagation* e *Perceptron*.

3.2.3.1 REDE BACKPROPAGATION

Segue o algoritmo de aprendizado da rede *Backpropagation*:

```

Procedure Multiplica_B (Ent : Tp_Pa_Ent_B; var Saida : Double);
Var
  x : Word;
  FSoma,FSomaAux,e : Double;
Begin
  FSoma := 0;
  x:=0;
  FSomaAux := M_Apr_B[x];
  For x := 1 to Ult_Pa_Ent_B Do
    FSoma := FSoma + (M_Apr_B[x] * Ent[x]);
  FSoma := FSoma + FSomaAux;
  e := Exp(FSoma*-1);
  Saida := 1 / (1 + e);
End;

Procedure TFTreinaID.Calc_Mat_Aprendizado_B;
Var
  C_Int, C_Pa, C_Pa_Ent : integer;
  Erro : Boolean;
  Saida, Saida_Real, Sinal_Erro, Esperado, Vl_Antigo,
  Vl_Novo, Entrada : Double;

Begin
  Erro := True;
  C_Int := 0;
  { ate acabarem os erros = aprendeu ou atingir o maximo de interacoes }
  While (Erro) And (C_Int <= Qt_Max_Iter_B) Do
    Begin
      Erro := False;
      Inc(C_Int);
      { para todos os padroes }
      For C_Pa := 1 to Ult_Padrao_B Do
        Begin
          Multiplica_B(Vet_Padroes_B[C_Pa].E_B,Saida);
          Esperado := Vet_Padroes_B[C_Pa].S_B;

```

```

Saida_Real := Saida;
{ Calcula novos valores na matriz de aprendizado}
If (Saida_Real > Esperado) or (Saida_Real <
                                (Esperado-0.25)) Then
Begin
  Erro := True;
  Sinal_Erro := (Esperado-
                Saida_Real)*(Saida_Real*(1-Saida_Real));
  For C_Pa_Ent := 1 to Ult_Pa_Ent_B DO
  Begin
    Entrada := Vet_Padroses_B[C_Pa].E_B[C_Pa_Ent];
    Vl_antigo := M_Apr_B[C_Pa_Ent];
    Vl_Novo := Vl_Antigo + (Passo*Sinal_Erro * Entrada);
    M_Apr_B[C_Pa_Ent] := Vl_Novo;
  End;
  Entrada := 1;
  Vl_antigo := M_Apr_B[0];
  Vl_Novo := Vl_Antigo + (Passo*Sinal_Erro * Entrada);
  M_Apr_B[0] := Vl_Novo;
End;
End;

LMens.caption:=' Iteração : '+IntToStr(C_Int);

End;
If Erro Then
  LMens.caption:=' Nao Aprendeu, '+IntToStr(C_Int)+' iterações !!'
Else
  LMens.caption:=' Aprendeu, '+IntToStr(C_Int)+' iterações !!';
End;

```

3.2.3.2 REDE PERCEPTRON

Segue o algoritmo de aprendizado da rede *Perceptron*:

```

Procedure Funcao_Trans(var S : Tp_Pa_Sai);
Var
  I : Word;
Begin

```

```

    For I :=1 to Ult_Pa_Sai Do Begin
        If S[I] >= 0 Then S[I] := 1
        Else          S[I] := 0;
    End;
End;

Procedure Multiplica(M : Tp_M_Apr; E : Tp_Pa_Ent; var S : Tp_Pa_Sai);
Var
    I, J : Word;
Begin
    FillChar (S,Sizeof(S),#0);
    For I := 1 to Ult_Pa_Sai Do
        Begin
            For j := 1 to Ult_Pa_Ent + 1 Do
                Begin
                    S[I] := (M[I,j] * E[J]) + S[I];
                End;
            End;
        End;
    End;

Procedure TFTreinaDirecao.Calc_Mat_Aprendizado;
Var
    C_Int, C_Pa, C_Pa_Ent,C_Pa_Sai : integer;
    Erro : Boolean;
    Saida : Tp_Pa_Sai;
    Esperado, Saida_Real, Vl_Antigo, Vl_Novo, Entrada : Integer;

Begin
    Erro := True;
    C_Int := 0;
    { ate acabarem os erros = aprendeu ou atingir o maximo de iteracoes }
    While (Erro) And (C_Int <= Qt_Max_Inter) Do Begin
        Erro := False;
        Inc(C_Int);
        { para todos os padroes }

        For C_Pa := 1 to Ult_Padrao Do Begin
            Multiplica(M_apr,Vet_Padroes[C_Pa].E,Saida);
            Funcao_Trans(Saida);
        End;
    End;
End;

```



```

For C_Pa_Sai:=1 to Ult_Pa_Sai Do Begin
    Esperado := Vet_Padrees[C_Pa].S[C_Pa_Sai];
    Saida_Real := Saida[C_Pa_Sai];
    { Calcula novos valores na matriz de aprendizado}
    If Esperado <> Saida_Real Then Begin
        Erro := True;
        For C_Pa_Ent := 1 to Ult_Pa_Ent DO Begin
            Entrada := Vet_Padrees[C_Pa].E[C_Pa_Ent];
            Vl_antigo := M_Apr[C_Pa_Sai,C_Pa_Ent];
            Vl_Novo := Vl_Antigo + (Tx_Apren*(Esperado - Saida_Real) *
                Entrada);
            M_Apr[C_Pa_Sai,C_Pa_Ent] := Vl_Novo;
        End;
    End;
End;
End;
End;

LMens.caption:=' Iteração : '+IntToStr(C_Int);

End;
If Erro Then
    LMens.caption:=' Nao Aprendeu, '+IntToStr(C_Int)+' iterações !!'
Else
    LMens.caption:=' Aprendeu, '+IntToStr(C_Int)+' iterações !!';
End;

```

3.2.4 OPERACIONALIDADE DA IMPLEMENTAÇÃO

Inicialmente, caso não exista a matriz de pesos do mapa de direções ou da classificação, os botões de “Abrir arquivo”, “Classificar” e “Mapa de Direções” estarão inibidos [Figura 33].



Figura 33 - Tela Inicial

O próximo passo, então, será treinar as classes de impressões digitais. Pressionando o botão “Treinar” da tela inicial será exibida a seguinte tela [Figura 34].

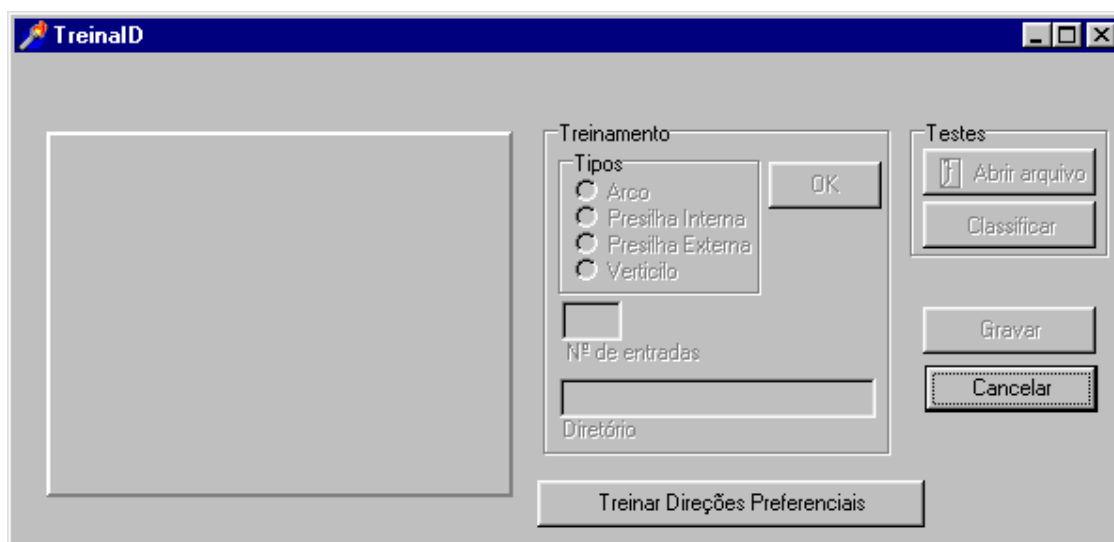


Figura 34 - Tela de treinamento das ID

Caso não exista a matriz de pesos das direções preferenciais estarão exibidos somente os botões “Treinar Direções Preferenciais” e “Cancelar”. Após isso pressionando o botão “Treinar Direções Preferenciais” será exibida a seguinte tela [Figura 35].



Figura 35 - Tela de treinamento das direções preferenciais

O próximo passo será configurar o número de entradas para cada classe e o diretório onde estão as imagens [Figura 36].



Figura 36 - Tela de treinamento das direções preferenciais

A seguir serão treinadas as direções preferenciais de acordo com as classes de direções apresentadas. O treinamento deverá ser feito nas linhas e inter-linhas para cada direção [Figura 37].

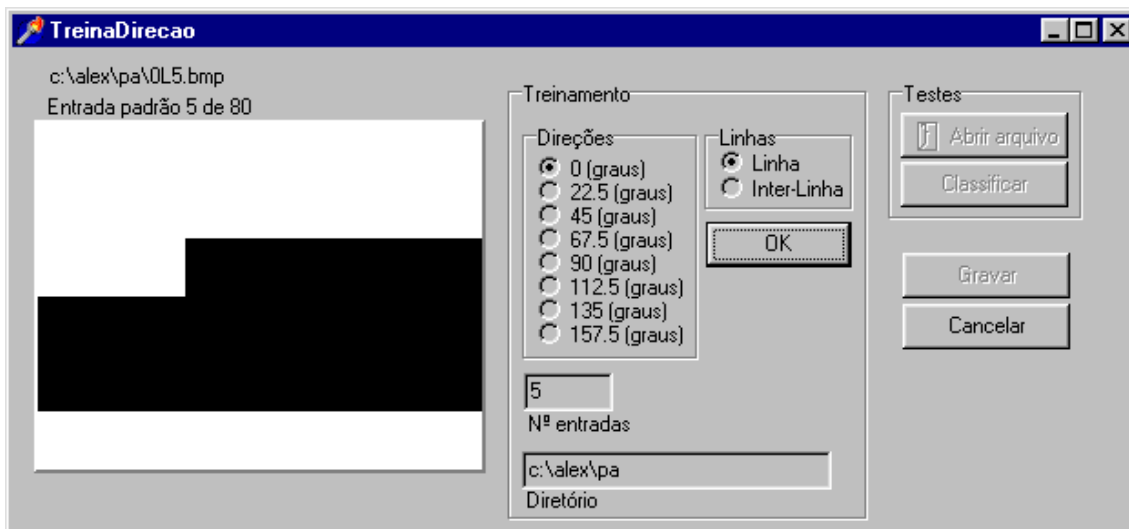


Figura 37 - Tela de treinamento das direções preferenciais




Figura 38 - Tela de treinamento das direções preferenciais

E assim sucessivamente até chegar ao número máximo de padrões, que no exemplo citado é 80 [Figura 38]. Ao chegar ao número máximo de padrões o treinamento ocorre automaticamente [Figura 39].




Figura 39 - Tela de treinamento das direções preferenciais

Após isso serão testadas algumas classes de direções que não participaram da fase de treinamento para averiguar o aprendizado da rede. Para isso, basta abrir o arquivo desejado e pressionar o botão “Classificar” [Figura 40].

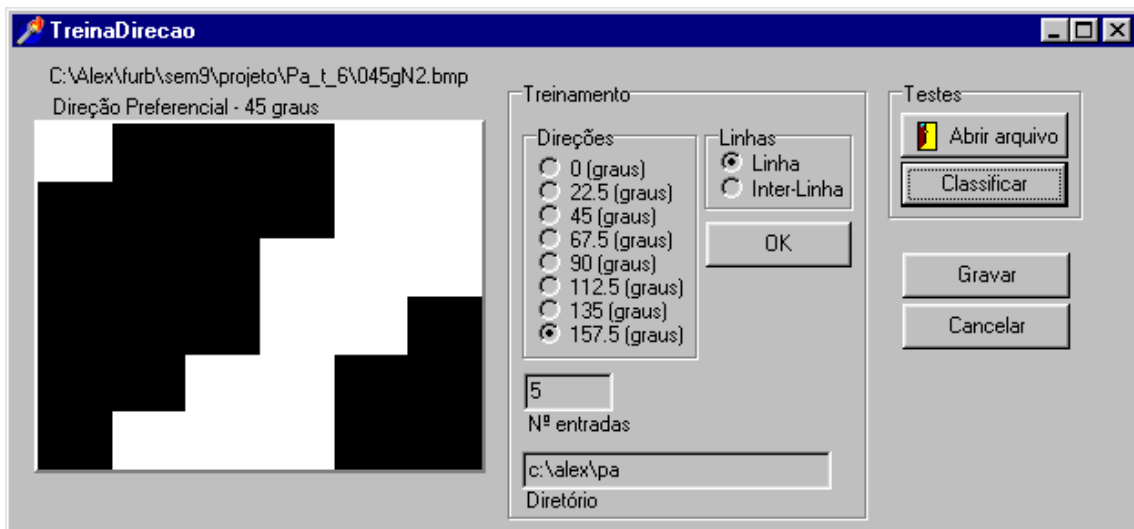


Figura 40 - Tela de treinamento das direções preferenciais

Estando satisfeita a fase de teste então o próximo passo será gravar a matriz de pesos. Para isso basta pressionar o botão “Gravar”. Esse botão somente estará ativo após o aprendizado da rede [Figura 41].



Figura 41 - Tela de treinamento das direções preferenciais

Estando concluída essa fase, poderá ser realizada a fase de treinamento das classes de impressões digitais [Figura 42].

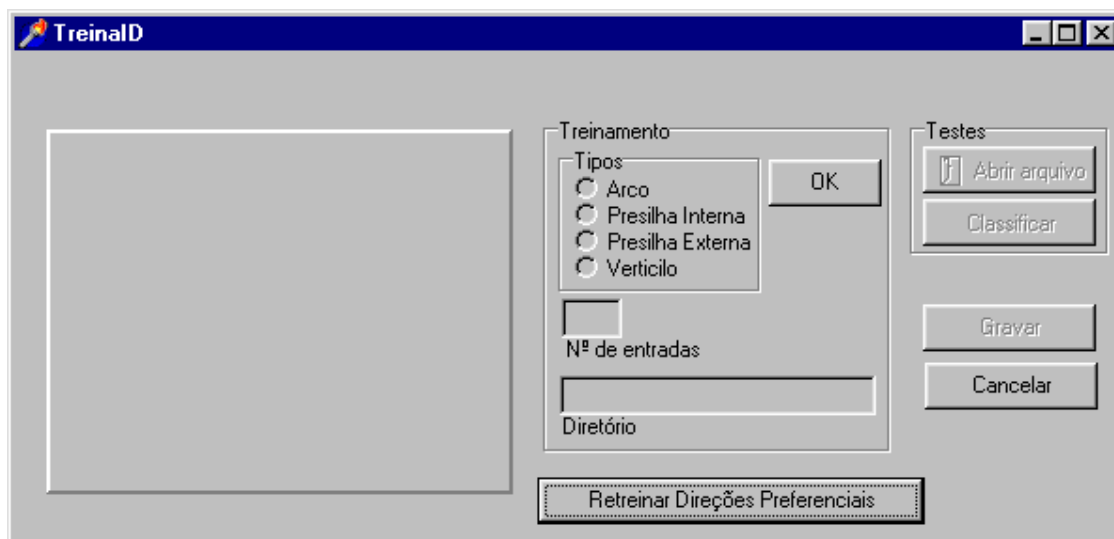


Figura 42 - Tela de treinamento das classes de impressões digitais

Nota-se agora que, pelo fato de existir a matriz de pesos das direções preferenciais, os botões para treinamento estão habilitados.

O próximo passo será configurar o número de entradas para cada classe e o diretório onde estão as imagens [Figura 43].

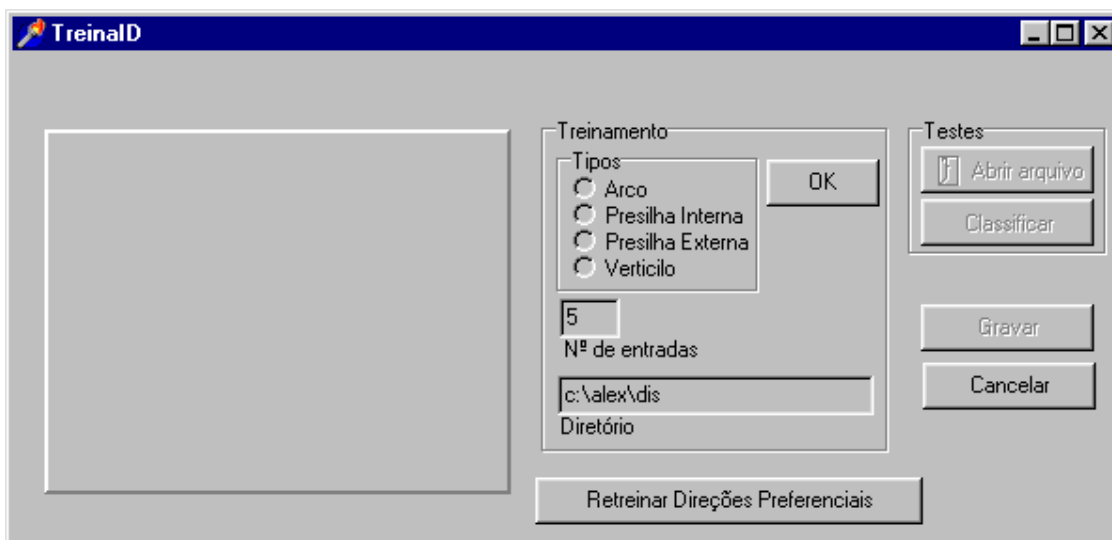


Figura 43 - Tela de treinamento das classes de impressões digitais

A seguir serão treinadas as classes de impressões digitais [Figura 44].



Figura 44 - Tela de treinamento das classes de impressões digitais

Esse treinamento ocorrerá até chegar o número máximo de padrões, que conforme representado na Figura 44 é 20. Após isso será informado se a rede conseguiu aprender ou não [Figura 45].



Figura 45 - Tela de treinamento das classes de impressões digitais

Estando com a fase de treinamento concluída, a próxima etapa será testar o aprendizado da rede com impressões digitais que não participaram da fase de treinamento [Figura 46].



Figura 46 - Tela de treinamento das classes de impressões digitais

Estando esse passo testado e aprovado, será então gravado a matriz de pesos. Para isso basta pressionar o botão “Gravar” [Figura 47].



Figura 47 - Tela de treinamento das classes de impressões digitais

Após esse passo conclui-se a fase de treinamento. Inicia-se então a utilização de fato, voltando-se a tela inicial [Figura 48].

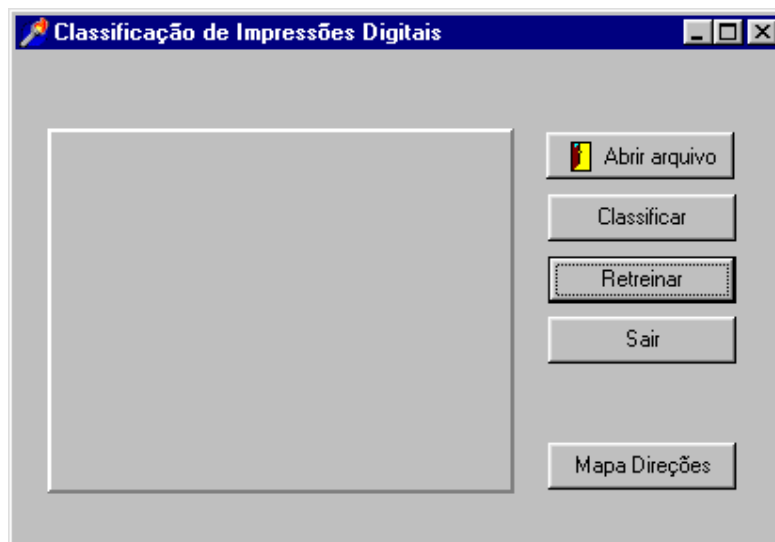


Figura 48 - Tela inicial

Nota-se agora que todos os botões estão exibidos. Pois agora existem as matrizes de pesos tanto das classes de impressões digitais como das classes das direções preferenciais.

Estando com as matrizes de pesos gravadas agora será possível utilizar o protótipo para classificação das impressões digitais [Figura 49].



Figura 49 - Tela inicial

Também será possível visualizar o mapa de direções resultante da impressão digital analisada. Ao pressionar o botão “Mapa Direções” será exibida a seguinte tela [Figura 50].




Figura 50 - Tela demonstrando o mapa de direções

4 ALGUMAS APLICAÇÕES

Pode-se empregar o reconhecimento de indivíduos por meios de tecnologia biométrica, como exemplo o reconhecimento de impressões digitais, para o controle de entrada e saída de edificações ou áreas fechadas, pagamento de salário, procura de pessoas, etc. Como exemplos podem ser considerados:

- a) Empresa: Uma empresa utilizaria um relógio ponto biométrico para controlar o horário de seus funcionários, ao contrário do ponto com cartão ou até mesmo com código de barras, o funcionário deve estar presente para que seja feita a coleta do horário de entrada e saída. Outra utilização dentro de uma empresa seria na hora do pagamento do salário, para se evitar que hajam fraudes como de um funcionário receber o seu salário e o de um colega.
- b) Escola: No caso da escola seria possível saber se algum aluno deixou de ir a aula, com o auxílio de uma porta automática ou uma catraca obrigaria o aluno a identificar-se na entrada e na saída da escola. Para uma escola mais exigente poderia-se colocar este controle em cada sala de aula.
- c) Condomínio: Da mesma forma que os anteriores controlar-se-ia a entrada de pessoas em um condomínio, substituindo a chave que pode ser copiada por algum funcionário demitido, um morador que vai embora e leva consigo uma cópia da chave ou até mesmo o chaveiro que fez a cópia da chave para um novo morador.
- d) Áreas restritas: Existem empresas que possuem áreas que nem todos os funcionários tem acesso, por exemplo o local onde estão certos equipamentos caros, materiais explosivos ou radioativos, componentes químicos ou remédios controlados. O que se faz atualmente, além de uma chave, é colocar uma porta com tranca acionada com cartão magnético, senha ou ambos, mas já conhecido que pode-se roubar o cartão e ver a senha.
- e) Bancos: Para o saque no caixa eletrônico seria desnecessária a presença do cartão magnético, o cliente do banco identificaria-se escolheria a conta, no caso de ter mais de uma, digitaria a quantidade e pronto. Porém por questões de

compatibilidade com outros caixas eletrônicos mais antigos, que são os novos de hoje, manteria-se no cadastro a senha.

- f) Previdência: No pagamento de aposentados, por exemplo, com a implantação de um sistema de reconhecimento de impressão digital as fraudes seriam menores, uma vez que poderia ser feita uma consulta no banco de dados interno a procura de uma pessoa que fosse cadastrada mais de uma vez. O mais importante é ainda o fato que os idosos não teriam que digitar sua senha, as vezes até esquecida, o que diminuiria em muito o tempo gasto para o pagamento de cada pessoa.
- g) Entre Países: No momento que uma pessoa consegue o visto para entrada em um país ela seria cadastrada num sistema internacional de pessoas que podem viajar, juntamente com o tempo de permanência permitido, e, ao chegar no aeroporto ou simplesmente em uma alfândega qualquer, a pessoa se identifica e é liberada ou não.
- h) Crime: Após implantado o sistema seria possível cadastrar pessoas procuradas, uma vez que esta pessoa tentasse trocar de país as autoridades encarregadas seriam avisadas imediatamente.
- i) Compras: Ao invés de utilizar o cartão de crédito que pode ser roubado, perdido ou copiado, o cliente se identificaria no computador da loja, entraria em contato com o banco e, uma vez comprovado o crédito do cliente, o valor da compra seria transferido da conta do cliente para a conta da loja no mesmo instante ou em forma de parcelas agendadas no sistema do próprio banco, quase eliminando a possibilidade de se atrasar o pagamento de uma conta.
- j) Eleições: Seria eliminada a necessidade de ter mais de duas pessoas por seção eleitoral, uma vez que a própria urna eletrônica identificaria o eleitor e liberaria a votação. Mais uma vez diminuindo possíveis fraudes.

Como pode-se ver as aplicações que podem empregar métodos de identificação biométrica são os mais diversos possíveis. Basta que esta tecnologia esteja em um bom estágio de confiabilidade e disponível em quantidade e custo compatíveis para que seja usada no dia a dia de todo o mundo.

5 CONCLUSÃO

Sistemas Biométricos de Identificação são os sistemas que utilizam características físicas únicas de cada indivíduo para identificá-lo. Atualmente um dos meios que poderá em um futuro próximo ser utilizado amplamente é o de reconhecimento através da impressão digital.

Em tempos de comércio eletrônico, a segurança não pode mais ser garantida pelos meios convencionais e nesse contexto os sistemas de reconhecimento de impressões digitais contribuem muito. Por ser utilizado peculiaridades do dedo humano, à autorização ou acesso não pode de forma alguma ser transferida à outra pessoa, como ocorre com senhas e cartões que podem ser facilmente emprestados ou roubados e ainda com a necessidade de uma renovação periódica, o que significa que seu sistema de segurança pode ser violado a qualquer momento. Para empresas que oferecem serviços, o custo da segurança depende do valor da informação.

Neste trabalho foi ilustrada a potencialidade de uso das tecnologias das redes neuronais para a obtenção do mapa de direções e de classificação de impressão digital. Quando do desenvolvimento do trabalho, conclui-se que a fase de análise do problema e a definição do pré-processamento e forma de representação em cada fase é muito importante, tendo em vista que as redes neurais apesar da vasta aplicação, possuem limites que dependem muito das representações utilizadas.

Com o decorrer do trabalho observou-se na prática algumas vantagens e algumas desvantagens do uso de redes neurais.

As vantagens observadas foram:

- a) Auto-aprendizado: não necessitam de conhecimentos de especialistas para tomar decisões; elas se baseiam unicamente nos exemplos históricos que lhes são fornecidos: não é necessário informar porque tal situação resultou em tal decisão no passado, ou porque tal decisão resultou em tal consequência (no caso do modelo *perceptron* por exemplo, os diversos padrões não treinados foram reconhecidos sem terem nunca sido apresentados a rede anteriormente). O sistema

substitui a análise do especialista humano para a classificação mesmo sem ser capaz de explicar o como se faz;

- b) Capacidade de generalização: mesmo com dados incompletos ou imprecisos as redes podem preencher as lacunas sem sofrer degradação; é algo parecido com a interpolação e extrapolação da estatística, porém operacionalmente muito diferente;
- c) Imunidade a ruídos: os dados reais sempre contêm ruído (variações aleatórias adicionadas aos valores originais); as redes conseguem separar o ruído da informação relevante, tendo sido utilizadas mesmo como filtros de dados. Vários testes foram efetuados inserindo ruídos tanto no mapa de direções quanto na imagem;
- d) Adaptabilidade: uma vez construída uma rede eficiente em dada aplicação, ela pode ser utilizada em aplicações de tempo-real, sem necessidade de ter sua arquitetura alterada a cada atualização; basta que seja retreinada com base nos novos dados históricos que forem surgindo.

Porém algumas desvantagens também foram detectadas. Tais como:

- a) Caixa-preta: é impossível saber porque a rede chegou a tal conclusão; seus critérios decisórios são encriptados, não se sabendo até o momento que pesos são relevantes à tomada de uma dada decisão; os milhares de pesos não aceitam interpretação e nem são passíveis de interpretação lógica: sabe-se apenas que funcionam;
- b) Preparação de dados: os dados de entrada necessitam de tratamento prévio: devem ser normalizados e devem ser cuidadosamente selecionados para que a rede seja corretamente ensinada a agir: dados de má qualidade produzem resultados falhos (como por exemplo omitir algum parâmetro importante no treinamento);
- c) Trabalho artesanal: não há regras gerais para se determinar o volume de dados de entrada para treinamento, quantas camadas devem ser utilizadas, a melhor estratégia de treinamento, que percentagem de dados deve ser destinada ao treinamento e ao teste da rede: esses parâmetros só podem ser estabelecidos

através de bom-senso, experiência com redes e de tentativa-e-erro. Várias tentativas de definição do número e formato de entrada tiveram que ser feitas antes de se chegar a configuração final utilizada.

Encontrou-se grande dificuldade em obter-se material bibliográfico relativo a técnicas eficientes de análise e reconhecimento de impressão digital. Mesmo os que foram encontrados abordam o tema de forma superficial. Sendo assim, foi necessário investir um razoável tempo em pesquisa para que se pudesse chegar a técnica para o tratamento das mesmas proposta neste trabalho.

Considera-se que o objetivo principal do trabalho, a construção de um protótipo de software para a classificação de impressões digitais baseado no uso da tecnologia das redes neurais, foi alcançado. No entanto por se tratar de um protótipo, ainda existe muitas possibilidades de melhorias. O pré-processamento da imagem, onde a centralização ainda é manual e a aquisição que é realizada através de meios convencionais, no papel, e não através de leitores óticos, são exemplos de melhorias que podem ser implementadas no futuro.

5.1 EXTENSÕES

Sugere-se alguns passos não contemplados no proposto trabalho, visando automatizar a aquisição, armazenagem e classificação de impressões digitais. Tais como:

- a) tratamento automático da imagem (centralização);
- b) localização automática do núcleo;
- c) localização automática das minúcias;
- d) utilização de um formato de armazenamento.

REFERÊNCIAS BIBLIOGRÁFICAS

- [DUN95] DUNTEMANN, Jeff. *Delphi: Programming Explorer*. Scottsdale: Coriolis Group Books, 1995.
- [FAC93] FACON, Jacques. **Processamento e Análise de Imagens**. Córdoba : CEFET, 1993.
- [FAU94] FAUSETT, Laurene. *Fundamentals of Neural Networks*. New Jersey : Prentice Hall, 1994.
- [HAR83] HARALICK, Robert M. **Pictorial Data Analysis**. Berlin : Springer, 1983.
- [JAN96] JANUÁRIO, Neide de Souza. **Curiosidades sobre Perícias** 1996. Endereço eletrônico: <http://web.horizontes.com.br/~januario/peric.html>.
- [KEH84] KEHDY, Carlos. **Elementos de Criminalística**. São Paulo : Coleção de Polícia de Criminologia, 1984.
- [LOE91] LOESCH, Cláudio. **Boletim Informativo do Departamento de Matemática**. Blumenau : FURB, 1991.
- [LOE94] LOESCH, Claudio. **Dynamis Revista Tecno-Científica**. v.2 n.9 p.15-27, Outubro/Dezembro de 1994.
- [LOE95] LOESCH, Claudio. **Boletim Informativo Redes Neurais**. v.1 n.2 p. 15-20, Maio de 1995.
- [LOE96] LOESCH, Claudio, SARI, Solange T.. **Redes Neurais Artificiais – Fundamentos e Modelos**. Blumenau : FURB, 1996.
- [MAR92] MAREN, Alianna J. *Handbook of Neural Computing Applications*. San Diego : Academic Press, 1992.
- [MAR96] MARTINO, Marcello Baptista. **Redes Neurais**. 1996. Endereço eletrônico : <http://www.cepel.br:80/~martino/rn.htm>.

- [MAT96] MATCHO, Jobathan. et. al. *Using Delphi 2 : Special Edition*. Hollis : QUE, 1996.
- [OSI97] OSIER, Dan. **Aprenda em 21 dias Delphi 2**. Rio de Janeiro: Campus, 1997.
- [OSO91] OSÓRIO, Fernando Santos. **Um Estudo sobre Reconhecimento Visual de Caracteres através de Redes Neurais**. Porto Alegre : UFRGS, 1991.
- [OSO92] OSÓRIO, Fernandes M., **Introdução ao Reconhecimento de Imagens**. Porto Alegre : UFRGS, 1992.
- [PAZ88] PAZ, Eduardo Peixoto. **Iniciação ao Processamento Digital de Imagens**. Rio de Janeiro : UFRJ/NCE, 1988.
- [ROB90] ROBERT, Hecht-Nielsen. *Neurocomputing*. Washington : Addison-Wesley Publishing Company, 1990.
- [RUB95] RUBENKING, Neil J. **Programação em Delphi para Leigos**. São Paulo : Berkeley Brasil, 1995.
- [TAF95] TAFNER, Maucon, XEREZ, Marcos de, RODRIGUES FILHO, Ilson W.. **Redes Neurais Artificiais**. Blumenau : FURB, 1995.
- [TAV91] TAVARES JÚNIOR, Gilberto da Silva. **A Papioscopia nos Locais de Crime**. São Paulo : Ícone , 1991.
- [TUR93] TURBAN, Efraim. *Decision Support and Expert Systems*. New York: Macmillan, 1993.
- [WAN93] WANG, Guyon. *Advances in Pattern Recognition Systems using Neural Network Technologies*. London : Word Scientific Publishing, 1993.
- [WIL95] WILHELM, Pedro Paulo Hugo; LOPES, Maurício Capobianco, et al. Sistema Inteligente de Apoio à Decisão. **Revista de Negócios**. Blumenau, v.1 n.1, Dezembro de 1995.