

ROMUALDO WANDRESEN

**INTEGRAÇÃO ENTRE REDES NEURAIS E CORRELAÇÃO PARA
IDENTIFICAR PONTOS DE APOIO PRÉ-SINALIZADOS**

Tese apresentada como requisito parcial para a obtenção do título de Doutor em Ciências Geodésicas no Programa de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná.

Orientadores: Prof. Dr. Edson A. Mitishita
Prof. Dr. José Bittencourt de Andrade.

CURITIBA

2004

À minha esposa Maria Otília.
Aos meus filhos Gustavo e Rafael Romualdo.
Dedico.

AGRADECIMENTOS

À Universidade Federal do Paraná e ao Setor de Ciências da Terra pela oportunidade de cursar o doutorado.

À Pontifícia Universidade Católica do Paraná pela concessão de licença com vencimentos.

À Aerosat Aerolevantamentos, pela cobertura aerofotogramétrica.

À Engefoto Aerolevantamentos, pelo apoio técnico recebido.

Ao Professor Flávio Bortolozzi, Pró-Reitor de Pesquisa e Pós-Graduação da Pontifícia Universidade Católica do Paraná, pelo apoio e incentivo recebidos durante todas as fases desse trabalho.

Ao Colegiado do programa de Pós Graduação em Planejamento Urbano (PPGTU) da Pontifícia Universidade Católica do Paraná, pela compreensão, na fase final do trabalho.

Ao Professor Orientador José Bittencourt de Andrade por sua orientação com firmeza, presteza e sabedoria, nas fases mais difíceis desse trabalho.

Ao Professor Orientador Edson Aparecido Mitishita por sua orientação e pela transferência dos conhecimentos na área de Fotogrametria.

À Verali Mônica Kleuser, secretária do Programa de Pós-Graduação em Ciências Geodésicas pelo sempre competente e prestativo atendimento em nossas solicitações.

Ao Engenheiro e Professor Cláudio Oliveira, pelo inestimável apoio recebido na parte computacional desse trabalho.

Ao Professor Raimundo José Borges Sampaio e à professora Maria Terezinha Arns Steiner pela orientação inicial no estudo de Redes Neurais Artificiais.

Ao Professor Amauri Araújo Lima, pela revisão.

Aos acadêmicos do Curso de Engenharia Cartográfica da Universidade Federal do Paraná, Rodrigo Augusto Quirino, Ligia Bettini Novasi e Fabiani das Dores Abati Miranda, pelo auxílio aos trabalhos de campo.

A Gustavo Wandresen, Rafael Romualdo Wandresen e Rogério Cipriano pelo auxílio na pré-sinalização dos pontos.

BIOGRAFIA

Romualdo Wandresen, filho de Nair Nienkoetter Wandresen e Valentin Wandresen, nasceu em 25 de abril de 1949, no município de Tubarão, SC.

Concluiu o 1º grau no Ginásio La Salle, em Francisco Beltrão, PR e o 2º grau no Colégio Estadual Nilson Baptista Ribas, em Curitiba, PR.

Em 1970, ingressou no curso de Licenciatura em Matemática da Universidade Federal do Paraná, concluindo-o em dezembro de 1973.

De 1974 a 1977 foi professor de Matemática, Desenho Geométrico, Geometria Descritiva e Física em diversos estabelecimentos de ensino na cidade de Curitiba, PR.

De 1976 a 1977 foi professor colaborador do Departamento de Matemática da Universidade Federal do Paraná.

De 1977 a 1980 foi professor auxiliar de ensino na escola de Oficiais Especialistas da Aeronáutica, em Curitiba, PR.

De 1976 a 1996 foi professor no Centro Federal de Educação Tecnológica do Paraná, onde atuou nos Departamentos Acadêmicos de Matemática e de Informática.

Em 1978 ingressou como professor auxiliar de ensino na Pontifícia Universidade Católica do Paraná, onde, desde 1988 é professor titular atuando em diversos cursos do Centro de Ciências Exatas e de Tecnologia (CCET). Foi diretor do curso de Licenciatura em Matemática, no período de 1997 a 2000 e Decano Adjunto do CCET em 1999.

Em 1980 obteve o título de Mestre em Ciências Geodésicas pela Universidade Federal do Paraná.

Em 1980 ingressou como professor assistente no Departamento de Geomática da Universidade Federal do Paraná, onde atualmente é professor titular.

Em 1992 coordenou o convênio firmado entre a Universidade Federal do Paraná e a República Federal da Alemanha, dentro do Projeto de Cooperação Técnica Internacional, objetivando auxílio ao Programa de Pós Graduação em Ciências Geodésicas.

Em 2001 iniciou o Doutorado em Ciências Geodésicas na Universidade Federal do Paraná.

Em 2003 iniciou suas atividades como professor colaborador no Programa de Pós-Graduação em Gestão Urbana – PPGTU da Pontifícia Universidade Católica do Paraná.

SUMÁRIO

LISTA DE FIGURAS	XII
LISTA DE QUADROS	XV
RESUMO	XVI
ABSTRACT	XVII
1 INTRODUÇÃO	1
1.1 CONSIDERAÇÕES GERAIS	1
1.2 OBJETIVOS	3
1.3 JUSTIFICATIVA	3
1.4 CONTEÚDO	4
2 FUNDAMENTAÇÃO TEÓRICA	5
2.1 IMAGEM DIGITAL	5
2.2 FORMAÇÃO DA IMAGEM DIGITAL	5
2.3 MODELO DE REPRESENTAÇÃO DE CORES	8
2.3.1 Fundamentos de Cores	8
2.3.2 Modelos de Cores	11
2.4 CORRELAÇÃO ESTATÍSTICA	15
2.5 CONCEITOS BÁSICOS SOBRE REDES NEURAIS	19
2.5.1 Modelo Natural	19
2.5.2 Rede Neural Artificial	20
2.5.3 Modelo de um Neurônio	21
2.5.4 O Perceptron	23
2.6 REDES <i>FEEDFORWARD</i> E RETROPROPAGAÇÃO	25
2.6.1 Algoritmo de Retropropagação	26
2.6.2 Taxa de Aprendizagem e Momento	35
2.6.3 Modo Padrão e modo Lote (<i>Batch</i>) de Treinamento	35
2.6.4 Algoritmo <i>Resilient Propagation (RPROP)</i>	36
2.7 MORFOLOGIA MATEMÁTICA	40
2.7.1 Elemento Estruturante	40
2.7.2 Definições Básicas	41
2.7.3 Dilatação	42
2.7.4 Erosão Binária	43
2.8 REFERENCIAIS FOTOGRAMÉTRICOS	45
2.8.1 Sistema Fiducial	45
2.8.2 Sistema Fotogramétrico	46
2.9 FOTOTRIANGULAÇÃO	48

2.9.1	Conceitos	48
2.9.2	Planejamento e Sistemas de Coordenadas	49
2.9.3	Coleta de Dados.....	49
2.9.4	Ferramentas para a Identificação Automática de Pontos	50
2.9.5	Automatização na Leitura das Marcas Fiduciais	51
2.9.6	Identificação e Medição Automática de Pontos de Apoio Naturais.....	52
2.9.7	Identificação e Medição Automática dos Pontos Fotogramétricos	52
2.9.8	Modelo Matemático da Aerotriangulação Analítica.....	53
2.9.9	Erros Sistemáticos da Imagem Fotogramétrica.....	54
2.9.10	Orientação Exterior.....	61
2.9.11	Ajustamento Paramétrico com Injunção	63
2.9.12	Teste de Hipótese Qui-Quadrado.....	66
3	MATERIAIS	68
3.1	PONTOS PRÉ-SINALIZADOS EM PAREDES VERTICAIS	68
3.1.1	Pontos pré-sinalizados dos tipos “cruz” e “círculo”, em uma parede.....	68
3.2	ÁREA DE ESTUDOS	68
3.2.1	Trabalhos de Campo	68
3.2.2	Planejamento do Vôo e Fotos Aéreas	70
3.2.3	Localização dos Pontos Pré-sinalizados	71
3.2.4	Coordenadas Geodésicas dos Pontos Pré-sinalizados.....	72
4	METODOLOGIA.....	83
4.1	PREPARAÇÃO DAS IMAGENS.....	83
4.1.1	Imagens de Treinamento.....	84
4.1.2	Imagens para o Reconhecimento por Redes Neurais	89
4.1.3	Imagens para o Reconhecimento por Correlação	94
4.2	TREINAMENTO NA REDE NEURAL ARTIFICIAL (RNA)	94
4.2.1	Treinamento da Rede Neural no Nível 0	95
4.2.2	Treinamento da Rede Neural no Nível 1	96
4.2.3	Treinamento da Rede Neural no Nível 2	96
4.3	SIMULAÇÃO DA RNA POR MEIO DO TREINAMENTO EXECUTADO	97
4.4	RECONHECIMENTO POR CORRELAÇÃO	100
4.4.1	Reconhecimento e Identificação dos Pontos Pré-sinalizados Homólogos ..	100
4.4.2	Reconhecimento e Identificação das Marcas Fiduciais	101
4.4.3	Valores Aproximados para as Marcas Fiduciais no Referencial de Imagem.....	
	101

4.4.4	Identificação das Marcas Fiduciais.....	102
5	EXPERIMENTOS	104
5.1	PONTOS PRÉ-SINALIZADOS EM PAREDES VERTICAIS	104
5.1.1	Treinamento do Alvo na Forma de Cruz.....	104
5.1.2	Treinamento do Alvo na Forma de Círculo.....	105
5.1.3	Identificação dos alvos	107
5.2	PONTOS PRÉ-SINALIZADOS USANDO RNA	108
5.2.1	Ponto Pré-sinalizado em Forma Circular.....	108
5.2.2	Pontos Pré-sinalizados do Tipo Cruz	110
5.3	PONTOS PRÉ-SINALIZADOS USANDO CORRELAÇÃO E RNA.....	113
5.3.1	Ponto Pré-sinalizado em Forma Circular.....	113
5.3.2	Pontos Pré-sinalizados em Forma de Cruz	115
5.4	PONTOS NATURAIS USANDO CORRELAÇÃO	118
5.5	MARCAS FIDUCIAIS USANDO CORRELAÇÃO	118
5.5.1	Marcas Fiduciais da Foto 1	118
5.6	ANÁLISE NA IDENTIFICAÇÃO DOS PONTOS.....	119
5.6.1	Pontos em Forma de Círculo.....	119
5.6.2	Ponto em Forma de Cruz	121
5.6.3	Marcas Fiduciais.....	122
5.7	ORIENTAÇÃO EXTERIOR	123
5.7.1	Formação do Modelo Matemático Fotogramétrico	123
5.7.2	Análise Estatística	128
5.7.3	Diferenças entre Coordenadas de Campo Observadas e Ajustadas	128
6	CONSIDERAÇÕES FINAIS	130
7	RECOMENDAÇÕES	133
	REFERÊNCIAS.....	134
	ANEXO 1 – ARQUIVO DE DESCRIÇÃO PARA IDENTIFICAR OS PONTOS NATURAIS	138
	ANEXO 2 - ARQUIVO DE SAÍDA DOS PONTOS NATURAIS, USANDO CORRELAÇÃO.	139
	ANEXO 3 – CARACTERÍSTICAS DA CÂMARA	140
	ANEXO 4 – CARACTERÍSTICAS DAS AEROFOTOS UTILIZADAS	141

LISTA DE TABELAS

TABELA 3.1- PONTOS PRÉ-SINALIZADOS	71
TABELA 3.2 - COORDENADAS GEODÉSICAS DOS PONTOS PRÉ-SINALIZADOS	72
TABELA 4.1 - REFERENCIAL FIDUCIAL	101
TABELA 4.2 – COORDENADAS DE IMAGEM APROXIMADAS DOS CENTROS ... DAS MARCAS FIDUCIAIS.....	102
TABELA 5.1 – TREINAMENTO COM ALVO CRUZ.....	105
TABELA 5.2 – TREINAMENTO COM ALVO CIRCULAR	106
TABELA 5.3 - IDENTIFICAÇÃO DO ALVO CRUZ NA IMAGEM DE TREINAMENTO	107
TABELA 5.4 – IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES NA FOTO 1	108
TABELA 5.5 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES . NA FOTO 2	108
TABELA 5.6 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES . NA FOTO 3	109
TABELA 5.7 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES . NA FOTO 4	110
TABELA 5.8 -IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 1	110
TABELA 5.9 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 2	111
TABELA 5.10 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 3	112
TABELA 5.11 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 4	113
TABELA 5.12 – IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 1-2 POR CORRELAÇÃO	114
TABELA 5.13 – IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 2-3 POR CORRELAÇÃO	114

TABELA 5.14 - IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 3-4 POR CORRELAÇÃO	115
TABELA 5.15 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 1-2 .. POR CORRELAÇÃO	116
TABELA 5.16 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 2-3 .. POR CORRELAÇÃO	116
TABELA 5.17 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 3-4 .. POR CORRELAÇÃO	117
TABELA 5.18 – RESUMO DO DESEMPENHO DO RECONHECIMENTO DOS PONTOS PRÉ-SINALIZADOS DO TIPO CÍRCULO POR RNA.....	117
TABELA 5.19 - RESUMO DO DESEMPENHO DO RECONHECIMENTO DOS PONTOS PRÉ-SINALIZADOS DO TIPO CRUZ POR RNA.....	118
TABELA 5.20 – MARCAS FIDUCIAIS DA FOTO 1.....	119
TABELA 5.21 - MARCAS FIDUCIAIS DA FOTO 2.....	119
TABELA 5.22 - MARCAS FIDUCIAIS DA FOTO 3.....	119
TABELA 5.23 - MARCAS FIDUCIAIS DA FOTO 4.....	119
TABELA 5.24 – PAR DE FOTOS 1-2.....	120
TABELA 5.25 – PAR DE FOTOS 2-3.....	120
TABELA 5.26 – PAR DE FOTOS 3-4.....	121
TABELA 5.27 – PAR DE FOTOS 1-2.....	121
TABELA 5.28 – PAR DE FOTOS 2-3.....	122
TABELA 5.29 – PAR DE FOTOS 3-4.....	122
TABELA 5.30 – DIFERENÇAS OBSERVADAS NA FOTO 1.....	122
TABELA 5.31 - DIFERENÇAS OBSERVADAS NA FOTO 2.....	123
TABELA 5.32 - DIFERENÇAS OBSERVADAS NA FOTO 3.....	123
TABELA 5.33 - DIFERENÇAS OBSERVADAS NA FOTO 4.....	123
TABELA 5.34 – COORDENADAS EM “PIXELS” POS PONTOS DO MODELO	124
TABELA 5.35 - COORDENADAS FOTOGRAMÉTRICAS DO PAR CORRIGIDAS DOS ERROS SISTEMÁTICOS	125
TABELA 5.36 – FOTOCOORDENADAS OBSERVADAS E AJUSTADAS NA FOTO 7213.....	126
TABELA 5.37 – FOTOCOORDENADAS OBSERVADAS E AJUSTADAS NA FOTO 7212.....	126

TABELA 5.38 – COMPARAÇÃO ENTRE AS COORDENADAS UTM	
APROXIMADAS E COORDENADAS UTM AJUSTADAS.....	127
TABELA 5.39 – DIFERENÇAS ENTRE COORDENADAS DE CAMPO E	
COORDENADAS AJUSTADAS	127

LISTA DE FIGURAS

FIGURA 2.1 – CONVERSÃO ANALÓGICO - DIGITAL.....	6
FIGURA 2.2 - “PIXELS” DE IMAGENS DIGITAIS.....	7
FIGURA 2.3 – O TRIÂNGULO DAS CORES.....	9
FIGURA 2.4 – CORES PRIMÁRIAS E SECUNDÁRIAS DA LUZ E DE PIGMENTOS	10
FIGURA 2.5 – CUBO DE CORES RGB.....	12
FIGURA 2.6 – TRIÂNGULO DE CORES HSI.....	13
FIGURA 2.7 – SÓLIDO DE CORES HSI.....	14
FIGURA 2.8 - MATRIZES DE AMOSTRA E DE BUSCA.....	16
FIGURA 2.9 – NEURÔNIO BIOLÓGICO.....	19
FIGURA 2.10 - MODELO DE UM NEURÔNIO ARTIFICIAL.....	21
FIGURA 2.11 - GRÁFICO DA FUNÇÃO LOGÍSTICA SIGMÓIDE.....	23
FIGURA 2.12 - O PERCEPTRON.....	24
FIGURA 2.13 – FUNÇÃO DE TRANSFERÊNCIA DO PERCEPTRON.....	24
FIGURA 2.14 – FRONTEIRA DE DECISÃO.....	25
FIGURA 2.15 – PERCEPTRON DE MÚLTIPLAS CAMADAS.....	26
FIGURA 2.16 – DETALHES DO NEURÔNIO SIMPLES DE SAÍDA J.....	27
FIGURA 2.17- NEURÔNIO OCULTO J CONECTADO AO NEURÔNIO K.....	30
FIGURA 2.18 – FLUXOGRAMA DO MÉTODO DE RETROPROPAGAÇÃO.....	32
FIGURA 2.19 - EXEMPLO DE DILATAÇÃO.....	43
FIGURA 2.20 - TRANSLAÇÕES DA EROÇÃO BINÁRIA.....	44
FIGURA 2.21 - EXEMPLO DE EROÇÃO BINÁRIA.....	45
FIGURA 2.22 – SISTEMA DE COORDENADAS FIDUCIAIS.....	46
FIGURA 2.23 – SISTEMA FOTOGRAMÉTRICO.....	47
FIGURA 2.24 – PONTO PRÉ-SINALIZADO CIRCULAR.....	50
FIGURA 2.25 – PONTO PRÉ-SINALIZADO EM CRUZ.....	50
FIGURA 2.26 – PIRÂMIDE DE IMAGENS.....	51
FIGURA 2.27- MATRIZES DE AMOSTRA DOS PONTOS FOTOGRAMÉTRICOS..	52
FIGURA 2.28 – DISPOSIÇÃO DO REFERENCIAL FOTOGRAMÉTRICO NUMA AEROFOTO.....	56
FIGURA 2.29 - COMPONENTES DA DISTORÇÃO RADIAL SIMÉTRICA.....	59

FIGURA 2.30 – EFEITO DA REFRAÇÃO FOTOGRAMÉTRICA NA IMAGEM FOTOGRAFICA	61
FIGURA 2.31 – ORIENTAÇÃO EXTERIOR DE UMA AEROFOTO NO ESPAÇO	62
FIGURA 3.1 - FOTO DIGITAL DA PRÉ-SINALIZAÇÃO NA PAREDE	68
FIGURA 3.2 - PONTO PRÉ-SINALIZADO EM FORMA DE "CRUZ"	69
FIGURA 3.3 - PONTO PRÉ-SINALIZADO EM FORMA DE CÍRCULO	69
FIGURA 3.4 - PARTE DE UMA DAS AEROFOTOS	70
FIGURA 3.5 - PONTOS PRÉ-SINALIZADOS "CRUZ" E "CÍRCULO"	71
FIGURA 3.6 – PONTOS PRÉ-SINALIZADOS 1 E 3	73
FIGURA 3.7 - PONTOS PRÉ-SINALIZADOS 2 E 4	74
FIGURA 3.8 – PONTOS PRÉ-SINALIZADOS 5 E 6	74
FIGURA 3.9 - PONTO PRÉ-SINALIZADO 7	75
FIGURA 3.10 - PONTO PRÉ-SINALIZADO 8	75
FIGURA 3.11 - PONTOS PRÉ-SINALIZADOS 9 E 10	76
FIGURA 3.12 - PONTOS PRÉ-SINALIZADOS 11 E 12	76
FIGURA 3.13 - PONTO PRÉ-SINALIZADO 13	77
FIGURA 3.14 - PONTO PRÉ-SINALIZADO 14	77
FIGURA 3.15 - PONTOS PRÉ-SINALIZADOS 15,16 E 17	78
FIGURA 3.16 - PONTOS PRÉ-SINALIZADOS 18,19 E 20	78
FIGURA 3.17 - PONTOS PRÉ-SINALIZADOS 21, 22 E 23	79
FIGURA 3.18 - PONTOS PRÉ-SINALIZADOS 24,25 E 26	79
FIGURA 3.19 - PONTO PRÉ-SINALIZADO 27	80
FIGURA 3.20 - PONTO PRÉ-SINALIZADO 28	80
FIGURA 3.21 - PONTO PRÉ-SINALIZADO 29	81
FIGURA 3.22 - PONTO PRÉ-SINALIZADO 30	81
FIGURA 3.23 - PONTOS PRÉ-SINALIZADOS 31 E 32	82
FIGURA 4.1 - PREPARAÇÃO DAS IMAGENS	83
FIGURA 4.2 - JANELA DE UM PONTO PRÉ-SINALIZADO	85
FIGURA 4.3 - CONJUNTO DE TREINAMENTO EM TONS DE CINZA NO NIVEL 0 .. PARA OS ALVOS CIRCULARES	86
FIGURA 4.4 – CONJUNTO DE TREINAMENTO PARA O ALVO CIRCULAR NO NIVEL 0 EM PRETO E BRANCO – IMAGEM BINÁRIA.....	87

FIGURA 4.5 - IMAGEM DE TREINAMENTO NÍVEL 0 EM TONS DE CINZA PARA ... O PONTO PRÉ-SINALIZADO DO TIPO EM CRUZ.....	87
FIGURA 4.6 - IMAGEM DE TREINAMENTO NÍVEL ZERO, PRETA E BRANCA PARA O PONTO PRÉ-SINALIZADO DO TIPO EM CRUZ.....	88
FIGURA 4.7 – IMAGEM NÍVEL 0, ORIGEM PARA O NÍVEL 1 CIRCULAR	88
FIGURA 4.8 – IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 1 DO ALVO CIRCULAR.....	88
FIGURA 4.9 – IMAGEM CONJUNTO DE TREINAMENTO DO NÍVEL 2 DO ALVO ... CIRCULAR.....	89
FIGURA 4.10 - IMAGEM NÍVEL 0, ORIGEM PARA O NÍVEL 1 EM CRUZ	89
FIGURA 4.11 - IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 1 DO ALVO .. EM CRUZ.....	89
FIGURA 4.12 - IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 2 DO ALVO .. EM CRUZ.....	89
FIGURA 4.13 - PARTE DE AEROFOTO COLORIDA.....	90
FIGURA 4.14 - PARTE DE AEROFOTO EM TONS DE CINZA.....	90
FIGURA 4.15 – PARTE DE AEROFOTO EM PRETO E BRANCO.....	91
FIGURA 4.16 – PARTE DE AEROFOTO EM TONS DE CINZA NO NÍVEL 1	91
FIGURA 4.17 – PARTE DE AEROFOTO EM TONS DE CINZA NO NÍVEL 2	92
FIGURA 4.18 – PARTE DE AEROFOTO NO NÍVEL 2 EM PRETO E BRANCO	93
FIGURA 4.19 – PARTE DE AEROFOTO ERODIDA NO NÍVEL 2.....	94
FIGURA 4.20 – FLUXOGRAMA DO PROCESSO DE RECONHECIMENTO POR REDES NEURAIS – SUBPROGRAMA SIMULA	99
FIGURA 4.21 - POSIÇÃO DAS MARCAS FIDUCIAIS.....	101
FIGURA 4.22 - RELAÇÃO ENTRE SISTEMA DE IMAGEM E SISTEMA FIDUCIAL	102
FIGURA 4.23 - AMOSTRA DE MARCA FIDUCIAL.....	103
FIGURA 5.1 - CONJUNTO DE TREINAMENTO PARA O ALVO EM CRUZ.....	105
FIGURA 5.2 – CONJUNTO DE TREINAMENTO PARA O ALVO CIRCULAR.....	106
FIGURA 5.3 – DESEMPENHO DO TREINAMENTO COM ALVOS CIRCULARES	106

LISTA DE QUADROS

QUADRO 4.1 - ARQUIVO DE DESCRIÇÃO DO TREINAMENTO	95
QUADRO 4.2 - DESCRIÇÃO DO SUB-PROGRAMA SIMULA	97
QUADRO 4.3 – ARQUIVO DE DESCRIÇÃO DO SUB-PROGRAMA ALINHA	100
QUADRO 4.4 – ARQUIVO DE DESCRIÇÃO PARA IDENTIFICAR MARCAS	
FIDUCIAIS	103
QUADRO 5.1 – ARQUIVO DE SAÍDA DA CORRELAÇÃO PARA OS PONTOS	
NATURAIS	118

RESUMO

Este trabalho apresenta, como objetivo principal, novas opções para a identificação automatizada de pontos pré-sinalizados para as aplicações relativas à fotogrametria, tal como fototriangulação. O grau de dificuldade para o tratamento computacional de uma foto aérea digitalizada foi contornado com o uso de morfologia matemática, aplicando erosão binária a uma das fotos que compõem o par aerofotogramétrico. Para a realização do trabalho, inicialmente foi estudada a identificação de pontos pré-sinalizados em paredes externas do Centro Politécnico da Universidade Federal do Paraná. À medida que se obteve razoável experiência com esse tipo de observações usando Redes Neurais Artificiais com o aplicativo MATLAB, passou-se à elaboração de experimentos na área de testes que compreendem uma faixa de cinco aerofotos obtidas na região do Centro Politécnico e localidades vizinhas. Nesta região, foram pré-sinalizados, antes do voo aerofotogramétrico, sempre sobre asfalto, pontos de apoio em formas circular e de cruz. A identificação automática desses pontos de apoio foi possível com o uso dos conceitos de correlação estatística, redes neurais artificiais e morfologia matemática. Na morfologia matemática, foi enfatizada a erosão binária. Isto permitiu, com o uso da linguagem de programação VISUAL C++, codificar procedimentos para identificar pontos de apoio pré-sinalizados na imagem esquerda do par de fotos. Os programas-fonte foram elaborados com base no procedimento em redes neurais artificiais conhecido na literatura como *Backpropagation* (Retro-propagação). Além disso, usou-se a nova idéia denominada *RPROP* (*Resilient Propagation*) e morfologia matemática. Com o conhecimento das posições desses pontos e do recobrimento lateral das fotos, foi possível obter-se o posicionamento dos pontos homólogos na segunda foto do par, usando-se, além de redes neurais artificiais, também correlação estatística. O conceito de correlação foi usado também para identificar o posicionamento das marcas fiduciais nas fotos. Também com o uso de correlação estatística, foi obtido o posicionamento de pontos homólogos naturais, escolhidos em uma das fotos. Com a finalidade de verificar a consistência dos dados identificados, realizou-se a orientação interior e a formação do modelo matemático fotogramétrico, isto é, a orientação exterior de um dos pares de aerofotos da área de testes.

Palavras-chave: redes neurais artificiais, correlação estatística, pontos pré-sinalizados, identificação automática, morfologia matemática.

ABSTRACT

This work aims to present new options for automated identification of photographic images of ground targets for aerophotogrametry applications such as aerotriangulation. The level of difficulty for computing treatment of a digitalized air picture was overcome using mathematical morphology, applied as binary erosion over one of the pictures of the stereoscopic model. Initially, the identification of target points placed on the external walls of the VI building of the Polytechnic Center of the Federal University of Parana (UFPR) was tried to gain experience. using Artificial Neural Networks through the software Matlab running several experiments. Five aerial photographs were taken over the Polytechnic Center and its neighborhood where targets with circular and cross shape were painted on the asphalt before the flight. The automatic identification of these targeted control points become possible by the use of the concepts of statistical correlation, artificial neural networks and mathematic morphology with emphasis on binary erosion. The identification of the targeted control points image was done on one of the pictures (say the left one) forming one stereoscopic model by a computer program written Visual C++ language using the concepts of artificial neural networks with emphasis on the procedure known in the literature as "Backpropagation", plus the new concept known as "RPROP" (Resilien Propagation) and the mathematical morphology. As overlaps of the pictures were known, it was possible to get an approximated position of the image of the same point on the neighbors pictures. The concept of correlation was also used to identify the position of fiducial marks on the photos. The position of non-targeted control points was also obtained with the use of statistical correlation.

Key words: artificial neural networks, statistical correlation, target, automatic identification, mathematic morphology.

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES GERAIS

A Fotogrametria tem o seu campo de aplicação dominante na elaboração de mapas, interagindo com outras ciências, como a Geodésia e a Cartografia. Neste sentido, ela revolucionou os métodos de confecção de mapas, tornando-os mais precisos e com custos cada vez menores.

São marcantes, entre outras, a invenção da fotografia em 1837, por Louis-Jacques Daguerre, da marca estereoscópica, por Carl Pulfrich, em 1901, permitindo a criação do primeiro estereocomparador pela Zeiss, do avião por Alberto Santos Dumont, do Estereomat, pela Wild na década de 1960, do restituidor analítico em 1957 por U. Helava, de acordo com ANDRADE (1998, p. 4).

Depois do pioneirismo de Loussedat, na década de 1930, ao utilizar imagens fotográficas em seus levantamentos cartográficos, Otto von Grüber inaugurou o início dos desenvolvimentos teóricos em Fotogrametria, com inúmeros importantes prosseguidores até os nossos dias, colocando esta ciência como aquela que se mantém no mais alto grau evolutivo, absorvendo imediatamente todos os avanços tecnológicos que podem colaborar para o seu desenvolvimento.

Com a colocação de imageadores a bordo de satélites artificiais e de espaçonaves, veio a necessidade de transmitir os dados colhidos com total segurança para estações terrestres de rastreamento. Resultou daí a imagem digital. Nascida dessa necessidade, a imagem digital mostrou-se rapidamente ser de elevadíssimo potencial tecnológico quando comparada com a imagem analógica. A imagem digital pode ser processada em computador. Imediatamente, inúmeras experiências começaram a demonstrar na prática o poder das imagens digitais. A matemática associada às imagens digitais começou a produzir produtos incríveis e de forma econômica.

O desejo de automatizar processos encontrou campo fértil com as imagens digitais. Na Fotogrametria, toda a sua base teórica passou a ser aplicada às imagens digitais e as possibilidades cresceram, criando-se produtos novos, como é o caso das ortofotos digitais, e automatizando tarefas difíceis, como a coleta de dados para

a aerotriangulação, a geração automática de DTM *Digital Terrain Model* e DEM *Digital Elevation Model*.

Os processos de automação ganharam campo nos trabalhos de fotointerpretação, na identificação automática de pontos ou feições, na estereocompilação, na coleta de dados para a aerotriangulação, na geração automática de DEM, DTM. Tais processos são conseguidos pela identificação de pontos homólogos por correlação estatística de duas matrizes de *pixels*, pela determinação do par de matrizes que minimizam a soma dos quadrados de suas diferenças, ou por amostragem, num processo de aprendizado desenvolvido pela técnica das Redes Neurais Artificiais (RNA).

O uso integrado dessas técnicas oferece um potencial enorme.

A automatização é viável quando permite ganho de tempo, de trabalho, sem perda de qualidade. Os processos automáticos já bem desenvolvidos em Fotogrametria como, por exemplo, a coleta de dados de DEM, exigem a participação do homem, quer na determinação dos melhores parâmetros para trabalhar numa determinada região ou tipo de imagem, quer para verificar a qualidade dos resultados e, não menos importante, para editar os resultados para expurgar erros e completar os dados de modo a garantir elevada qualidade.

Esse mesmo princípio vale nesta tarefa de identificar, transferir e determinar as coordenadas fotogramétricas de pontos de apoio terrestre nas fototriangulações, e, em especial, nas aerotriangulações.

Os trabalhos de AGOURIS e SCHENK na década de 1990, na Ohio State University, mostraram ser a automação da aerotriangulação totalmente viável. Veja (AGOURIS; SCHENK, 1996, p. 703-710), por exemplo. Eles montaram um mosaico com imagens do vértice de pirâmide no exemplo, com procedimentos automáticos e adotaram o método dos mínimos quadrados para transferir pontos de apoio ou fotogramétricos.

Foi apresentado um sistema para reconhecimento automático de pontos sinalizados em fotografias aéreas digitais por KEPUSKA e MASON (1995, p.917-925), na Revista *Photogrammetric Engineering & Remote Sensing*, em julho de 1995. Nesse artigo, foi demonstrada a viabilidade do uso de pontos de apoio pré-sinalizados, em uma pesquisa desenvolvida no Instituto de Geodésia e Fotogrametria de Zurique, Suíça.

TOTH e AMON (1996), mostraram ser totalmente viável a implantação de um sistema automatizado para aerotriangulação.

MARINOV (2000, p.371-378) mostrou, em um trabalho de orientação relativa e absoluta de um modelo aerofotogramétrico, a localização de um ponto com resolução de *sub-pixel*. Para esse propósito, ele usou a transformação projetiva como modelo matemático de transformação geométrica e a transformação bilinear como transformação radiométrica para o modelo de obtenção dos níveis de cinza. O procedimento inicia-se aplicando a correlação estatística para obter a posição da janela que contém o alvo, e depois, nessa janela, aplicar o método dos mínimos quadrados.

SIDNEY et al. (1999, p. 220-225) mostraram em um trabalho de visualização de alvos 3D o uso de RNA de aprendizado não supervisionado, utilizando Redes Fuzzi-Artmap.

ADHEMAR et al. (2004) apresentam uma revisão bibliográfica sobre rede neural artificial do tipo ART2 aplicada na classificação de caracteres e algumas considerações sobre variações de ART, como ARTMAP, por exemplo.

1.2 OBJETIVOS

O objetivo geral é a integração entre RNA e correlação estatística.

Os objetivos específicos deste trabalho são demonstrar:

- o uso de Correlação Estatística para a identificação e leitura de coordenadas das marcas fiduciais;
- o uso de Redes Neurais Artificiais para a identificação de imagens de alvos de pré-sinalização para pontos de apoio;
- o uso do método de correlação estatística para o transporte de imagens de pontos de apoio pré-sinalizados e não pré-sinalizados.

1.3 JUSTIFICATIVA

O interesse em problemas de identificação de padrões tem tido considerável crescimento nas duas últimas décadas, com conseqüente aumento da necessidade de métodos para uso na elaboração de sistemas nesta área. Com o objetivo do reconhecimento e identificação automática de padrões homólogos em imagens

fotográficas digitais, apresentam-se metodologias com o uso do conceito de correlação estatística e redes neurais artificiais, para o reconhecimento e a identificação de pontos de apoio na aerofotogrametria.

O desenvolvimento da Inteligência Artificial nas últimas décadas permitiu a automatização em diversas áreas do conhecimento. Isto ocorre também na área de Ciências Geodésicas. Em particular, a Fotogrametria passou a usar imagens digitais em seus procedimentos. Este trabalho prioriza o reconhecimento automatizado de pontos de apoio pré-sinalizados, colaborando desta forma com o desenvolvimento da automatização em Fotogrametria.

1.4 CONTEÚDO

O capítulo II contém a Fundamentação Teórica. No capítulo III, apresentam-se os materiais usados para trabalhos de campo e laboratórios. O capítulo IV contém a descrição da metodologia utilizada. O capítulo V apresenta os experimentos realizados na área de testes, bem como a orientação exterior de um par de aerofotos como teste de consistência dos dados obtidos na pesquisa. O capítulo VI é composto pelas considerações finais e o capítulo VII pelas recomendações.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 IMAGEM DIGITAL

Examinando uma imagem analógica preta e branca, ao microscópio, conclui-se que ela é formada por aglomerados de pontos pretos – são grãos de brometo de prata. Na imagem digital, a idéia é substituir os aglomerados de grãos por números. Como em geral os computadores usam *bytes* de 8 *bits*, e, assim, pode-se representar, em 8 *bits*, números desde 0 até 255, estabelecendo-se um mapa onde cada tom é associado com um número, desde o zero até o 255. Com isso, se associamos ao 0 a ausência de cor, 0 representa o preto e 255 o branco nas imagens preta e branca. Os números intermediários representariam os tons de cinza numa escala em que 100% cinza (preto) é representado por 0 (ausência de cor), 0% de cinza (branco) corresponde a 255 e 128 corresponde a 50% cinza, por exemplo.

Para as imagens coloridas, o princípio é o mesmo. Adotando as cores fundamentais RGB – sistema onde, na língua inglesa, tem-se R (*red*) vermelho; G (*green*) verde, e B (*blue*) azul, que são combinados para formar todas as demais cores, é possível representar o tom de cada uma com um *byte* de 8 *bits*. Portanto, 24 *bits* são utilizados.

Uma imagem digital consiste de uma matriz de *pixel* e pode ser guardada na memória de um computador, na forma de uma matriz de números. Cada posição dessa matriz recebe o nome de *pixel* – que significa *picture element* (elemento pictórico).

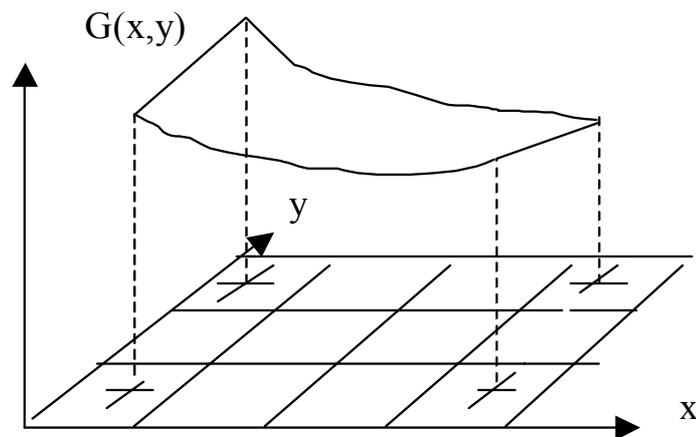
Imagem digital é uma imagem gerada por uma câmara digital ou pela digitalização de uma imagem analógica com o uso de um *scanner*. A câmara digital é um sensor constituído por um sistema óptico, elementos detectores, denominados de CCD, sigla da língua inglesa para *Charge Coupled Device*, dispostos num arranjo retangular e circuitos eletrônicos.

2.2 FORMAÇÃO DA IMAGEM DIGITAL

O princípio de formação de imagem por uma câmara digital consiste na geração de um sinal elétrico ao incidir de um raio de luz refletido do objeto fotografado. O sinal elétrico é de intensidade proporcional à intensidade da luz que

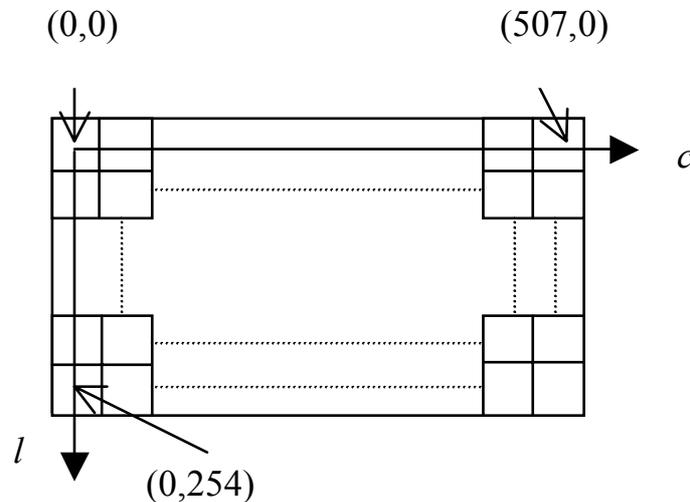
alcança a superfície fotossensível, constituída pelos elementos sensores. De acordo com GRUEN E BEYER (1987, p.181-189), o sinal é apresentado seguindo um padrão de malha regular (reticulado), espaçado em intervalos iguais em um processo conhecido, como conversão analógico-digital, conforme está esquematizado na FIGURA 2.1.

FIGURA 2.1 – CONVERSÃO ANALÓGICO - DIGITAL



A conversão analógico-digital mapeia com valores discretos a função contínua $G(x, y)$ do sinal analógico em dois eixos co-planares e perpendiculares x e y , com intervalos fixos que dependem dos espaçamentos entre os elementos individuais denominados *pixels*. Os espaçamentos entre os *pixels* determinam a resolução da imagem digital obtida. A imagem adquirida com uma câmara digital é tratada como uma malha regular, em cujas interseções estão as posições dos *pixels*. Esta malha pode ser considerada como uma matriz, em que as colunas e linhas formam um sistema de coordenadas cartesianas, onde os eixos x e y , com seus versores iguais a resolução da imagem digital segundo os eixos. A origem do sistema de coordenadas poderia ser adotada em qualquer linha e coluna da matriz, mas, a não ser que seja indicado o contrário, no presente trabalho, a origem será considerada sempre como sendo o canto esquerdo superior da imagem. Como exemplo, a FIGURA 2.2 esquematiza uma imagem que apresenta 507 *pixels* em coluna por 254 *pixels* em linha, formando uma matriz de 254 linhas por 507 colunas. O eixo na direção de c representa as colunas e na direção de l representa as linhas.

FIGURA 2.2 - "PIXELS" DE IMAGENS DIGITAIS



Associa-se a cada posição (c_i, l_i) (coluna, linha) da matriz da malha um número inteiro, que é o mapa do tom de cinza do "pixel" representado. Este número inteiro é obtido através da função que converte valores analógicos contínuos em digitais, portanto discretos, conforme anteriormente descrito, de 0 a 255. Esta função pode ser expressa por G , definida no domínio da imagem, limitado no plano (c, l) , a qual relaciona a informação de posição (c_i, l_i) ao tom de cinza G :

$$G = G(c_i, l_i) \quad (2.1)$$

No processo de aquisição de imagens, podem ocorrer problemas, tais como:

- radiação do objeto dependente da iluminação e direção espacial;
- orientação da câmara e distorção da perspectiva da imagem; diferentes distorções da imagem.

Os problemas citados, e ainda outros que possam ocorrer nos procedimentos de aquisição de uma imagem, representam ruídos que são designados por:

$$\eta = \eta(c_i, l_i) \quad (2.2)$$

O tom de cinza, observado desta forma, é expresso pela combinação das equações (2.1) e (2.2):

$$G = G(c_i, l_i) + \eta(c_i, l_i) \quad (2.3)$$

Do exposto, pode ser afirmado que a imagem digital possui, entre outras, duas qualidades fundamentais:

- A resolução da imagem, ditada pelos versores, geralmente mensurada em termos de “pontos por polegada” – dpi (em língua inglesa, *dots per inch*), ou em micrômetros e, como ocorre por conveniência, em metros no terreno. De qualquer forma, todos esses valores são conversíveis uns aos outros desde que conhecida a escala da imagem.

- A precisão que se refere ao erro associado à posição do “pixel” no objeto.

2.3 MODELO DE REPRESENTAÇÃO DE CORES

O objetivo de um modelo de representação de cores é emitir a especificação de cores em um formato padronizado aceito universalmente (FILHO, 1999, p. 158).

2.3.1 Fundamentos de Cores

A percepção de cor, um processo fisiopsicológico do sistema nervoso central humano, ainda não é completamente compreendido. No entanto, os aspectos físicos da cor vêm sendo pesquisados há muitos anos.

Os olhos humanos percebem os comprimentos de onda do espectro eletromagnético situados entre 400 e 700 nm ($1\text{nm}=10^{-9}\text{m}$). As cores que os seres humanos percebem num objeto são determinadas pela natureza da luz refletida do objeto.

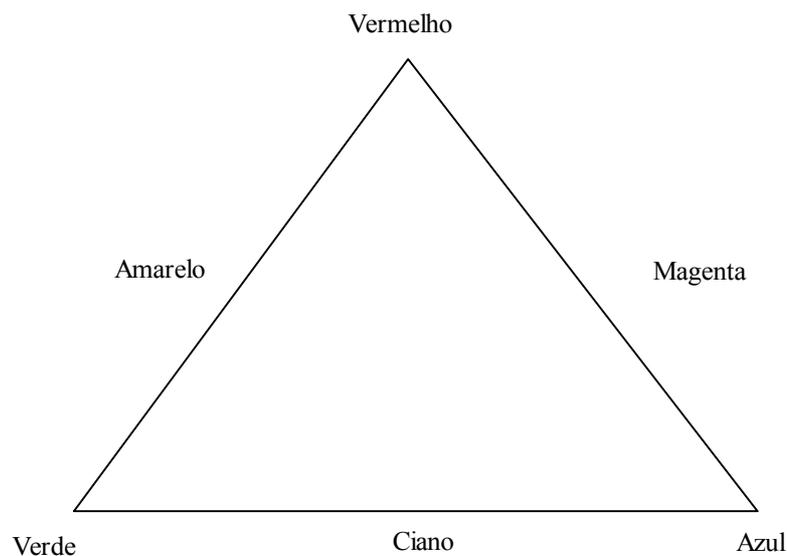
Em 1666, Newton observou que um prisma atravessado pela luz branca, a decompõe em um espectro de cores que vão da violeta à vermelha. Os valores desse espectro são dados por:

- violeta (400 a 446 nm);
- azul (446 a 500 nm);
- verde (500 a 578 nm);
- amarela (578 a 592 nm);
- alaranjada (592 a 620 nm);
- vermelha (620 a 700 nm);

A percepção cromática pelo olho humano é baseada em hipótese formulada por Young em 1801. Esta hipótese estabelece que os cones (células fotossensíveis que compõem a retina juntamente com os bastonetes) se subdividem em três classes com diferentes máximos de sensibilidade situados em torno do vermelho, do verde e do azul. Todas as cores percebidas pelo olho humano são combinações dessas três cores, denominadas cores primárias aditivas. Para que houvesse padronização, a CIE (*Comission International de l'Eclairage* – Comissão Internacional de Iluminação) atribuiu no ano de 1931, os seguintes comprimentos de onda para as cores primárias: azul = 435,8 nm, verde = 546,1 nm, vermelho = 700 nm (FILHO, 1999, p. 155).

As cores podem ser reproduzidas com o uso de dois conceitos: modelo de cores subtrativas e modelo de cores aditivas (ANDRADE, 1998, p.10-11).

FIGURA 2.3 – O TRIÂNGULO DAS CORES



FONTE: Adaptado de (ANDRADE, 1998, p.10).

A FIGURA 2.3 é usada para o entendimento das cores por subtração e adição.

As cores por subtração são, então, obtidas conforme a seguir especificado:

- vermelha = branca – verde – azul
- azul = branca – verde – vermelha
- verde = branca – vermelha – azul
- magenta = branca – verde
- ciano = branca – vermelha

- amarela = branca – azul
- preta = branca – verde – azul – vermelha

Observa-se que a cor preta é a ausência total de luz.

As cores por adição são obtidas da seguinte forma:

- ciano = verde + azul
- magenta = vermelha + azul
- amarela = verde + vermelha
- branca = verde + azul + vermelha

Combinando as cores dos pigmentos: amarelo e ciano é obtida a cor do pigmento verde; amarelo e magenta é obtido o pigmento vermelho; magenta e ciano é obtido o pigmento azul; amarelo, magenta e ciano, é obtido o pigmento preto. As combinações de mistura de cores (primárias aditivas) e de pigmentos (primárias subtrativas) são mostradas na FIGURA 2.4.

FIGURA 2.4 – CORES PRIMÁRIAS E SECUNDÁRIAS DA LUZ E DE PIGMENTOS



FONTE: (GONZALES,2000, p. 177)

As três características para a distinção das cores entre si são: brilho (*B – brightness*), matiz (*H – hue*) e saturação (*S – saturation*). O brilho representa a

noção de intensidade luminosa da radiação. O matiz é uma propriedade associada ao comprimento de onda na combinação de várias ondas visíveis. A saturação expressa a pureza do matiz, isto é, o grau de mistura do matiz original com a luz branca. Por exemplo, o rosa e o vermelho apresentam o mesmo matiz, mas têm diferentes graus de saturação (FILHO, 1999, p. 158).

Cromaticidade é a denominação conjunta de matiz e saturação. Desta forma, uma cor pode ser definida pelo seu brilho e pela sua cromaticidade. Os percentuais de vermelho, verde e azul presentes em uma cor denominam-se coeficientes tricromáticos, dados pelas equações (2.4), (2.5) e (2.6)

$$r = \frac{R}{R + G + B} \quad (2.4)$$

$$g = \frac{G}{R + G + B} \quad (2.5)$$

$$b = \frac{B}{R + G + B} \quad (2.6)$$

onde R , G e B representam a quantidade de luz vermelha, verde e azul, respectivamente, normalizadas entre 0 e 1. A soma dos três coeficientes tricromáticos é:

$$r + g + b = 1 \quad (2.7)$$

2.3.2 Modelos de Cores

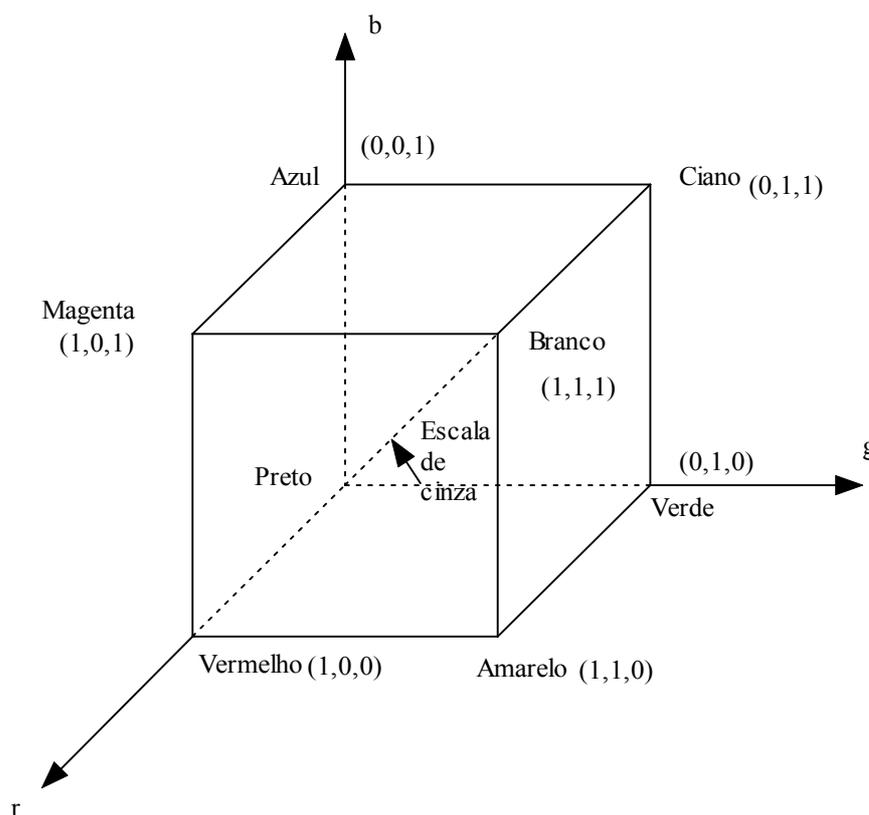
Um modelo de cores é uma representação tridimensional na qual cada cor é representada por um ponto no sistema de coordenadas cartesianas no espaço R^3 .

Há vários modelos de cor que são utilizados para representar os componentes de matiz e saturação de uma imagem colorida. Para o propósito do presente trabalho, serão apresentados apenas os modelos *RGB* (*red, green, blue*) e *HSI* (matiz, saturação, intensidade).

2.3.2.1 O modelo RGB de cores

O modelo RGB, representado na FIGURA 2.5 tem como base um sistema de coordenadas cartesianas. Este modelo é representado por um cubo com três de seus vértices sendo as cores primárias (vermelho, verde e azul) e os outros três vértices as cores secundárias (ciano, magenta e amarelo). O vértice que representa a origem do cubo é o preto, e o mais afastado da origem representa a cor branca. Neste modelo, a escala de cinzas se estende através da diagonal do cubo, formando uma escala de cinzas que vai desde 0 (preto) até 1 (branco). Os valores de r, g, b estão normalizados no intervalo $[0,1]$, de acordo com as equações (2.4) , (2.5) , (2.6) e (2.7).

FIGURA 2.5 – CUBO DE CORES RGB



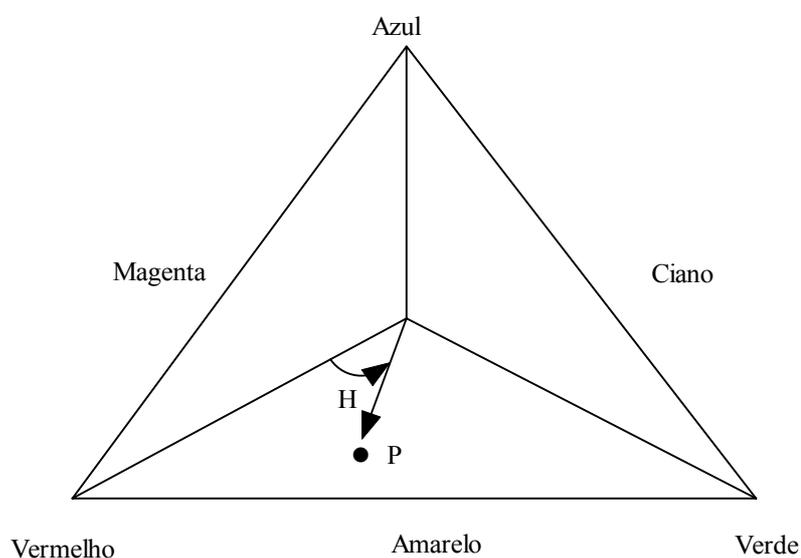
FONTE: Adaptado de (GONZALES, 2000, p.161).

Uma dificuldade com o modelo *RGB* é que ele não produz componentes de cor que refletem com fidelidade o sistema visual humano (PEREZ, 2001, p.29). O modelo RGB é o mais utilizado por câmaras digitais e monitores de vídeo.

2.3.2.2 Modelo HSI de cores

Um outro modelo de cores que produz componentes que melhor representam o entendimento das cores é composto pelos componentes $H = hue$, $S = saturation$ e $I = intensity$, ou seja, matiz, saturação e intensidade. Este modelo é importante e de interesse, porque permite separar as componentes de matiz, saturação e intensidade da informação de cor, em uma imagem da maneira como o ser humano as percebe.

FIGURA 2.6 – TRIÂNGULO DE CORES HSI

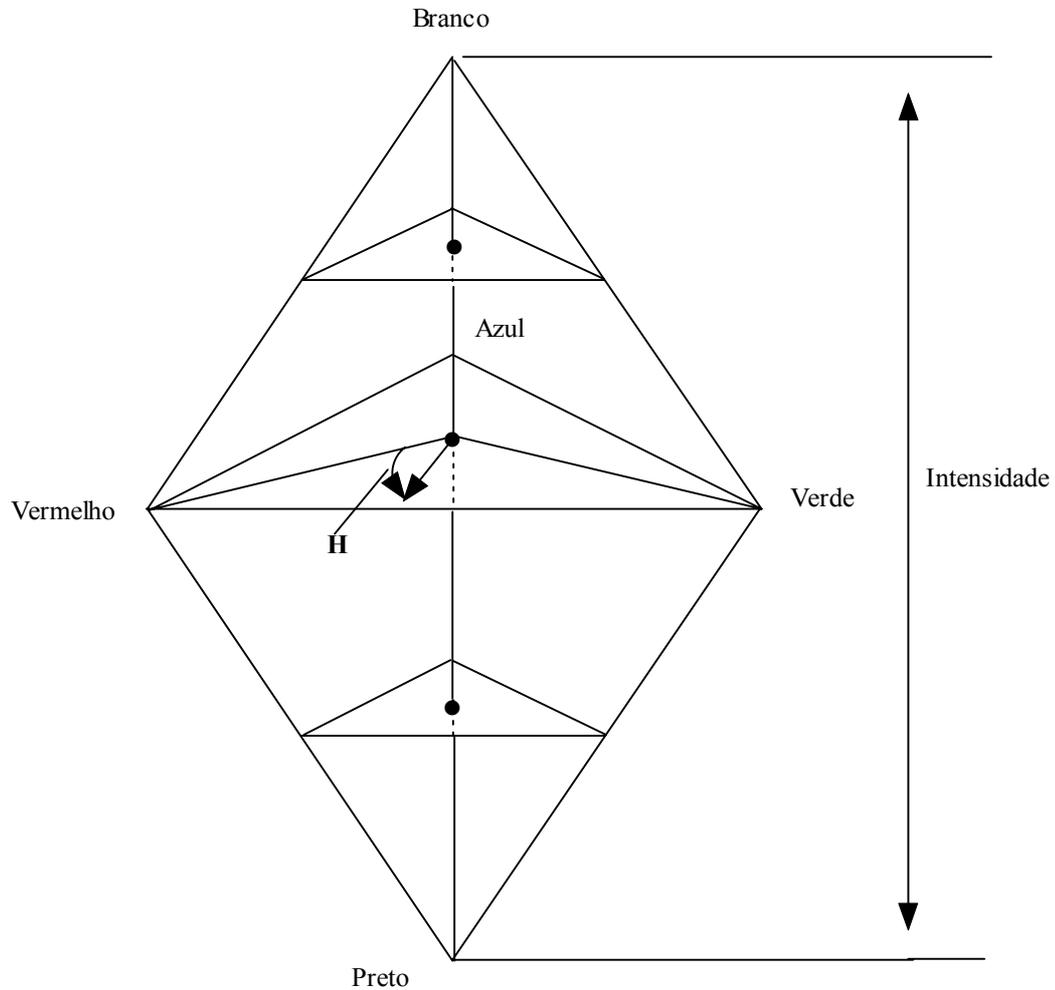


FONTE: adaptado de (GONZALES, 2000, p.163).

A FIGURA 2.6 representa o triângulo HSI como um plano que intercepta as coordenadas r, g, b na FIGURA 2.5. O componente de saturação S é medido de acordo com o comprimento do vetor partindo do centro do triângulo HSI correspondente até uma determinada cor r, g ou b , sendo que as bordas do triângulo correspondem a 100% de saturação. A intensidade no modelo HSI é medida sobre uma linha perpendicular ao plano formado pelo triângulo, passando esta perpendicular pelo centro do triângulo. As intensidades ao longo dessa linha que ficam abaixo do triângulo tendem do escuro até o preto. As intensidades ao longo dessa linha que ficam acima do plano do triângulo tendem do claro ao branco. A matiz H do ponto de cor P é definida como um ângulo entre 0° e 360° , em relação ao eixo vermelho, esquematizado na FIGURA 2.6. Por exemplo, se $H = 0^\circ$, a cor é vermelha e se $H = 30^\circ$, a cor é amarela.

A intensidade no modelo HSI é medida em relação a uma linha perpendicular ao plano determinado pelo triângulo Vermelho-Verde-Azul, passando esta perpendicular pelo centro do triângulo, conforme mostrado na FIGURA 2.7.

FIGURA 2.7 – SÓLIDO DE CORES HSI



FONTE: adaptado de (GONZALES, 2000, p.163).

Os componentes de intensidade, saturação e matiz, em termos de componentes RGB são definidos pelas equações:

$$I = \frac{1}{3}(R + G + B) \quad (2.8)$$

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \quad (2.9)$$

$$H = \arccos \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{\sqrt{(R-G)^2 + (R-B)(G-B)}} \right\} \quad (2.10)$$

Para maiores detalhes, a fórmula (2.10) tem uma dedução completa apresentada em (GONZALES, 2000, p. 164-166). Imagens em níveis de cinza representando matiz, saturação e intensidade podem ser geradas lendo *pixel a pixel* a imagem *RGB* original e calculando esses valores por meio das equações (2.8), (2.9) e (2.10).

Uma das limitações do modelo *HSI* é que ele considera cada componente *RGB* por igual ao se calcular a intensidade ou luminosidade de uma imagem. A sensibilidade do olho humano varia para cada componente *RGB*. Desta forma, melhores resultados para a intensidade podem ser obtidos por meio da transformação (WEEKS, 1996):

$$I = 0,299R + 0,587G + 0,114B \quad (2.11)$$

A aplicação da equação (2.11) faz resultar uma correspondência melhor com a percepção de brilho de uma cor.

2.4 CORRELAÇÃO ESTATÍSTICA

No tratamento digital de imagens, entende-se por *correlação* a comparação de imagens para a identificação de pontos homólogos que melhor se adaptam de uma imagem chamada de *referência* com outra imagem denominada *imagem de busca*. Na imagem de referência, escolhe-se uma *matriz de amostra* e se faz percorrer “pixel” a “pixel” esta matriz em uma janela na imagem de busca. Calcula-se, então, para cada posição da matriz de amostra, um valor de comparação, conforme ilustrado na Uma imagem em tons de cinza, com *pixels* representados por dígitos de oito bits, permite distinguir 256 tons de cinza, do zero (preto) ao 255 (branco). O valor da correlação entre duas matrizes de tons de cinza de iguais dimensões pode ser calculado pela relação definida na equação (2.12)

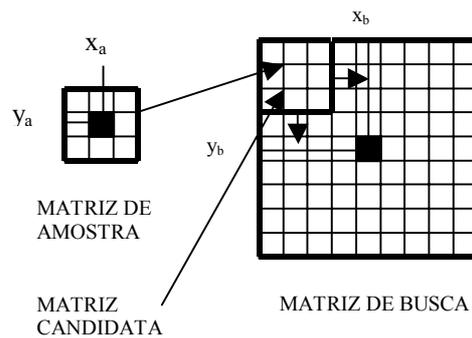
FIGURA 2.8. Ainda na Uma imagem em tons de cinza, com *pixels* representados por dígitos de oito bits, permite distinguir 256 tons de cinza, do zero (preto) ao 255

(branco). O valor da correlação entre duas matrizes de tons de cinza de iguais dimensões pode ser calculado pela relação definida na equação (2.12)

FIGURA 2.8, cada posição assumida pela matriz de amostra na matriz de busca denomina-se matriz candidata.

Uma imagem em tons de cinza, com *pixels* representados por dígitos de oito bits, permite distinguir 256 tons de cinza, do zero (preto) ao 255 (branco). O valor da correlação entre duas matrizes de tons de cinza de iguais dimensões pode ser calculado pela relação definida na equação (2.12)

FIGURA 2.8 - MATRIZES DE AMOSTRA E DE BUSCA



FONTE: Adaptado de (ANDRADE, 1998, p.122).

$$\rho = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \quad (2.12)$$

onde σ_{xy} representa a covariância entre as variáveis aleatórias x e y , enquanto que σ_x e σ_y são os seus respectivos desvios padrões. Esses parâmetros, σ_{xy} , σ_x e σ_y , são estimados com base nas amostras:

$$x = [x_1 \ x_2 \ x_3 \ \dots \ x_n]^T \quad ; \quad y = [y_1 \ y_2 \ y_3 \ \dots \ y_n]^T \quad (2.13)$$

Os desvios padrões de x e y são, respectivamente, estimados pelas estatísticas amostrais:

$$s_x = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad ; \quad s_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n-1}} \quad (2.14)$$

e a covariância entre x e y é estimada por:

$$s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (2.15)$$

Nas fórmulas (2.14) e (2.15) \bar{x} e \bar{y} são respectivamente as médias amostrais de x e y

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad ; \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (2.16)$$

Substituindo as (2.14) e (2.15) na (2.12) resulta na estatística que estima o

$$\text{parâmetro } \rho = \text{corr}(x, y) = \frac{\sigma_{xy}}{\sigma_x \sigma_y}$$

$$\hat{s} = \rho = \frac{\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})]}{\sqrt{\left[\sum_{i=1}^n (x_i - \bar{x})^2 \right] \left[\sum_{i=1}^n (y_i - \bar{y})^2 \right]}} \quad (2.17)$$

Ao se desenvolver o numerador da (2.17), resulta:

$$\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})] = \sum_{i=1}^n x_i y_i - \bar{y} \left[\sum_{i=1}^n x_i \right] - \bar{x} \left[\sum_{i=1}^n y_i \right] + n\bar{x}\bar{y} \quad (2.18)$$

Substituindo as (2.16) na (2.18), resulta:

$$\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})] = \sum_{i=1}^n x_i y_i - \frac{1}{n} \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right) \quad (2.19)$$

A seguir, desenvolve-se o denominador da (2.17);

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n [(x_i)^2 - 2x_i \bar{x} + (\bar{x})^2] \quad (2.20)$$

Substituindo a (2.16) na (2.20):

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n (x_i)^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \quad (2.21)$$

e de maneira análoga:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i)^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2 \quad (2.22)$$

Finalmente, substituindo as (2.19), (2.21 e (2.22) na (2.17), resulta:

$$r = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{n} \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right)}{\sqrt{\left(\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \right) \left(\sum_{i=1}^n y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2 \right)}} \quad (2.23)$$

Onde:

x_i = Valor do tom no *pixel* i na matriz de amostra;

y_i = Valor do tom no *pixel* i na matriz candidata dentro da matriz de busca;

n = número de *pixels* da matriz de amostra;

r = valor da correlação.

O valor da correlação é um número real que varia entre -1 e $+1$. Para ausência de correlação, $r = 0$. Para $r=1$, significa correlação perfeita, isto é, quando uma das variáveis cresce em valor, por exemplo, da matriz de amostra, a matriz candidata da matriz de busca também cresce. O valor da correlação negativa, $r = -1$ significa que quando uma variável cresce, a outra decresce e vice-versa. É importante observar que a existência de correlação física significa existência de correlação estatística, mas a recíproca não é verdadeira, isto é, a existência de correlação estatística não implica necessariamente em correlação física. Este fato demonstra que, no processo de identificação de pontos homólogos em Fotogrametria, não basta se calcular correlação de cores, mas, sem dúvida, outras ferramentas devem ser usadas para se maximizar a probabilidade de sucesso.

O ponto homólogo da imagem da direita é obtido a partir da pesquisa (busca) da correlação deslocando-se a matriz de amostras, "*pixel*" a "*pixel*" sobre a matriz de busca, e, para cada posição da matriz candidata, calcula-se a correlação. A posição central da matriz candidata, que resultar com o valor mais próximo de 1, tem alta probabilidade de ser o centro da matriz que representa o ponto homólogo na outra imagem. A área da matriz de busca deve ser restrita àquela que se saiba com certeza que contém o ponto homólogo, pois, caso contrário, haveria

identificação errada. A ordem da matriz de amostra deve ser ímpar, pois desta forma haverá um “*pixel*” central na matriz de amostra (ANDRADE, 1998, p.124).

2.5 CONCEITOS BÁSICOS SOBRE REDES NEURAIS

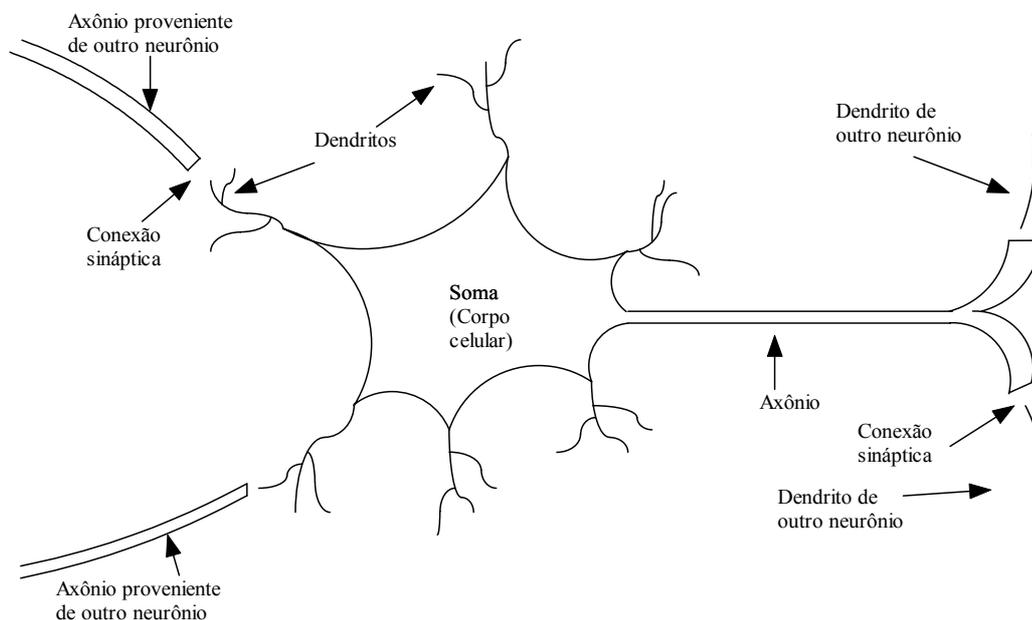
2.5.1 Modelo Natural

As redes neurais artificiais são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm capacidade computacional adquirida por meio do aprendizado e generalização (REZENDE, 2003, p. 142).

Neste sentido, as redes neurais artificiais consistem em uma abordagem de Inteligência Artificial, para soluções de problemas que têm por base o modelo conhecido e aceito de inteligência: o cérebro humano (NIEVOLA, 1998, p. 12).

Desta forma, o elemento básico para as redes neurais artificiais é a célula nervosa, ou neurônio, que é formado basicamente das seguintes partes, ilustradas na FIGURA 2.9

FIGURA 2.9 – NEURÔNIO BIOLÓGICO



FONTE: (Adaptado de FAUSETT, 1994, p. 6).

Onde:

- **Dendritos:** são elementos através dos quais cada neurônio recebe informações do meio exterior. Os dendritos são considerados elementos de entrada do sistema.

- *Núcleo ou corpo celular*: em função dos sinais aferentes, passa para um de dois estados possíveis: excitado ou inibido.
- *Axônio*: é responsável pela transmissão do estado do neurônio para outros neurônios.
- *Sinapse ou conexão sináptica*: esta conexão efetua (ou não) a interligação entre a saída de um neurônio e a entrada do próximo neurônio, por intermédio de um processo bioquímico.

A rede neural artificial tem um processo de aprendizado interativo e, por meio desse processo, deve melhorar o seu desempenho à medida que interage com o meio externo. Isto pode ser feito por intermédio de um processo iterativo de ajustes aplicado a seus pesos, o *treinamento*. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas. Um problema de aprendizado é resolvido por meio de um algoritmo de aprendizado. Existem tipos diferentes de algoritmos de aprendizagem para determinados modelos de redes neurais. Esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

A generalização de uma rede neural artificial está ligada à capacidade de dar respostas coerentes para dados não apresentados a ela previamente no treinamento.

2.5.2 Rede Neural Artificial

Uma rede neural artificial é um sistema de processamento de informações que apresenta certas características em comum com uma rede neural biológica. As redes neurais artificiais são desenvolvidas como generalização de modelos matemáticos de neurônios biológicos com base nas seguintes asserções (FAUSETT, 1994, p.6):

- o processamento das informações ocorre por intermédio de elementos simples, chamados de *neurônios*;
- os sinais são passados entre os neurônios por meio de conexões;
- cada conexão tem um peso associado;
- para determinar o sinal de saída, cada neurônio aplica na função de ativação a soma dos pesos dos sinais de entrada.

Uma rede neural é caracterizada por seus padrões de conexão entre os neurônios, denominados *arquitetura* da rede; seu método de atualização dos pesos nas conexões, denominado algoritmo de *treinamento* ou algoritmo de *aprendizado*; sua *função de ativação*.

Uma rede neural artificial consiste de um grande número de elementos chamados *neurônios*, *unidades*, *células* ou *nodos*. Cada neurônio é conectado a outro, por meio de ligações, cada uma associada a pesos.

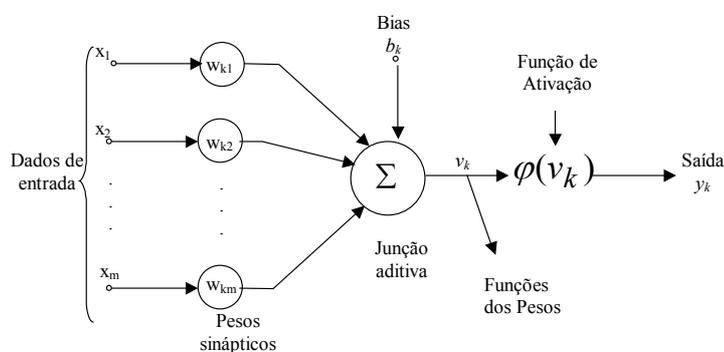
Cada neurônio tem um estado interno, chamado *ativação* ou *nível de atividade*, o qual é uma função de sua entrada. Um neurônio envia a sua ativação para vários outros neurônios.

2.5.3 Modelo de um Neurônio

A partir da observação do modelo natural, McCulloch & Pitts (McCulloch, Pitts, 1943) elaboraram um modelo matemático aproximado do comportamento do neurônio. Este modelo, o mais utilizado como fundamento básico para as redes neurais artificiais, sugere que todos os sinais fornecidos à rede atingem o núcleo por meio das entradas (dendritos), que têm a capacidade de atenuar parcial ou totalmente o sinal recebido, realizando a seguir uma reação bioquímica, a qual determina o estado ativo ou inativo da saída da célula nervosa.

Um neurônio é uma unidade de processamento de informação fundamental para as operações em uma rede neural. A FIGURA 2.10 mostra o modelo de um neurônio que forma a base para o projeto de redes neurais artificiais.

FIGURA 2.10 - MODELO DE UM NEURÔNIO ARTIFICIAL



FONTE: (HAYKIN, 2001, p.36).

Com base na FIGURA 2.10 , identificam-se os seguintes elementos básicos em um modelo de neurônio artificial:

- Elos de conexão (sinapses), cada uma caracterizada por um peso. O sinal x_j na entrada da sinapse j , conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . O primeiro índice subscrito (k) se refere ao neurônio k e o segundo (j) ao sinal de entrada relativo ao respectivo peso (w_{kj}).
- Uma *somatória*, v_k , caracterizada por uma combinação linear entre os sinais de entrada e os seus respectivos pesos.
- Uma *função de ativação*, $\varphi(v_k)$, cuja finalidade é restringir a amplitude de saída (y_k) do neurônio.
- Uma *perturbação (bias)*, aplicada externamente, representada por b_k na FIGURA 2.10. A perturbação tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo de ela ser positiva ou negativa, respectivamente.

Do anteriormente exposto, pode-se então expressar um neurônio k pelas equações (2.24) a (2.26).

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (2.24)$$

$$v_k = u_k + b_k \quad (2.25)$$

$$y_k = \varphi(v_k) \quad (2.26)$$

Na equação (2.24), $x_1, x_2, x_3, \dots, x_m$ são os dados de entrada; $w_{k1}, w_{k2}, w_{k3}, \dots, w_{km}$ são os pesos sinápticos do neurônio k .

A forma mais comum de função de ativação utilizada na elaboração de redes neurais artificiais é a denominada função logística *sigmóide* e apresenta forma de **S**, como mostrado na FIGURA 2.11.

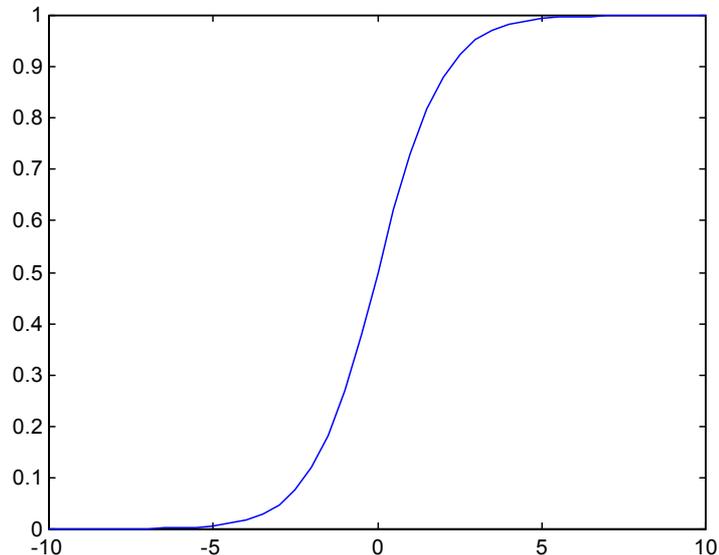
A função logística sigmóide cujo gráfico está na FIGURA 2.11 tem por expressão:

$$f(x) = \frac{1}{1 + e^{-x}}, \quad x \in R \quad (2.27)$$

e a sua derivada é dada por:

$$\frac{df(x)}{dx} = f(x)[1 - f(x)] \quad (2.28)$$

FIGURA 2.11 - GRÁFICO DA FUNÇÃO LOGÍSTICA SIGMÓIDE



A maior importância da função sigmóide está na sua variação entre 0 e 1.

$$\text{Assim, } f(x) = \frac{1}{1 + e^{-x}} = \begin{cases} 0, & x \rightarrow -\infty \\ 1, & x \rightarrow +\infty \end{cases}$$

2.5.4 O Perceptron

O Perceptron é a forma mais simples de uma rede neural artificial, constituído basicamente por um neurônio simples, com pesos sinápticos ajustáveis e *bias*. O Perceptron Simples (ROSENBLATT, 1958) foi o primeiro modelo de rede neural artificial envolvendo o conceito de aprendizado (REZENDE, 2003).

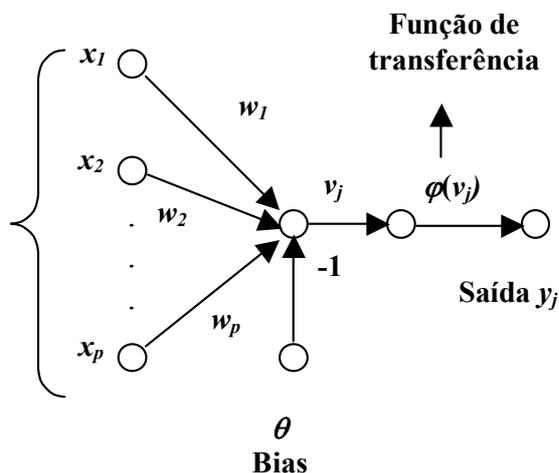
O Perceptron é usado para a classificação de padrões linearmente separáveis, isto é, padrões que se encontram em lados opostos de um hiperplano.

Um perceptron simples está esquematizado na FIGURA 2.12 .

Na FIGURA 2.12 , os pesos do perceptron são $w_1, w_2, w_3, \dots, w_p$. As entradas correspondentes aplicadas ao perceptron são x_1, x_2, \dots, x_p . O *bias* aplicado externamente é denotado por θ . Do conceito de neurônio artificial, o combinador de saída v_j é:

$$v_j = \sum_{i=1}^p w_i x_i - \theta \quad (2.29)$$

FIGURA 2.12 - O PERCEPTRON

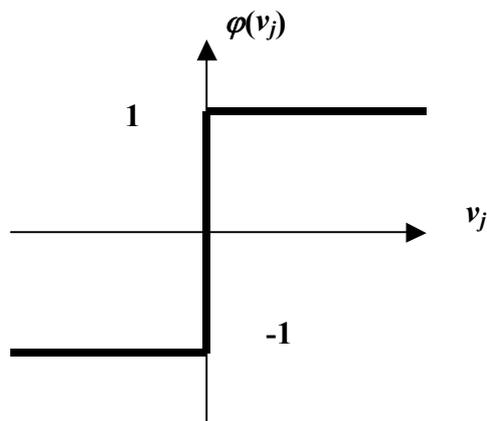


A saída do neurônio é obtida por

$$y_j = \phi(v(j)) \quad (2.30)$$

A função de transferência está representada na FIGURA 2.13 .

FIGURA 2.13 – FUNÇÃO DE TRANSFERÊNCIA DO PERCEPTRON



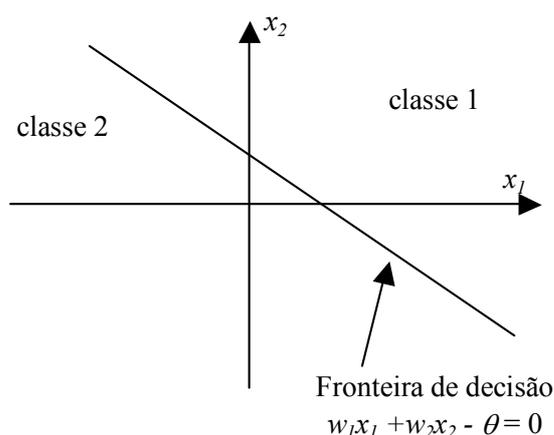
O propósito do Perceptron é classificar o conjunto estimulado aplicado externamente em duas classes. A regra de decisão para a classificação é assinalar os padrões representados pelas entradas para uma das classes se a saída do Perceptron for +1, e para a outra classe, se a saída do Perceptron for -1. Assim, no

caso de um Perceptron elementar, há duas regiões de decisão separadas por um hiperplano, dado pela equação (2.31).

$$\sum_{i=1}^p w_i x_i - \theta = 0 \quad (2.31)$$

A FIGURA 2.14 ilustra a fronteira de decisão para o caso de apenas duas variáveis de entrada x_1 e x_2

FIGURA 2.14 – FRONTEIRA DE DECISÃO

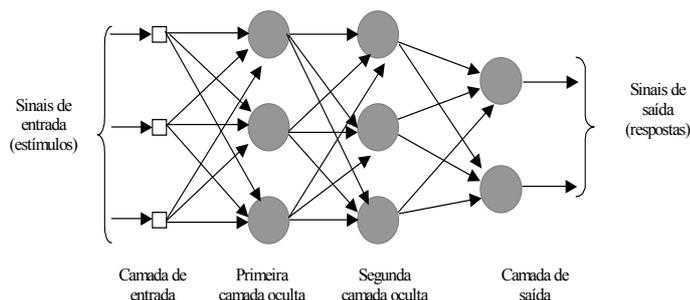


O ponto (x_1, x_2) que se situa acima da linha fronteira é assinalado para a classe 1 e o que se situa abaixo é assinalado para a classe 2.

2.6 REDES FEEDFORWARD E RETROPROPAGAÇÃO

Uma rede *Feedforward* (alimentada para frente) ou Perceptron, de múltiplas camadas, consiste de um conjunto de unidades sensoriais formando a *camada de entrada*, uma ou mais *camadas ocultas* e uma *camada de saída* de nós computacionais. Este tipo de rede é uma generalização do perceptron simples (HAYKIN, 2001, p.183). Na FIGURA 2.15 está representada a estrutura de um Perceptron de múltiplas camadas.

FIGURA 2.15 – PERCEPTRON DE MÚLTIPLAS CAMADAS



FONTE: (HAYKIN, 2001, p.186).

O termo retropropagação (*backpropagation*) refere-se a um método de treinamento empregado na arquitetura do Perceptron de múltiplas camadas, no qual os pesos das conexões são ajustados pela retropropagação de erro. Esta retropropagação consiste de dois passos através das diferentes camadas da rede: um passo para frente, a *propagação*, e um passo para trás, a *retropropagação*. No passo de propagação, os pesos sinápticos são invariantes. No *passo para trás*, os pesos sinápticos são *ajustados* por uma regra de correção de erro que consiste na diferença entre a resposta de saída da camada em questão da rede e a resposta desejada. Isto produz um sinal de erro, que é propagado para trás através da rede em direção contrária às conexões sinápticas.

2.6.1 Algoritmo de Retropropagação

A apresentação do n -ésimo exemplo de treinamento, isto é, o sinal de erro na saída do neurônio j , na iteração n é definido por:

$$e_j(n) = d_j(n) - y_j(n) \quad (2.32)$$

onde $e_j(n)$ se refere ao sinal de erro na saída do neurônio j , para a iteração n , $y_j(n)$ se refere ao sinal funcional que aparece na saída do neurônio j , para a iteração n e $d_j(n)$ é o valor desejado para a saída do neurônio j . O valor instantâneo da energia do erro para o neurônio j é definida por $e_j^2(n)/2$ (HAYKIN, 2001, p.188). Correspondentemente, o valor instantâneo $\varepsilon(n)$ do erro total é obtido somando-se os termos $e_j^2(n)/2$ de todos os neurônios da camada de saída:

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.33)$$

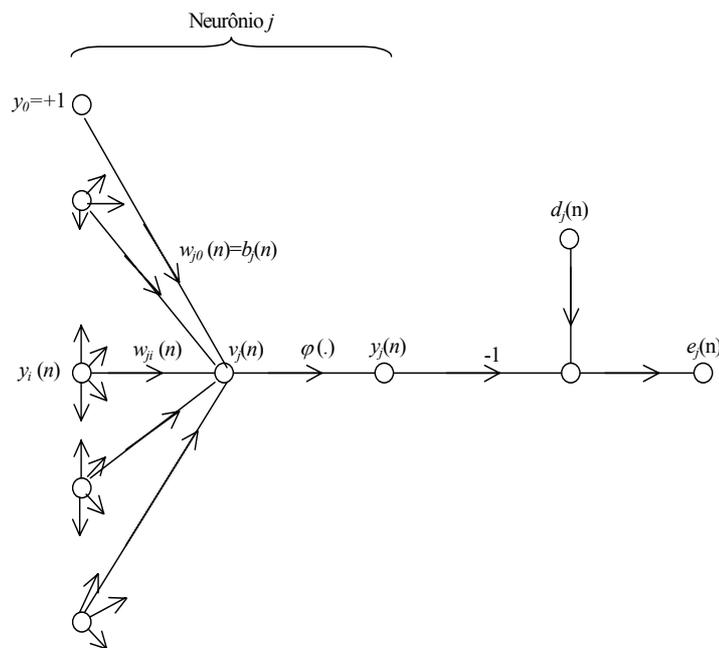
Na (2.33) o conjunto C inclui todos os neurônios da camada de saída da rede. Seja N o número total de padrões contidos no conjunto de treinamento. A energia média do erro quadrático é obtida por:

$$\varepsilon_{med} = \frac{1}{N} \sum_{m=1}^N \varepsilon(n) \quad (2.34)$$

A energia média do erro ε_{med} é uma função de todos os parâmetros livres (pesos sinápticos e bias) da rede. Para um dado conjunto de treinamento, ε_{med} representa a *função de custo* como uma medida de desempenho de aprendizagem.

O objetivo do processo de aprendizagem é ajustar os parâmetros livres da rede para minimizar a função de custo ε_{med} .

FIGURA 2.16 – DETALHES DO NEURÔNIO SIMPLES DE SAÍDA J



FONTE: (HAYKIN, 2001, p.189).

Na FIGURA 2.16 representa-se o neurônio j sendo alimentado por um conjunto de sinais funcionais produzidos por uma camada de neurônios à sua esquerda. Associado ao neurônio j , é produzido um campo local induzido $v_j(n)$ na entrada da função de ativação dada na (2.35)

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (2.35)$$

Na (2.35) m é o número total de entradas aplicadas ao neurônio j . O peso sináptico w_{j0} , que corresponde à entrada fixa $y_0 = +1$, é igual ao *bias* b_j aplicado ao neurônio j . Desta forma, o sinal funcional $y_j(n)$ produzido na saída do neurônio j na iteração n é

$$y_j(n) = \varphi_j(v_j(n)) \quad (2.36)$$

Aqui é aplicada uma correção $\Delta w_{ji}(n)$ ao peso sináptico $w_{ji}(n)$, proporcional à derivada parcial $\partial \varepsilon(n) / \partial w_{ji}(n)$. Uma vez que ε é função de y e y é função de v , que por sua vez é função de w , pode-se expressar:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (2.37)$$

A derivada parcial $\partial \varepsilon(n) / \partial w_{ji}(n)$ representa um *fator de sensibilidade*, determinando a direção de busca, no espaço de pesos, para o peso sináptico w_{ji} . Usando a (2.33) resulta:

$$\frac{\partial \varepsilon(n)}{\partial e_j(n)} = e_j(n) \quad (2.38)$$

Pela (2.32) resulta:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (2.39)$$

Derivando a (2.36) em relação à $v_j(n)$, resulta:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (2.40)$$

Derivando a (2.35) em relação à $w_{ji}(n)$, resulta:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (2.41)$$

Agora, a substituição das equações de (2.38) à (2.41) na equação (2.37), resulta em:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_i(n) \quad (2.42)$$

A correção $\Delta w_{ji}(n)$ aplicada ao peso sináptico $w_{ji}(n)$ é definida pela regra delta:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (2.43)$$

onde η é o parâmetro da taxa de aprendizagem. O uso do sinal negativo na equação (2.43) indica a descida do gradiente no espaço dos pesos, isto é, a busca de uma direção para a mudança do peso que reduza o valor de $\varepsilon(n)$. Isto se deve ao fato de que $\frac{\partial \varepsilon}{\partial w}$ representa o vetor ortogonal à superfície determinada por (2.33), no sentido positivo. O sinal negativo na (2.43), aponta o sentido para o qual $\varepsilon(n)$ decresce. Substituindo a (2.42) na (2.43) resulta:

$$\Delta w_{ji}(n) = \eta e_j(n) \varphi'_j(v_j(n)) y_i(n) \quad (2.44)$$

O gradiente local $\delta_j(n)$ é definido por

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial v_j(n)} = -\frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (2.45)$$

Substituindo a (2.45) na (2.44), resulta:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (2.46)$$

O gradiente local, que pela (2.45) é igual ao produto do sinal de erro $e_j(n)$ pela derivada da função de ativação, aponta para as modificações necessárias nos pesos sinápticos. Pelas equações (2.44) e (2.45), nota-se que um dos fatores envolvidos no cálculo do ajuste de pesos $\Delta w_{ji}(n)$ é o sinal de erro na saída do neurônio j . Podemos então identificar dois casos distintos, dependendo de onde o neurônio j está localizado na rede.

Caso 1: O neurônio j é um Nó de Saída

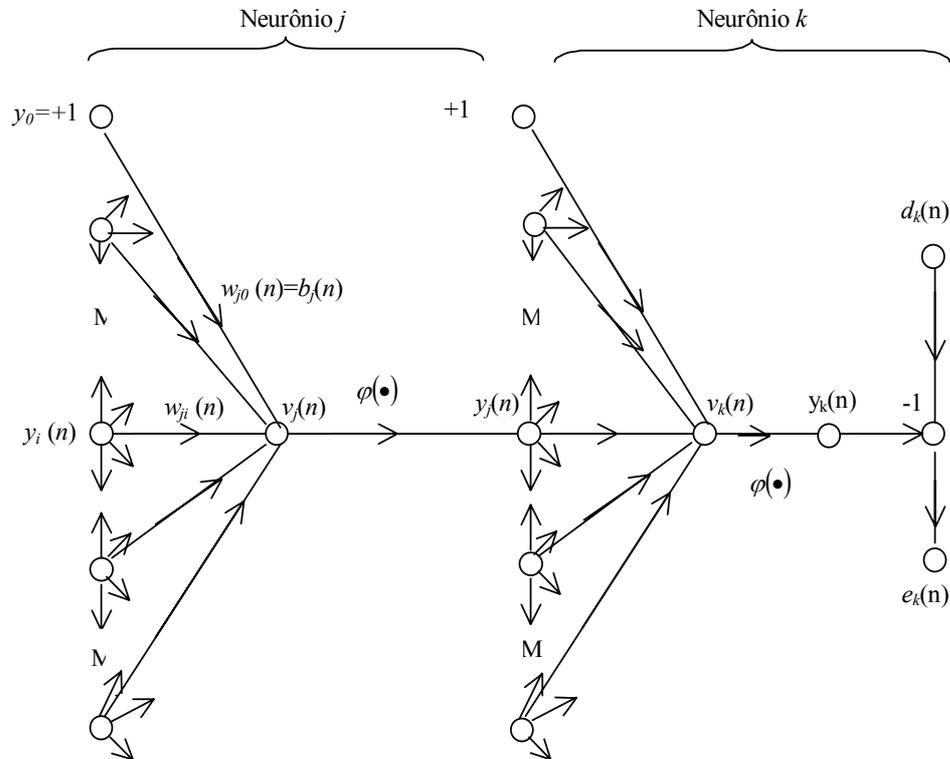
Se o neurônio j está localizado na camada de saída da rede, utiliza-se a equação (2.32) para o cálculo do sinal de erro $e_j(n)$ associado com ele (FIGURA 2.16). Uma vez determinado o sinal de erro, calcula-se o gradiente local $\delta_j(n)$, usando a equação (2.45).

Caso 2: O Neurônio j é um Nó Oculto

Se o neurônio j está localizado em uma camada oculta da rede, não existe uma resposta desejada especificada para aquele neurônio. O sinal de erro para o neurônio oculto deve ser determinado recursivamente, em termos dos sinais de erro de todos os neurônios aos quais o neurônio oculto está diretamente conectado. A FIGURA 2.17 representa o neurônio j como um nó oculto da rede. De acordo com a

equação (2.45), o gradiente local $\delta_j(n)$ para o neurônio oculto pode ser redefinido para o neurônio oculto j como:

FIGURA 2.17- NEURÔNIO OCULTO J CONECTADO AO NEURÔNIO K



FONTE: (HAYKIN, 2001, p.192).

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) \quad (2.47)$$

Na segunda igualdade da equação (2.47) foi usada a equação (2.40). Para o cálculo da derivada parcial $\partial \varepsilon(n) / \partial y_j(n)$ na equação (2.47), procede-se como segue: a equação (2.33), adaptada à FIGURA 2.17 fornece equação

$$\varepsilon(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (2.48)$$

onde o neurônio k é um nó de saída. Derivando parcialmente a (2.48) em relação ao sinal funcional $y_j(n)$, resulta:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (2.49)$$

Mas

$$\frac{\partial e_k(n)}{\partial y_j(n)} = \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (2.50)$$

Agora, substituindo a equação (2.50) na (2.49), resulta em:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (2.51)$$

No entanto, da equação (2.42) adaptada à FIGURA 2.17, nota-se que

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi_k(v_k(n)) \quad (2.52)$$

Deste modo,

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (2.53)$$

Na FIGURA 2.17 o campo local induzido para o neurônio de saída k é

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n) \quad (2.54)$$

Agora derivando parcialmente a equação (2.54) em relação a $y_j(n)$, resulta:

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (2.55)$$

Substituindo as equações (2.53) e (2.55) na equação (2.51), resulta na derivada parcial procurada:

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = -\sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) = -\sum_k \delta_k(n) w_{kj}(n) \quad (2.56)$$

Na segunda igualdade da equação (2.56), utilizamos a definição do gradiente local $\delta_k(n)$ dado na equação (2.45) com o índice j substituído por k .

Utilizando a equação (2.56) em (2.47), resulta na *fórmula de retropropagação* para o gradiente local

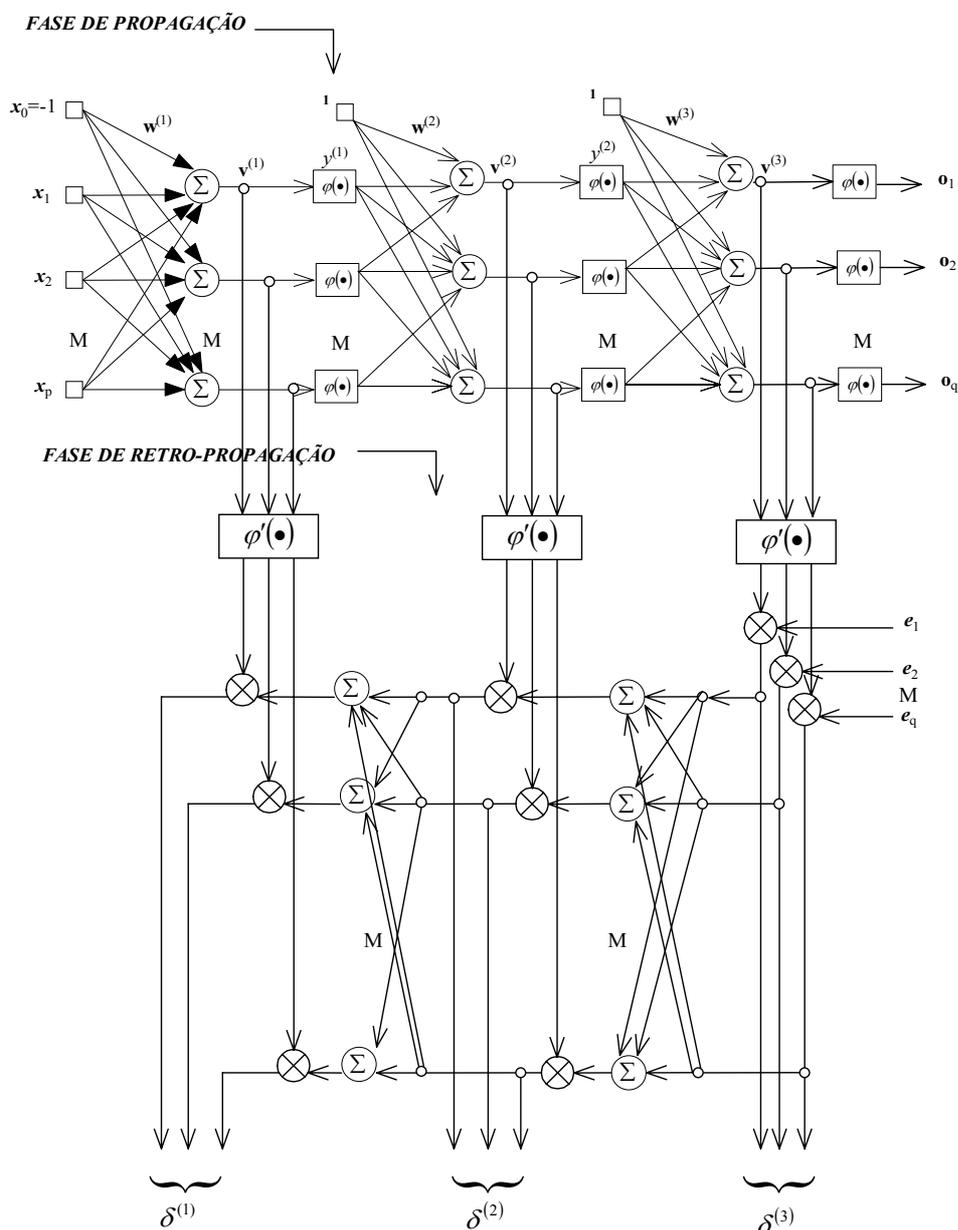
$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (2.57)$$

onde o neurônio j é oculto. No caso em que a função de ativação é a função sigmóide, definida na fórmula (2.27) e mostrada na FIGURA 2.11, a fórmula (2.57) se transforma em:

$$\delta_j(n) = y_j(n) [1 - y_j(n)] \sum_k \delta_k(n) w_{kj}(n) \quad (2.58)$$

sendo que $y_j(n)$ é o resultado da função de ativação do neurônio j em uma camada escondida, na época n . Na FIGURA 2.18 está mostrado o fluxograma do método de retropropagação.

FIGURA 2.18 – FLUXOGRAMA DO MÉTODO DE RETROPROPAGAÇÃO



FONTE: (HAYKIN, 1994, p.154).

A FIGURA 2.18 apresenta um fluxograma das fase de propagação, representada na parte superior e de retropropagação representada na parte inferior da mesma. As notações usadas nesta figura são as seguintes:

$w^{(l)}$ = vetor dos pesos sinápticos de um neurônio na camada l , incluído o *bias*.

$v^{(l)}$ = vetor do nível de atividade interna da rede dos neurônios na camada l

$y^{(l)}$ = vetor das aplicações da função de ativação dos neurônios na camada l

$\delta^{(l)}$ = vetor dos gradientes locais dos neurônios na camada l

e = vetor dos erros representados pelos elementos $e_1, e_2, e_3, \dots, e_q$. O índice l varia desde $l=0$ na camada de entrada até $l=L$, na camada de saída. No fluxograma da FIGURA 2.18 tem-se $L=3$. Na parte inferior deste fluxograma está representada a fase de retropropagação *backward*, onde são calculados os gradientes locais. As etapas para o treinamento de uma rede neural com o uso do algoritmo de retropropagação para o treinamento do conjunto de dados $\{\mathbf{x}(n), \mathbf{d}(n)\}; n=1, 2, \dots, N\}$, onde \mathbf{x} é o vetor de entrada e \mathbf{d} é o vetor resposta desejada são apresentadas a seguir:

- I) *Inicialização*: Determina-se uma configuração para a rede neural: número de camadas e número de neurônios em cada camada. Atribuem-se valores aleatórios aos pesos sinápticos e *bias*. Segundo (HAYKIN, 1994 p.155) estes pesos devem ser pequenos e uniformemente distribuídos.
- II) *Apresentação dos exemplos de treinamento*. Apresenta-se à rede os exemplos de treinamento, para que sejam treinados em uma iteração (época). Para cada exemplo no conjunto ordenado de alguma maneira, executam-se as fases para frente *forward* e para trás *backward*, nas etapas III e IV, respectivamente.
- III) *Computação para frente (forward)*: Se um exemplo de treinamento da época é representado por $\{\mathbf{x}(n), \mathbf{d}(n)\}; n=1, 2, \dots, N\}$, com o vetor de entrada $\mathbf{x}(n)$, aplicado à camada de entrada de nós computacionais, ocorre o campo local induzido. Utilizando a equação (2.35), aplicada à camada l , na iteração n , resulta o valor do campo local induzido para o neurônio j :

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{(l-1)}(n),$$

onde $y_i^{(l-1)}(n)$ é valor da função de ativação da saída do neurônio i na camada anterior $(l-1)$, na iteração (época) n e $w_{ji}^{(l)}$ é o peso sináptico do

neurônio j da camada l , que é alimentado pelo neurônio j da camada $l-1$. A função de ativação é a função sigmóide e desta forma a saída do neurônio j na camada l é obtida por:

$$y_j^{(l)}(n) = \frac{1}{1 + e^{-v_j^{(l)}(n)}}$$

Se o neurônio j está na primeira camada, então $l=1$ e

$$y_j^{(0)}(n) = x_j(n)$$

onde $x_j(n)$ é o j -ésimo elemento do vetor de entrada $x(n)$.

Se o neurônio j está na camada de saída, então $l=L$ e

$$y_j^{(L)}(n) = o_j(n)$$

Calcula-se o erro:

$$e_j^{(L)}(n) = d_j(n) - o_j(n)$$

onde $d_j(n)$ é o j -ésimo elemento do vetor resposta desejado

IV) Retropropagação

Cálculo dos gradientes locais da rede, camada por camada:

Para a camada de saída L :

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)]$$

Para a camada escondida l

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) \{1 - y_j^{(l)}(n)\} \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad j=1,2,3,\dots,p \quad k=1,2,3,\dots,q$$

Ajuste dos pesos sinápticos na camada l

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha \{w_{ji}^{(l)}(n) - w_{ji}^{(l)}(n-1)\} + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n),$$

$$l=1,2,\dots; i=1,2,\dots,p; j=1,2,\dots,q$$

onde α é a constante momento e η é a taxa de aprendizagem

V) Iteração

Reiteram-se os cálculos, pela apresentação de nova época de treinamento, repetindo-se os passos de II até IV, até que os parâmetros da rede estabilizem os seus valores.

2.6.2 Taxa de Aprendizagem e Momento

O algoritmo *backpropagation* fornece uma aproximação para a trajetória no espaço dos pesos calculados pelo método de passos descendentes. Quanto menor se fizer o parâmetro taxa de aprendizagem η , tanto menor será a mudança nos pesos sinápticos da rede de uma iteração para a próxima. Por outro lado, quanto maior for a taxa de aprendizagem η , maior será a mudança nos pesos sinápticos de uma iteração para a outra. Neste caso, a rede pode se tornar instável, isto é, oscilatória. Um método simples de incrementar a taxa de aprendizagem e evitar o perigo de instabilidade é modificar a regra delta mostrada na equação (2.46) pela inclusão de um termo “momento”, como mostrado por (RUMELHART; HINTON ; WILLIAMS 1986):

$$\Delta w_{ji}(n+1) = \alpha \Delta w_{ji}(n) + \eta \delta_j(n+1) y_i(n+1) \quad (2.59)$$

O termo $\alpha \Delta w_{ji}(n)$ é o termo momento.

2.6.3 Modo Padrão e modo Lote (*Batch*) de Treinamento

Em aplicações práticas do algoritmo *Backpropagation* resultam muitas aplicações de um conjunto de exemplos de treinamento para *perceptrons* de múltiplas camadas. Uma “Época” é uma apresentação completa de um conjunto inteiro de treinamento. A aprendizagem *backpropagation* pode ser processada no modo “padrão” ou no modo lote (*batch*) de treinamento.

2.6.3.1 Modo padrão de treinamento

Neste modo, a atualização é executada após a apresentação de cada exemplo do conjunto de treinamento. Este é o modelo de operação para o qual o algoritmo “backpropagation” foi originalmente concebido. Considere-se uma época composta por N exemplos de treinamento, isto é, N padrões de treinamento dispostos na ordem $[x(1), d(1), x(2), d(2), \dots, x(N), d(N)]$. O primeiro exemplo $[x(1), d(1)]$, na época corrente é apresentado à rede, e as seqüências de cálculos *forward* (para a frente) e *backward* (para trás) são executadas. A seguir são executados os ajustes para os pesos sinápticos e *bias* da rede. O segundo exemplo $[x(2), d(2)]$ é apresentado à rede na mesma época e a seqüência de *forward* e *backward* é

repetida resultando um segundo ajuste de pesos sinápticos e *bias*. Este processo continua até a apresentação do último exemplo de treinamento $[x(N), d(N)]$ nesta mesma época.

2.6.3.2 Modo de Treinamento em Lote (*batch*)

Neste modo de treinamento, a atualização dos pesos é executada somente após a apresentação de todos os exemplos de treinamento que formam uma época.

Considerando que a atualização dos pesos deva ser feita após a apresentação dos N padrões de treinamento, tem-se inicialmente, como uma estimativa para as correções, a média das correções para os N padrões:

$$\hat{\Delta w_{ji}}(n) = \frac{1}{N} \sum_{n=1}^N \Delta w_{ji}(n) \quad (2.60)$$

Agora, substituindo a (2.46) na (2.60), resulta:

$$\hat{\Delta w_{ji}}(n) = \frac{1}{N} \sum_{n=1}^N \eta \delta_j(n) y_i(n) = \frac{\eta}{N} \sum_{n=1}^N \delta_j(n) y_i(n) \quad (2.61)$$

Considerando-se a regra delta dada em (2.43) e comparando com a (2.61), resulta:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -\frac{1}{N} \sum_{n=1}^N \delta_j(n) y_i(n) \quad (2.62)$$

2.6.4 Algoritmo *Resilient Propagation* (*RPROP*)

2.6.4.1 Descrição

RPROP é um processo que tem por finalidade tornar mais eficiente o algoritmo de retropropagação *backpropagation* e significa as iniciais em inglês *Resilient Propagation*. Conforme RIEDMILLER e BRAUN (1993, p. 586-591) a idéia básica do *RPROP* é eliminar a influência do tamanho das derivadas parciais nos cálculos dos pesos. Como consequência, é considerado somente o sinal da derivada parcial na atualização dos pesos. O tamanho da mudança de peso é determinado exclusivamente por um valor de atualização $\Delta_{ij}(t)$

$$\Delta w_{ji}(t) = \begin{cases} -\Delta_{ji}(t), & \text{se } \frac{\partial \varepsilon}{\partial w_{ji}}(t) > 0 \\ +\Delta_{ji}(t), & \text{se } \frac{\partial \varepsilon}{\partial w_{ji}}(t) < 0 \\ 0 & , \text{ se } \frac{\partial \varepsilon}{\partial w_{ji}}(t) = 0 \end{cases} \quad (2.63)$$

O segundo passo do aprendizado *RPROP* é determinar os novos valores atualizados $\Delta_{ji}(t)$, pela seguinte regra:

$$\Delta_{ji}(t) = \begin{cases} \eta^+ \Delta_{ji}^{(t-1)}, & \text{se } \frac{\partial \varepsilon^{(t-1)}}{\partial w_{ji}} \frac{\partial \varepsilon^{(t)}}{\partial w_{ji}} > 0 \\ \eta^- \Delta_{ji}^{(t-1)}, & \text{se } \frac{\partial \varepsilon^{(t-1)}}{\partial w_{ji}} \frac{\partial \varepsilon^{(t)}}{\partial w_{ji}} < 0 \\ \Delta_{ji}^{(t-1)} & \text{se } \frac{\partial \varepsilon^{(t-1)}}{\partial w_{ji}} \frac{\partial \varepsilon^{(t)}}{\partial w_{ji}} = 0 \end{cases} \quad (2.64)$$

onde $0 < \eta^- < 1 < \eta^+$

A regra de adaptação dos pesos trabalha do seguinte modo:

Se as derivadas parciais dos pesos correspondentes a w_{ji} mudam os seus sinais, isto indica que a última atualização foi demasiadamente grande e o algoritmo saltou para um mínimo local. Devido a isso, o valor de atualização Δ_{ji} é decrescido por um fator η^- .

Se as derivadas conservam os seus sinais, o valor de atualização é levemente incrementado na seqüência, para acelerar a convergência em regiões de mínimos locais.

Uma vez que os valores de atualização para cada peso são adaptados, a atualização dos pesos segue uma regra muito simples:

Se a derivada for positiva (erro de incremento), o peso é diminuído;

Se a derivada for negativa, o valor de atualização do peso é adicionado.

No entanto, ocorre uma exceção:

Se a derivada parcial muda de sinal, isto é, o passo anterior foi muito grande e o mínimo foi perdido, então a atualização dos pesos é revertida.

Portanto:

$$\Delta w_{ji}(t) = -\Delta w_{ji}(t-1), \text{ se } \frac{\partial \varepsilon^{(t-1)}}{\partial w_{ji}} \frac{\partial \varepsilon^{(t)}}{\partial w_{ji}} < 0 \quad (2.65)$$

O treinamento na rede é feito no modo em lote “batch”.

2.6.4.2 Pseudocódigo RPROP

O pseudocódigo mostrando o núcleo do algoritmo RPROP é:

```

{   Para todos os pesos e biases
    if  $\left( \frac{\partial \varepsilon}{\partial w_{ji}}(t-1) * \frac{\partial \varepsilon}{\partial w_{ji}}(t) > 0 \right)$  then
        {  $\Delta_{ji}(t) = \text{minimum}(\Delta_{ji}(t-1) * \eta^+, \Delta_{\text{max}})$ 
           $\Delta w_{ji}(t+1) = -\text{sign}\left(\frac{\partial \varepsilon}{\partial w_{ji}}(t)\right) * \Delta_{ji}(t)$ 
           $w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$ 
        }
    else if  $\left( \frac{\partial \varepsilon}{\partial w_{ji}}(t-1) * \frac{\partial \varepsilon}{\partial w_{ji}}(t) < 0 \right)$  then
        {    $\Delta_{ji}(t) = \text{maximum}(\Delta_{ji}(t-1) * \eta^-, \Delta_{\text{min}})$ 
           $w_{ji}(t+1) = w_{ji}(t) - \Delta w_{ji}(t)$ 
           $\frac{\partial \varepsilon}{\partial w_{ji}}(t) = 0$ 
        }
    else if  $\left( \frac{\partial \varepsilon}{\partial w_{ji}}(t-1) * \frac{\partial \varepsilon}{\partial w_{ji}}(t) = 0 \right)$  then
        {    $\Delta w_{ji}(t) = -\text{sign}\left(\frac{\partial \varepsilon}{\partial w_{ji}}(t)\right) * \Delta_{ji}(t)$ 
           $w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$ 
        }
}

```

No pseudocódigo representado anteriormente, os operadores (*maximum*) e (*minimum*) são respectivamente o mínimo (*minimum*) e o máximo (*maximum*) valor

de dois números. O operador *sign* retorna +1, se o argumento for positivo, e -1, se o argumento for negativo.

2.6.4.3 Parâmetros

Todos os valores iniciais para Δ_{ij} são iguais a um determinado Δ_0 . Para Δ_0 representar o tamanho dos primeiros acréscimos dos pesos, é preferível escolhê-los em proporção razoável ao tamanho dos pesos iniciais. Uma boa escolha pode ser $\Delta_0 = 0,1$. Para que sejam evitados problemas de *overflow/underflow*, adota-se para Δ_{\max} o valor 50,0 e Δ_{\min} o valor 0,000001. Uma boa escolha para os fatores crescente e decrescente é, respectivamente, $\eta^+ = 1,2$ e $\eta^- = 0,5$. (RIEDMILLER; BRAUN, 1993, p. 586-591).

2.6.4.4 Vantagens do Método

Em comparação a outros algoritmos de aprendizagem, no RPROP é usado somente o sinal da derivada para a atualização dos pesos e a aprendizagem. No algoritmo de retropropagação, por exemplo, todas as derivadas parciais devem ser calculadas para o processo de atualização dos pesos sinápticos. O fato de ser utilizado somente o sinal da derivada parcial economiza espaço de memória e tempo consumido de cálculos.

Outro aspecto freqüentemente discutido em processos comuns de gradientes descendentes é que os tamanhos das derivadas parciais decrescem exponencialmente com a distância entre o peso e a camada de saída, devido à influência da função de ativação sigmóide. Uma consequência disso é que na camada da saída os pesos são pouco modificados e a aprendizagem se torna lenta.

Usando RPROP, o tamanho do acréscimo do peso depende somente da seqüência dos sinais da derivadas parciais e não depende do tamanho dessas derivadas. Por esta razão, a aprendizagem é homogênea sobre toda a rede, isto é, peso próximo à entrada tem iguais chances de aprender e se adaptar, se comparado com peso próximo à camada de saída (RIEDMILLER; BRAUN, 1993, p. 586-591).

2.7 MORFOLOGIA MATEMÁTICA

Morfologia denota uma área da biologia, que trata da forma e estrutura que a matéria pode apresentar. Morfologia é composta pelas palavras gregas *morphê* (forma) e *logos* (ciência) (FACON, 1996, p.1).

A *morfologia matemática* pode ser conceituada como o estudo da forma de modelos matemáticos constituídos por estruturas geométricas de entidades presentes em uma imagem digital. De acordo com (GONZALES; WOODS, 2000, p.370) “*morfologia matemática é uma ferramenta para a extração de componentes de imagens úteis na representação e descrição da forma de uma região, como por exemplos, fronteira*”. Ainda de acordo com (FACON, 1996, p.2), “*O princípio básico da morfologia matemática consiste em extrair informações relativas à geometria e à topologia de um conjunto desconhecido de uma imagem*”. Segundo (WANGENHEIM, 2004), “*morfologia digital é um caminho para descrever ou analisar a forma de um objeto digital*”.

Há dois tipos de morfologia matemática: a morfologia binária, que se aplica sobre imagens binárias, e a morfologia em tons de cinza, que se aplica sobre imagens em níveis de cinza.

Na morfologia binária, aplicada no presente trabalho, é procurada uma configuração de pontos pretos e brancos, na vizinhança de cada *pixel* da imagem original. A morfologia age sobre imagens digitais a partir de elementos estruturantes definidos em malhas retangulares ou hexagonais exatas (FACON, 1996, p.3).

2.7.1 Elemento Estruturante

Um elemento estruturante é um conjunto completamente definido e conhecido em sua forma e tamanho, que é comparado ao conjunto desconhecido da imagem a partir de uma transformação. O formato e o tamanho do elemento estruturante permitem testar de que maneira este elemento estruturante está ou não contido na imagem (FACON, 1996, p.2). Um elemento estruturante é definido pelos *pixels* que o formam. FACON, (1996, p. 13) caracteriza um *pixel* inativo ou neutro marcado com “.” e em *pixel* ativo marcado com “•”. O *pixel* inativo não interage com o conjunto imagem e o *pixel* ativo desenvolve um papel de interação com a imagem. O resultado dessa interação define uma posição específica, a do ponto central do

elemento estruturante, na imagem, no momento da ação. A seguir, representa-se um elemento estruturante B .

$$B = \begin{Bmatrix} \cdot & \bullet & \cdot \\ \bullet & \cdot & \bullet \\ \cdot & \bullet & \cdot \end{Bmatrix}$$

O símbolo “()” representa a posição central do elemento estruturante. Quando o ponto central do elemento estruturante coincide com o seu centro físico, não há a necessidade de ser inserida a notação “()”. Isto é mostrado na representação a seguir (FACON, 1996, p.14):

$$B = \begin{Bmatrix} \cdot & \bullet & \cdot \\ \bullet & \cdot & \bullet \\ \cdot & \bullet & \cdot \end{Bmatrix} = \begin{Bmatrix} \cdot & \bullet & \cdot \\ \bullet & (\cdot) & \bullet \\ \cdot & \bullet & \cdot \end{Bmatrix}$$

Uma imagem digital binária X contém dois tipos de informação, o fundo (representado por “.”) e os *pixels* relevantes (representados por “•”). Na forma digital, uma imagem X é representada entre “[]”, como no exemplo a seguir:

$$X = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix}$$

2.7.2 Definições Básicas

A teoria básica de conjuntos é aplicada em morfologia matemática. Os conjuntos representam as formas dos objetos em uma imagem. Sendo Z o conjunto dos números inteiros, Z^2 é o conjunto de todos os pares ordenados (a,b) com a e b sendo elementos de Z . Desta forma, sejam A e B subconjuntos de Z^2 , com componentes $a = (a_1, a_2)$, respectivamente. A *translação* de A por $x = (x_1, x_2)$, é definida por (GONZALES;WOODS, 2000,p.370):

$$(A)_x = \{c / c = a + x, \forall a \in A\} \quad (2.66)$$

A reflexão de B , denotada por \hat{B} , é definida por

$$\hat{B} = \{x / x = -b, \forall b \in B\} \quad (2.67)$$

O complemento do conjunto A é definido como

$$A^c = \{x/x \notin A\} \quad (2.68)$$

A diferença entre dois conjuntos A e B é definida por

$$A - B = \{x/x \in A, x \notin B\} = A \cap B^c \quad (2.69)$$

2.7.3 Dilatação

Considere-se A e B dois conjuntos não-vazios contidos em Z^2 e ϕ o conjunto vazio. A dilatação de A por B , denotada por $A \oplus B$, é definida por:

$$A \oplus B = \{x/(\hat{B})_x \cap A \neq \phi\} \quad (2.70)$$

Segundo (WANGENHEIM, 2004), dilatação é uma operação morfológica que combina dois conjuntos usando adição vetorial. Como o nome sugere, o resultado da dilatação é uma imagem maior do que a original. A dilatação de um conjunto A pelo conjunto B pode, portanto, ser definida alternativamente por:

$$A \oplus B = \{c/c = a + b, a \in A, b \in B\} \quad (2.71)$$

Nas equações (2.70) e (2.71), A representa a imagem sendo operada e B é o elemento estruturante, e sua composição define a natureza da dilatação.

Sejam os conjuntos A e B definidos como pares ordenados de uma imagem binária formada apenas por *pixels* brancos e pretos. Por exemplo, se o conjunto $A = \{(1,1), (1,2), (2,1), (2,2)\}$ representa posições de *pixels* pretos e $B = \{(0,0), (1,0)\}$ representa o elemento estruturante, então a dilatação de A por B é obtida com a partir da definição:

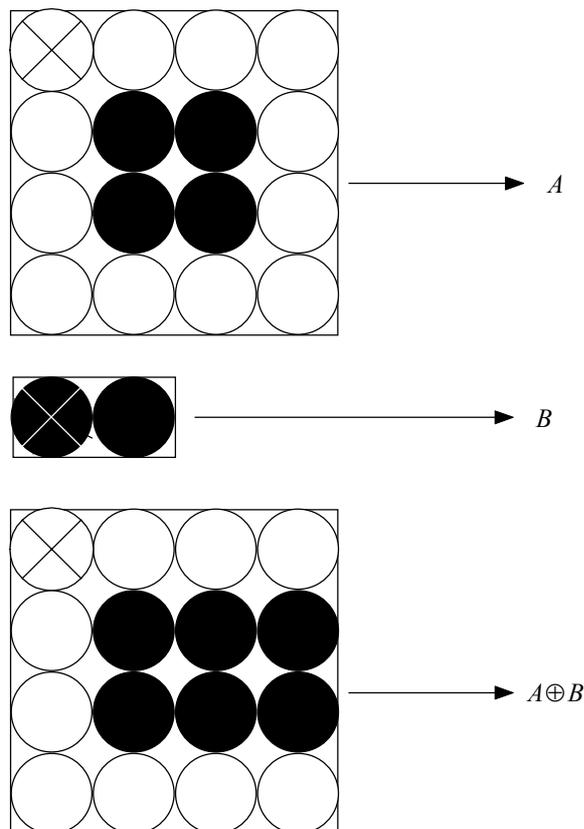
$$A \oplus B = \{A + \{(x_1 \in B)\} \cup A + \{(x_2 \in B)\}\} \quad (2.72)$$

Para este exemplo, a equação (2.72) pode ser reescrita como:

$$\begin{aligned} A \oplus B &= \{A + \{(0,0)\} \cup A + \{(1,0)\}\} \\ A + \{(0,0)\} &= \{(1,1) + (0,0), (1,2) + (0,0), (2,1) + (0,0), (2,2) + (0,0)\} = \{(1,1), (1,2), (2,1), (2,2)\} \\ A + \{(1,0)\} &= \{(1,1) + (1,0), (1,2) + (1,0), (2,1) + (1,0), (2,2) + (1,0)\} = \{(2,1), (2,2), (3,1), (3,2)\} \\ A \oplus B &= \{(1,1), (1,2), (2,1), (2,2), (3,1), (3,2)\}. \end{aligned}$$

Na Figura 2.19 estão representados os conjuntos A , elemento estruturante B e o conjunto dilatação $A \oplus B$. O "pixel" marcado com um "x" representa a origem (0,0) de cada imagem.

FIGURA 2.19 - EXEMPLO DE DILATAÇÃO



FONTE: (WANGENHEIM, 2004).

2.7.4 Erosão Binária

Para dois conjuntos A e B em Z^2 , a erosão binária de A por B , de acordo com (GONZALES;WOODS, 2000, p.372) e (FACON, 1996, p.15), é definida por:

$$A \ominus B = \{x / (B)_x \subseteq A\} \quad (2.73)$$

A (2.73) significa que a erosão de A por B é o conjunto de todos os pontos x tais que B , quando transladado por x , fique contido em A . A erosão basicamente diminui o tamanho de uma imagem. Pode ser vista como uma transformação morfológica que combina dois conjuntos usando vetores de subtração. A erosão da imagem A pelo elemento estruturante B pode ser definida como (WANGENHEIM, 2004, p.56):

$$A \ominus B = \{x | x + b \in A \forall b \in B\} \quad (2.74)$$

A seguir, mostra-se um exemplo simples de erosão binária, representada na

Figura 2.21 .Seja em uma imagem o conjunto A , dado por quatro "pixels" pretos $A = \{(1,1), (1,2), (2,1), (2,2)\}$ e o elemento estruturante $B = \{(0,0), (1,0)\}$. O conjunto $A \ominus B$ é o conjunto de translações de B que alinham B sobre o conjunto de "pixels" pretos em A . Isso significa que nem todas as translações necessitam ser consideradas, mas somente aquelas que inicialmente localizam sua origem de B em um membro de A . Existem quatro dessas translações (WANGENHEIM, 2004, p.56), que são obtidas com a aplicação da fórmula (2.74) e representadas na Figura 2.20:

$B_{(1,1)} = \{(0+1,0+1), (1+1,0+1)\} = \{(1,1), (2,1)\}$. Sendo os *pixels* $(1,1)$ e $(2,1)$ pretos na imagem A , o "pixel" $(1,1)$ no resultado será preto.

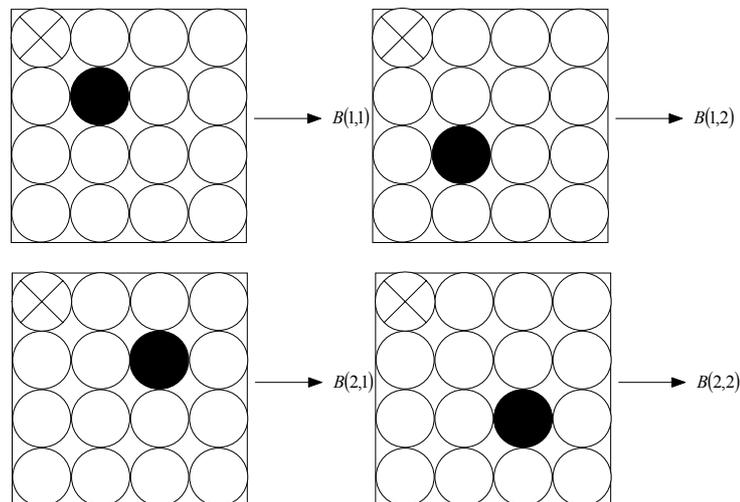
$B_{(1,2)} = \{(0+1,0+2), (1+1,0+2)\} = \{(1,2), (2,2)\}$. Sendo os *pixels* $(1,2)$ e $(2,2)$ pretos na imagem A , o "pixel" $(1,2)$ no resultado será preto.

$$B_{(2,1)} = \{(0+2,0+1), (1+2,0+1)\} = \{(2,1), (3,1)\}$$

$$B_{(2,2)} = \{(0+2,0+2), (1+2,0+2)\} = \{(2,2), (3,2)\}$$

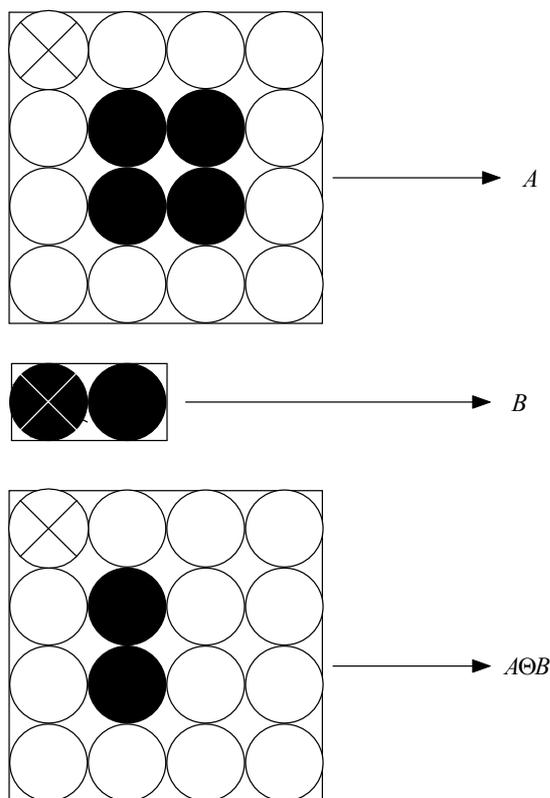
Usando agora a fórmula (2.73), encontra-se a erosão procurada:

FIGURA 2.20 - TRANSLAÇÕES DA EROSIÃO BINÁRIA



FONTE: (WANGENHEIM, 2004).

FIGURA 2.21 - EXEMPLO DE EROSAÃO BINÁRIA



FONTE: (WANGENHEIM, 2004).

2.8 REFERENCIAIS FOTOGRAFAMÉTRICOS

De acordo com (ANDRADE, 1998, p. 79), em Fotogrametria são utilizados referenciais fotogramétricos bidimensionais ou tridimensionais. Nos dois casos, esses referenciais sempre estão ligados a instrumentos. A materialização dos referenciais depende de calibração envolvendo a medição de coordenadas de pontos.

2.8.1 Sistema Fiducial

Durante a tomada de fotos aéreas, são gravadas no filme marcas de pontos denominadas marcas fiduciais. Essas marcas permitem materializar o sistema de coordenadas fiduciais. A calibração das marcas fiduciais define o sistema fiducial. Um sistema de coordenadas fiduciais usual é apresentado na FIGURA 2.22.

FIGURA 2.22 – SISTEMA DE COORDENADAS FIDUCIAIS

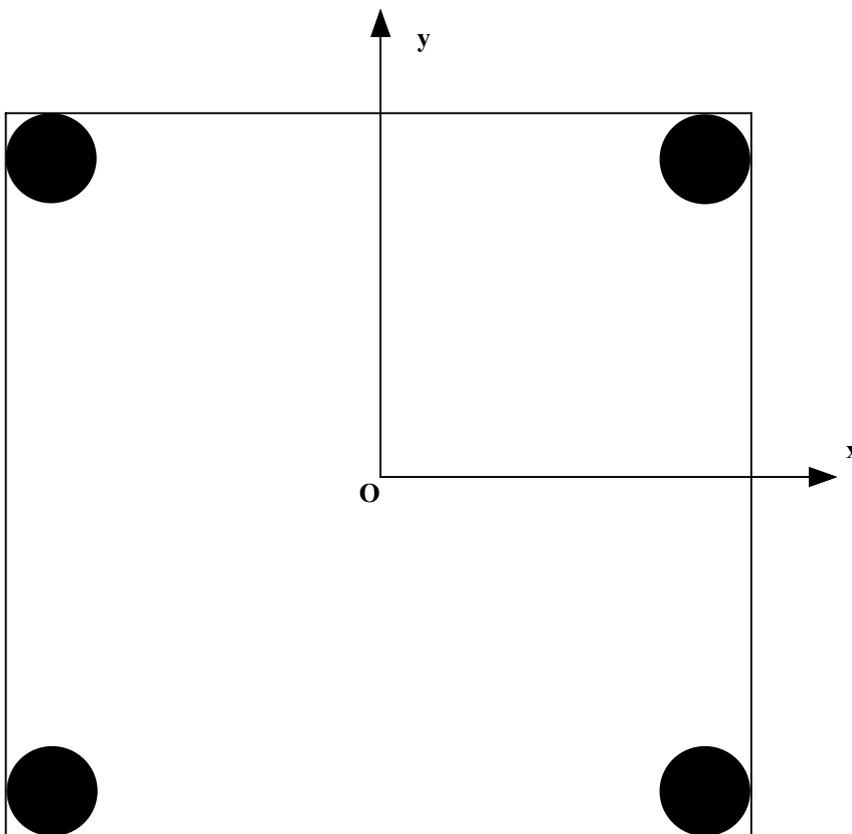


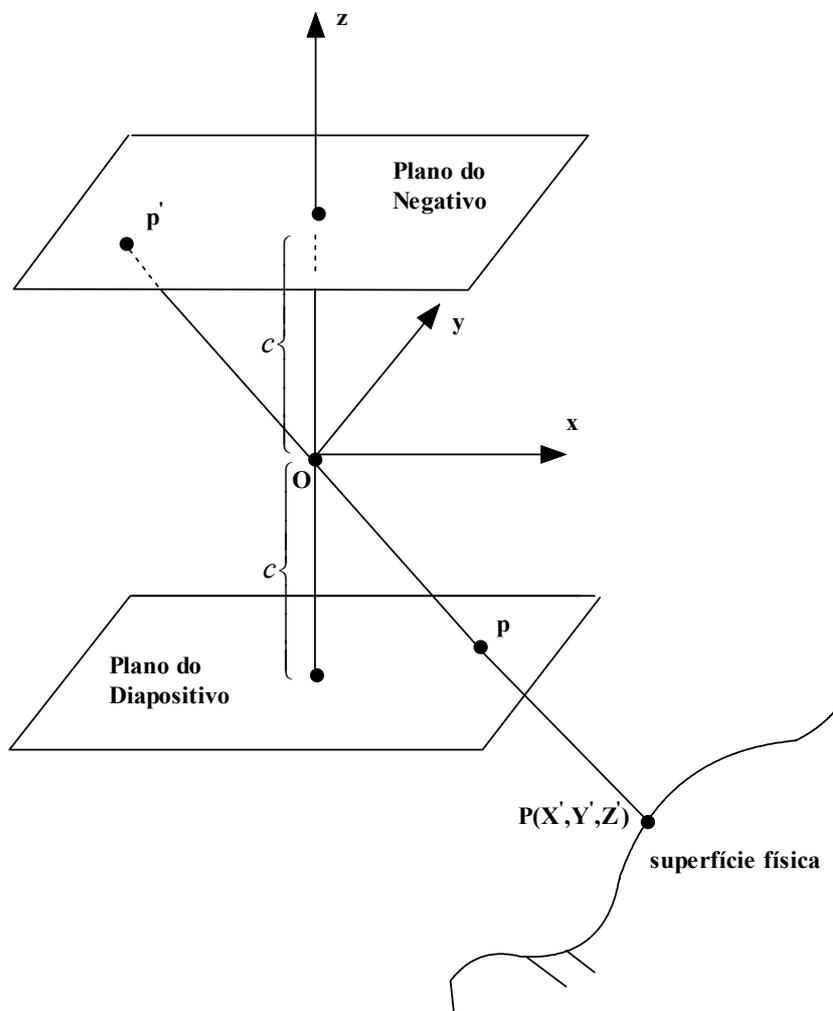
FIGURA 2.22 apresenta os seguintes elementos:

- a intersecção das diagonais define a origem **O** do sistema (centro fiducial);
- a direção do eixo **Ox** define a direção do voo;
- os eixos **Ox** e **Oy** são perpendiculares e formam um sistema dextrógiro de coordenadas.

2.8.2 Sistema Fotogramétrico

O sistema fotogramétrico é mostrado na FIGURA 2.23 (ANDRADE, 1998, p. 81)

FIGURA 2.23 – SISTEMA FOTOGRAMÉTRICO



FONTE: (Adaptado de ANDRADE, 1998, p.81).

Na FIGURA 2.23 estão representados:

A distância focal da câmera: c ;

O ponto imagem: p' ou p , conforme se trabalha no plano do negativo ou o plano do diapositivo;

O ponto objeto P , na superfície física.

O sistema de Coordenadas Fotogramétricas é definido da seguinte maneira (ANDRADE, 1998, p. 81):

O “centro de perspectiva” é a origem O ;

Os eixos Ox e Oy são paralelos aos seus homônimos no sistema fiducial e orientados da mesma forma;

O eixo **Oz** é perpendicular ao plano do negativo e forma com os eixos **Ox** e **Oy** um sistema dextrógiro de coordenadas.

2.9 FOTOTRIANGULAÇÃO

2.9.1 Conceitos

Segundo ANDRADE (1998, p. 105), *Fototriangulação é uma técnica fotogramétrica para a determinação de coordenadas de pontos num referencial específico.*

A Fototriangulação com fotografias aéreas recebe as denominações de Aerotriangulação, Triangulação Aérea ou Triangulação Espacial.

Até um passado recente, a Fotogrametria utilizava equipamentos mecânicos de solução analógica para a fototriangulação. Os equipamentos eram de grande porte, alta durabilidade, porém de custos elevados.

O desenvolvimento científico e tecnológico nas áreas de eletrônica e informática propicia hoje soluções precisas, econômicas e rápidas. Os microcomputadores substituem as operações mecânicas, possibilitando, para a fototriangulação, o uso da Fotogrametria analítica com enfoque digital.

Ainda segundo ANDRADE (1998, p.106), muitos métodos e equipamentos foram desenvolvidos ao longo da história da Fotogrametria, com o objetivo de alcançar a mais alta precisão, aliada ao mais baixo custo na determinação de coordenadas, porém os equipamentos mecânicos permitiam alta precisão e eram suficientemente robustos para durar longos anos, mas extremamente caros. Os registradores mecânicos de coordenadas foram gradativamente sendo substituídos por equipamentos eletrônicos e ligados a microcomputadores. A seguir, surgiram equipamentos analíticos, cuja parte mecânica foi drasticamente reduzida.

Atualmente, o microcomputador substitui tudo com inúmeras vantagens, no que se refere a custos, versatilidade e precisão. Pelo objetivo do presente trabalho, tratar-se-á aqui apenas da Fototriangulação Analítica com enfoque digital.

2.9.2 Planejamento e Sistemas de Coordenadas

Em um projeto de serviços cartográficos, o planejamento da fototriangulação deve ter início já no planejamento da cobertura fotográfica (ANDRADE, 1998, p. 107). Devem ser previstas, principalmente, quantidades de pontos de controle de campo, escala média das aerofotos e número de faixas.

2.9.3 Coleta de Dados

As operações de coleta de dados com fotos digitais são (ANDRADE, 1998, p. 118):

- a) escolha dos pontos fotogramétricos e de apoio;
- b) marcação dos pontos fotogramétricos;
- c) transferência dos pontos fotogramétricos;
- d) medição de coordenadas;
- e) correção de erros sistemáticos.

No processo de fototriangulação, são envolvidos três tipos de pontos: marcas fiduciais, pontos de apoio e pontos fotogramétricos.

As marcas fiduciais são sinais definidos e com localização bem conhecida em uma imagem, e permitem recuperar a geometria projetiva da foto.

Os pontos de apoio podem ser pré-sinalizados ou naturais, como, por exemplo, canto de edificações. Neste trabalho, são apresentados pontos de apoio pré-sinalizados ou naturais confeccionados nos arruamentos da área de testes. São ao todo 32 pontos, sendo 16 em forma circular e 16 em forma de “cruz”, conforme apresentado na FIGURA 2.24 e na FIGURA 2.25.

Pontos pré-sinalizados são os pontos com coordenadas conhecidas no referencial fotogramétrico e geodésico local, naturais ou artificiais, que podem ser empregados para a orientação exterior do modelo aerofotogramétrico.

FIGURA 2.24 – PONTO PRÉ-SINALIZADO CIRCULAR



FIGURA 2.25 – PONTO PRÉ-SINALIZADO EM CRUZ

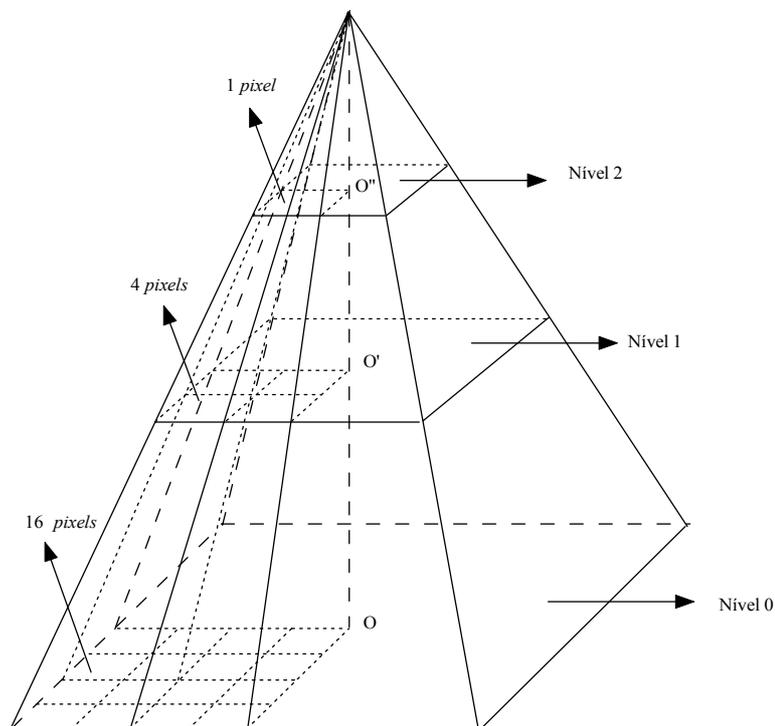


2.9.4 Ferramentas para a Identificação Automática de Pontos

A identificação automática dos pontos marcas fiduciais e pontos de apoio pré-sinalizados será feita neste trabalho utilizando-se Correlação e RNA.

Uma ferramenta para se conseguir valores aproximados da posição dos pontos pré-sinalizados é conhecida como *pirâmide de imagens*. A pirâmide de imagens consiste de um conjunto de imagens derivadas da imagem original, cada uma com um grau de resolução menor. Por exemplo: a partir de uma imagem original, denominada de nível 0, obtém-se uma segunda imagem cujos *pixels* são formados pela média aritmética de 4 *pixels* contíguos da imagem original, que se denomina de imagem no nível 1. A partir da imagem no nível1, pode ser obtida uma terceira chamada de nível 2, da mesma forma anterior, e assim sucessivamente. A última imagem forma o vértice da pirâmide, sendo que a base é a imagem original. Uma pirâmide de imagens está mostrada na FIGURA 2.26. Nesta figura, está mostrado que 16 *pixels* na imagem em nível 0 são transformados em 4 *pixels* na imagem em nível 1 e estes transformados em 1 *pixel* na imagem em nível 2.

FIGURA 2.26 – PIRÂMIDE DE IMAGENS



2.9.5 Automatização na Leitura das Marcas Fiduciais

Para que a leitura e a identificação de coordenadas de pontos fique automatizada, a primeira providência é a obtenção da posição aproximada desses pontos.

O certificado de calibração da câmara fornece as coordenadas das marcas fiduciais. Transformam-se as coordenadas das marcas fiduciais para as coordenadas de imagem. Esta transformação resulta em uma primeira aproximação para as coordenadas das marcas fiduciais na imagem aerofotográfica.

No presente trabalho, as marcas fiduciais estão contidas em janelas de 101 por 101 *pixels*. Esta então deve ser a matriz de amostra da imagem representativa da marca fiducial, se for utilizado o método de correlação estatística para identificação da mesma. As dimensões da matriz de busca podem ser, por exemplo, 200 *pixels* por 200 *pixels*, devido ao grau de incerteza do valor aproximado das coordenadas da marca fiducial que se deseja identificar e medir. Desloca-se agora a imagem de amostra sobre a imagem de busca *pixel a pixel*. A cada deslocamento calcula-se a correlação existente entre a matriz de amostra e a matriz candidata. A

posição que mostrar a maior correlação é onde se encontra o possível centro da marca fiducial (PIECHEL, 1991).

2.9.6 Identificação e Medição Automática de Pontos de Apoio Naturais

Os pontos de apoio naturais são levantados em feições foto-identificáveis que definam um ponto, tais como cantos de edificações, de cercas, de muros, de jardins, de cruzamentos, etc, ou em sinais colocados no terreno antes das aerofotos serem tomadas (ANDRADE, 1998, p. 128).

Obter padrões de feições que definam os pontos de controle é uma tarefa difícil, bem como achar automaticamente a sua posição aproximada na imagem.

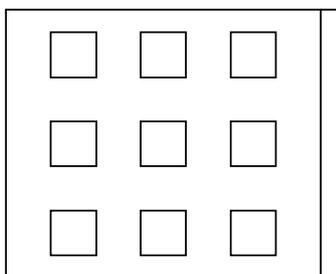
Um procedimento semelhante ao descrito para as marcas fiduciais pode ser realizado, com os métodos de correlação ou RNA, onde a matriz de amostra é aquela que contém o ponto de controle identificado numa das imagens pelo operador.

2.9.7 Identificação e Medição Automática dos Pontos Fotogramétricos

Para a transferência de pontos de uma foto para o seu homólogo na outra, a primeira etapa é a determinação de coordenadas fotogramétricas aproximadas. Isto pode ser realizado com o conhecimento do recobrimento longitudinal (ANDRADE, 1998, p. 129).

As matrizes de amostra dos pontos fotogramétricos devem situar-se em áreas ao entorno das posições dos pontos de Von Grüber, como mostrado na FIGURA 2.27.

FIGURA 2.27- MATRIZES DE AMOSTRA DOS PONTOS FOTOGAMÉTRICOS



FONTE: (ANDRADE, 1998, p. 118).

As matrizes de amostra devem ter de preferência um número ímpar de linhas e colunas, facilitando desta forma a localização do “pixel” central.

Conforme (FRITSCH, 1995, p. 173) e (FÖERSTNER, 1995, p. 165), para definir as matrizes de busca, torna-se necessário obter valores aproximados das coordenadas do ponto procurado. Os valores aproximados que se obtêm com dados aproximados de superposição não são muito bons e isso acarreta uma matriz de busca relativamente grande, provocando, em conseqüência, um volume muito alto de cálculos (ANDRADE, 1998, p. 130). Segundo (TSINGAS, 1991), (AGOURIS, 1992), (TOTH; AMMON, 1996, p.711-717), (KRUPNIK, 1996, p.1151-1155), e (KRZYSZEK, 1995), a estratégia, neste caso, deve ser a do uso da técnica da pirâmide de imagens, já descrita anteriormente.

2.9.8 Modelo Matemático da Aerotriangulação Analítica

O modelo matemático usual nos procedimentos fotogramétricos analíticos ou digitais é constituído pelas equações de colinearidade. Da condição de alinhamento dos pontos objeto (P), imagem (p) ou e centro de perspectiva (O), na FIGURA 2.31 e após a aplicação de transformações do espaço imagem no espaço objeto, tem-se, conforme ANDRADE (1998, p.84):

$$\begin{cases} x = -f \frac{m_{11}(X - X_0) + m_{12}(Y - Y_0) + m_{13}(Z - Z_0)}{m_{31}(X - X_0) + m_{32}(Y - Y_0) + m_{33}(Z - Z_0)} \\ y = -f \frac{m_{21}(X - X_0) + m_{22}(Y - Y_0) + m_{23}(Z - Z_0)}{m_{31}(X - X_0) + m_{32}(Y - Y_0) + m_{33}(Z - Z_0)} \end{cases} \quad (2.75)$$

onde:

$$\begin{cases} m_{11} = \cos \varphi \cos \chi \\ m_{12} = \cos \omega \sin \chi + \sin \omega \sin \varphi \cos \chi \\ m_{13} = \sin \omega \sin \chi - \cos \omega \sin \varphi \cos \chi \\ m_{21} = -\cos \varphi \sin \chi \\ m_{22} = \cos \omega \cos \chi - \sin \omega \sin \varphi \sin \chi \\ m_{23} = \sin \omega \cos \chi + \cos \omega \sin \varphi \sin \chi \\ m_{31} = \sin \varphi \\ m_{32} = -\sin \omega \cos \varphi \\ m_{33} = \cos \omega \cos \varphi \end{cases} \quad (2.76)$$

x e y são as coordenadas do ponto p no referencial do espaço imagem;

X, Y, Z são as coordenadas de pontos do espaço objeto no referencial geodésico local.

X_0, Y_0, Z_0 são coordenadas dos centros de perspectiva (origem do sistema fotogramétrico) referidas ao referencial geodésico local (ANDRADE, 1998, p. 75);

(ω, φ, χ) = ângulos eulerianos que representam os parâmetros de rotação da orientação exterior;

f é a distância focal da câmara aérea.

2.9.9 Erros Sistemáticos da Imagem Fotogramétrica

As equações de colinearidade são deduzidas com a condição matemática de que o ponto imagem, o centro de projeção e o ponto objeto estejam alinhados (colineares). No entanto, na prática esta condição não permanece, pela existência de erros sistemáticos, alterando as posições do ponto imagem ou do raio incidente de luz.

2.9.9.1 Orientação interior

A orientação interior tem como objetivo recuperar a geometria projetiva da imagem, com a transformação do referencial de imagem para o referencial fiducial. A orientação interior pode ser realizada utilizando-se modelos matemáticos, conforme seja o número de marcas fiduciais.

No caso de aerofotos com quatro marcas fiduciais, o indicado é a transformação afim geral no plano (ANDRADE, 1998, p.100), na sua forma geral, dada pela equação:

$$\begin{pmatrix} x \\ y \end{pmatrix}_{im} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix}_{fid} + \begin{pmatrix} x_0 \\ y_0 \end{pmatrix} \quad (2.77)$$

onde $\begin{pmatrix} x \\ y \end{pmatrix}_{im}$ são as coordenadas no referencial de imagem observadas, $\begin{pmatrix} x \\ y \end{pmatrix}_{fid}$ são as coordenadas fotogramétricas corrigidas e $(a_{11}, a_{12}, a_{21}, a_{22}, x_0, y_0)$ são os parâmetros incógnitos da transformação.

Uma análise do modelo matemático mostrado na equação (2.77), admitindo que as coordenadas no referencial fiducial $\begin{pmatrix} x \\ y \end{pmatrix}_{fid}$ tenham variância nula, permite concluir que este é um modelo linear de ajustamento paramétrico do tipo $L_a = F(X_a)$, cuja solução obtida pelo método dos mínimos quadrados é:

$$X_a = (A^T A)^{-1} A^T L_b \quad (2.78)$$

sendo que X_a , mostrado na equação (2.79), é o vetor dos seis parâmetros ajustados, A é a matriz das derivadas parciais para linearizar o modelo, mostrada na (2.82). Por ser neste caso o modelo já linear, a matriz A é obtida com os coeficientes dos parâmetros da (2.77). Como são quatro as marcas fiduciais, serão oito os valores observados, então o vetor L_b dos valores observados, está representado na equação (2.81). A matriz A , com oito linhas e seis colunas, é apresentada na equação (2.82).

$$X_a = (x_0 \quad y_0 \quad a_{11} \quad a_{12} \quad a_{21} \quad a_{22})^T \quad (2.79)$$

$$A = \frac{\partial L_a}{\partial (x_0, y_0, a_{11}, a_{12}, a_{21}, a_{22})} \quad (2.80)$$

$$L_b = (x_1 \quad y_1 \quad x_2 \quad y_2 \quad x_3 \quad y_3 \quad x_4 \quad y_4)^T \quad (2.81)$$

$$A = \begin{pmatrix} 1 & 0 & x_1 & 0 & y_1 & 0 \\ 0 & 1 & 0 & x_1 & 0 & y_1 \\ 1 & 0 & x_2 & 0 & y_2 & 0 \\ 0 & 1 & 0 & x_2 & 0 & y_2 \\ 1 & 0 & x_3 & 0 & y_3 & 0 \\ 0 & 1 & 0 & x_3 & 0 & y_3 \\ 1 & 0 & x_4 & 0 & y_4 & 0 \\ 0 & 1 & 0 & x_4 & 0 & y_4 \end{pmatrix} \quad (2.82)$$

Com o conhecimento dos 6 parâmetros, as coordenadas das marcas fiduciais corrigidas podem ser obtidas a partir da transformação inversa da (2.77):

$$\begin{pmatrix} x \\ y \end{pmatrix}_{corr} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}^{-1} \begin{pmatrix} x - x_0 \\ y - y_0 \end{pmatrix}_{obs} \quad (2.83)$$

Para aerofotos com oito marcas fiduciais, pode ser utilizada a transformação projetiva no plano:

$$x_{f_i} = \frac{a_1 x_i + a_2 y_i + a_3}{a_4 x_i + a_5 y_i + 1}$$

$$y_{f_i} = \frac{a_6 x_i + a_7 y_i + a_8}{a_4 x_i + a_5 y_i + 1}$$
(2.84)

Para aerofotos com mais de oito marcas fiduciais, a transformação polinomial é adequada.

$$x_{f_i} = a_0 + a_1 x_i + a_2 y_i + a_3 x_i y_i + a_4 x_i^2 + a_5 y_i^2$$

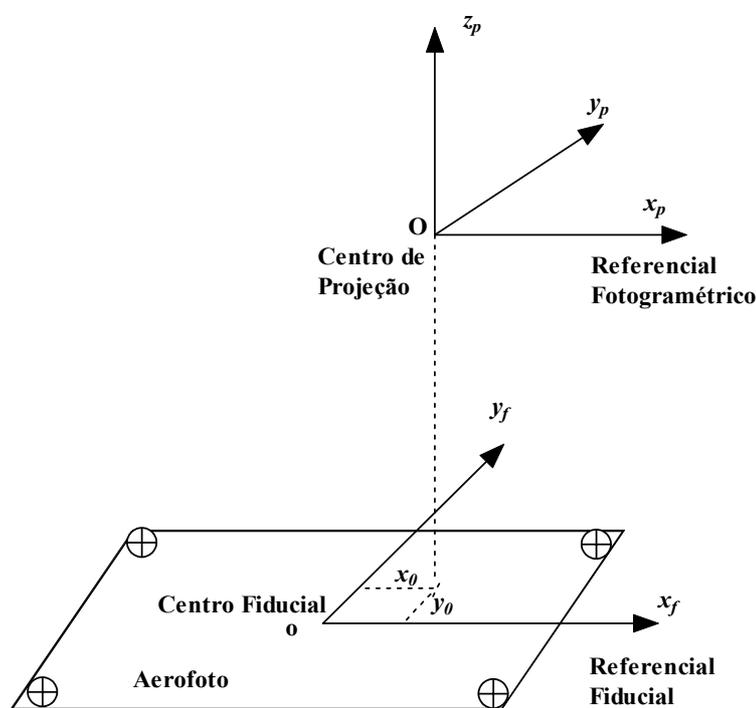
$$y_{f_i} = b_0 + b_1 x_i + b_2 y_i + b_3 x_i y_i + b_4 x_i^2 + b_5 y_i^2$$
(2.85)

Depois de corrigidas da deformação do filme, as coordenadas devem ser referidas ao referencial fotogramétrico por meio da translação:

$$x_{p_i} = x_{f_i} - x_0$$

$$y_{p_i} = y_{f_i} - y_0$$
(2.86)

FIGURA 2.28 – DISPOSIÇÃO DO REFERENCIAL FOTOGRAMÉTRICO NUMA AEROFOTO



FONTE: (MITISHITA, 1997, p. 43).

As coordenadas do ponto principal (x_0, y_0) no referencial fiducial materializam o referencial fotogramétrico (MITISHITA, 1997, p.43). Os valores de x_0 e y_0 são determinados por calibração de câmaras e se encontram no certificado de calibração.

As coordenadas no referencial fotogramétrico são (x_p, y_p, z_p) , onde z_p é constante e igual à distância focal da câmara, positiva ou negativa, conforme a observação fotogramétrica seja no negativo ou diapositivo, respectivamente. Em aplicações fotogramétricas em geral, somente as coordenadas planas (x_p, y_p) são utilizadas.

2.9.9.2 Deformação do filme

A deformação do filme é o erro sistemático que desloca o ponto imagem, provocado por deformações no filme devido às variações de temperatura, pressão, umidade relativa do ar, tensões a que o filme é submetido, envelhecimento devido ao intervalo de tempo entre a tomada de foto e da utilização das aerofotos.

2.9.9.3 Distorções das lentes

O processo de fabricação do sistema de lentes da objetiva apresenta duas falhas que acarretam imperfeições nas imagens fotográficas (MITISHITA, 1997, p.40).

Uma das falhas está na impossibilidade de se construir uma lente na forma ideal de um parabolóide de revolução. O que se fabrica é uma lente com superfície esférica. Isso provoca imperfeições na imagem. Tais imperfeições foram estudadas por Seidel, que as definiu como as cinco aberrações monocromáticas (MERCHANT, 1978, p. 4-11): aberração esférica, coma, curvatura de campo, astigmatismo, e distorção.

A outra falha tem origem na montagem das objetivas. Ocorre que nessa montagem é impossível ao fabricante alinhar perfeitamente os eixos ópticos das lentes, resultando com isso um deslocamento da imagem, que é denominado de *distorção descentrada* (ANDRADE, 1998, p.97).

2.9.9.3.1 Distorção radial simétrica

De acordo com (ANDRADE, 1998, p. 91), a distorção radial simétrica é a parcela não desejável da refração sofrida por um raio de luz ao atravessar um sistema de lentes. O modelo matemático para corrigir as observações fotogramétricas da distorção radial foi desenvolvido por Conrady, em 1929. O desenvolvimento deste modelo é apresentado em (ANDRADE, 1998, p.91-97). O resultado desse desenvolvimento conduz às fórmulas para a correção do erro da distorção radial simétrica:

$$\begin{cases} \delta x_s = (K_0 + K_1.r^2 + K_2.r^4 + K_3.r^6)x_p \\ \delta y_s = (K_0 + K_1.r^2 + K_2.r^4 + K_3.r^6)y_p \\ r = \sqrt{x_p^2 + y_p^2} \end{cases} \quad (2.87)$$

Na equação (2.87), δx_s e δy_s representam as componentes da distorção radial simétrica, δr representada na FIGURA 2.29, e x_p e y_p são as coordenadas no referencial fotogramétrico.

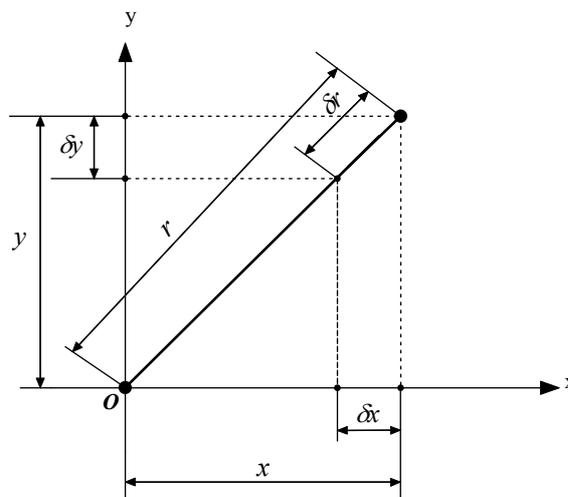
As coordenadas no referencial fotogramétrico corrigidas da distorção radial simétrica são então calculadas por:

$$\begin{bmatrix} x_{ps} \\ y_{ps} \end{bmatrix} = \begin{bmatrix} x_p \\ y_p \end{bmatrix} - \begin{bmatrix} \delta x_s \\ \delta y_s \end{bmatrix} \quad (2.88)$$

Na equação (2.87), os parâmetros K_0, K_1, K_2, K_3 , descrevem a distorção radial simétrica, para a distância focal calibrada, obtidos do certificado de calibração da câmera (ANDRADE, 1998, p.97).

Na equação (2.88) x_{ps} e y_{ps} representam as coordenadas no referencial fotogramétrico, corrigidas da distorção radial simétrica.

FIGURA 2.29 - COMPONENTES DA DISTRORÇÃO RADIAL SIMÉTRICA



FONTE: (ANDRADE, 1998, p. 96).

2.9.9.3.2 Distorção descentrada

Com base no modelo de Conrady, de 1929, Brown, em 1966, desenvolveu o modelo matemático para a distorção descentrada, que passou a se chamar de modelo de “Conrady e Brown”.

Detalhes do desenvolvimento do modelo matemático desta distorção são encontrados em (ANDRADE, 1998, p.97-99). O resultado deste desenvolvimento conduz às fórmulas para a correção do erro da distorção descentrada:

$$\begin{cases} \delta x_d = P_1(r^2 + 2x_{ps}^2) + 2.P_2.x_{ps}.y_{ps} \\ \delta y_d = P_2(r^2 + 2x_{ps}^2) + 2.P_1.x_{ps}.y_{ps} \\ r = \sqrt{x_{ps}^2 + y_{ps}^2} \end{cases} \quad (2.89)$$

Na equação (2.89) δx_d e δy_d são as componentes da distorção descentrada.

As coordenadas do sistema fotogramétrico corrigidas da distorção descentrada são então calculadas na equação (2.90).

Os parâmetros (P_1, P_2) da equação (2.89) são obtidos a partir do certificado de calibração da câmera.

$$\begin{bmatrix} x_{pd} \\ y_{pd} \end{bmatrix} = \begin{bmatrix} x_{ps} \\ y_{ps} \end{bmatrix} - \begin{bmatrix} \delta x_d \\ \delta y_d \end{bmatrix} \quad (2.90)$$

Na equação (2.90) x_{pd} e y_{pd} representam as coordenadas no referencial fotogramétrico, corrigidas da distorção descentrada.

2.9.9.4 Refração fotogramétrica

Um raio de luz teoricamente tem uma trajetória linear. No entanto, o raio de luz sofre deslocamento da trajetória colinear, ao percorrer a distância que separa o centro óptico da câmara ao ponto objeto, devido às variações dos índices de refração atmosférica (ANDRADE, 1998, p.84-89).

Na FIGURA 2.30, está representado o efeito da refração fotogramétrica na imagem fotográfica com os seus elementos. Nessa figura, ε representa a refração fotogramétrica; δ_r , o deslocamento radial da imagem devido à refração fotogramétrica; α , o ângulo nadiral; c , a distância focal; H , a altura de vôo; h_p , a altitude do ponto P; PP o ponto principal; P' a imagem do ponto P sem a consideração da refração fotogramétrica e P'', a imagem do ponto P considerando a refração fotogramétrica.

As fórmulas para corrigir os efeitos da refração fotogramétrica estão deduzidas em (ANDRADE, 1998, p.85-89). Essas fórmulas são:

$$\begin{cases} \delta x_r = x_{pd} \cdot \left(1 + \frac{r^2}{c^2}\right) \varepsilon_{45} \\ \delta y_r = y_{pd} \cdot \left(1 + \frac{r^2}{c^2}\right) \varepsilon_{45} \\ r = \sqrt{x_{pd}^2 + y_{pd}^2} \end{cases} \quad (2.91)$$

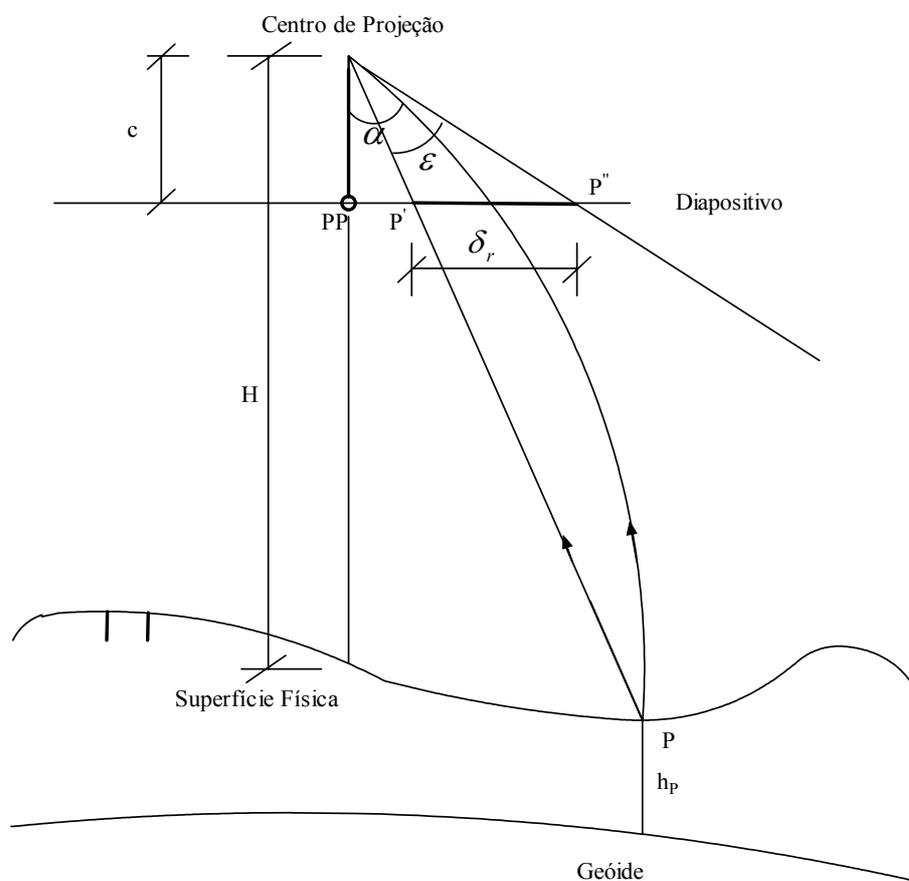
As coordenadas corrigidas da refração fotogramétrica são:

$$\begin{bmatrix} x_{pr} \\ y_{pr} \end{bmatrix} = \begin{bmatrix} x_{pd} \\ y_{pd} \end{bmatrix} - \begin{bmatrix} \delta x_r \\ \delta y_r \end{bmatrix} \quad (2.92)$$

Nas equações (2.91) e (2.92), δx_r e δy_r representam as componentes da refração fotogramétrica. Na equação (2.92), x_{pr} e y_{pr} representam as coordenadas no referencial fotogramétrico corrigidas da refração fotogramétrica.

Na equação (2.91), o termo ε_{45} representa o parâmetro de refração fotogramétrica média para um ângulo nadiral de 45 graus.

FIGURA 2.30 – EFEITO DA REFRAÇÃO FOTOGRAMÉTRICA NA IMAGEM FOTOGRÁFICA



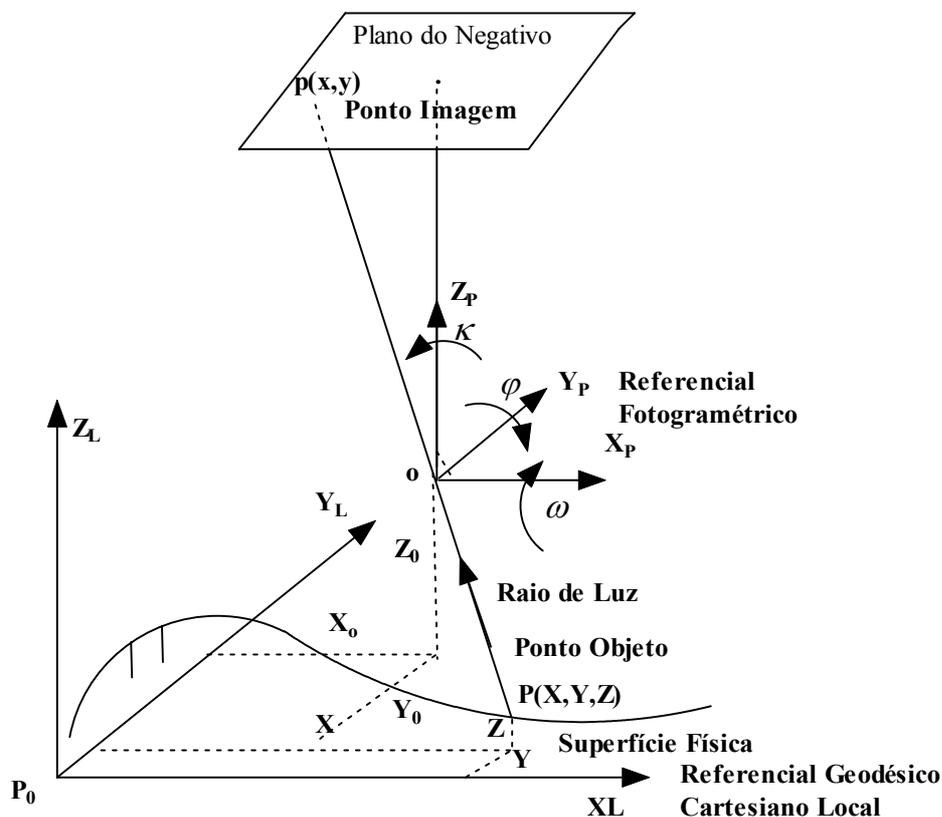
FONTE: (MITISHITA, 1997, p.63).

2.9.10 Orientação Exterior

O modelo matemático para o ajustamento de observações fotogramétricas de um par de aerofotos, visando a formação analítica do modelo fotogramétrico, é obtido a partir das equações de colinearidade. A orientação exterior de uma aerofoto no espaço, em relação ao referencial geodésico cartesiano local, consiste em se

determinar os parâmetros (X_0, Y_0, Z_0) de posicionamento e os parâmetros (κ, ϕ, ω) de orientação, conforme mostrado na FIGURA 2.31.

FIGURA 2.31 – ORIENTAÇÃO EXTERIOR DE UMA AEROFOTO NO ESPAÇO



FONTE: (MITISHITA, 1997, p. 56).

A análise das equações de colinearidade permite concluir que o primeiro membro delas apresenta fotocoordenadas de pontos observados de uma aerofoto, enquanto que o segundo apresenta coordenadas dos mesmos pontos no referencial geodésico local. Analisando ainda as equações de colinearidade, pode-se concluir que estas representam um modelo matemático não-linear da forma a seguir:

$$\begin{aligned} F(x_i) &= F(\kappa, \phi, \omega, X_0, Y_0, Z_0, X_i, Y_i, Z_i) \\ F(y_i) &= F(\kappa, \phi, \omega, X_0, Y_0, Z_0, X_i, Y_i, Z_i) \quad i = 1, 2, \dots, n \end{aligned} \quad (2.93)$$

Na equação (2.93), n representa o número de pontos observados em uma das aerofotos.

Considerando as coordenadas fotogramétricas e as coordenadas geodésicas como valores observados, pode-se empregar o ajustamento paramétrico com injunções de peso, como procedimento adequado para a determinação dos parâmetros da orientação exterior (MITISHITA, 1997, p.72).

Como são n pontos para cada uma das fotos (esquerda e direita) e para cada ponto resultam duas equações de observações (uma em x e outra em y), tem-se $2n$ equações para a foto da esquerda e $2n$ equações para a foto da direita, totalizando $4n$ equações de observações, que é o número de linhas da matriz A . Usando o modelo matemático das equações de colinearidade, infere-se que o número de colunas da matriz A será $12 + 3n$. Onde 12 são os elementos obtidos pelas derivadas parciais da equação (2.93) em relação aos 6 primeiros parâmetros das fotos respectivamente da esquerda e da direita, e $3n$ são as derivadas parciais de F em relação aos n pontos (X_i, Y_i, Z_i). Assim sendo, a matriz A terá a seguinte configuração:

A matriz A , de dimensões $4n$ linhas por $(12+3n)$ colunas, é a união das quatro sub-matrizes mostradas na equação a seguir:

$$A_{4n \times (12+3n)} = \begin{bmatrix} (A_{11})_{2n \times 12} & (A_{12})_{2n \times 3n} \\ (A_{21})_{2n \times 12} & (A_{22})_{2n \times 3n} \end{bmatrix} \quad (2.94)$$

A sub-matriz A_{11} contém as derivadas parciais das $2n$ equações dos n pontos da foto da esquerda do par aerofotogramétrico em relação aos 6 primeiros parâmetros da (2.93), enquanto que a sub-matriz A_{21} contém as derivadas parciais das $2n$ equações dos n pontos homólogos na foto da direita do par.

As sub-matrizes A_{12} e A_{22} contêm as derivadas parciais das $2n$ equações dos pontos respectivamente das fotos da esquerda e da direita, em relação às coordenadas dos n pontos no referencial geodésico local.

2.9.11 Ajustamento Paramétrico com Injunção

De acordo com (MITISHITA, 1997), o ajustamento paramétrico com injunção é dado por:

$$\begin{aligned}
X &= -(N + N^C)^{-1} (U + U^C) \\
N &= A^T P A \\
U &= A^T P L \\
U^C &= C^T P^C E \\
X_a &= X_0 + X
\end{aligned} \tag{2.95}$$

A matriz A da equação (2.95), com as suas dimensões está mostrada na equação (2.94). A matriz P da (2.95) é a matriz dos pesos dos valores observados que tem dimensão $4n \times 4n$. O vetor L da equação (2.95) é obtido por:

$$L = L_0 - L_b \tag{2.96}$$

O vetor L_b tem dimensões $4n \times 1$ e contém as coordenadas dos pontos fotogramétricos, sendo que são $2n$ coordenadas na foto da esquerda e $2n$ coordenadas para a foto da direita do par, conforme apresentado na equação (2.97).

$$L_b^T = [x_{1E}^b \ y_{1E}^b \ x_{2E}^b \ y_{2E}^b \ \dots \ x_{nE}^b \ y_{nE}^b \ x_{1D}^b \ y_{1D}^b \ x_{2D}^b \ y_{2D}^b \ \dots \ x_{nD}^b \ y_{nD}^b] \tag{2.97}$$

O vetor L_0 é obtido a partir da equação (2.98), onde o índice E refere-se à foto esquerda e D à foto direita.

$$L_0^T = F(X_0) = [x_{1E}^0 \ y_{1E}^0 \ x_{2E}^0 \ y_{2E}^0 \ \dots \ x_{nE}^0 \ y_{nE}^0 \ x_{1D}^0 \ y_{1D}^0 \ x_{2D}^0 \ y_{2D}^0 \ \dots \ x_{nD}^0 \ y_{nD}^0] \tag{2.98}$$

As componentes do vetor L_0 são os valores aproximados das coordenadas de foto obtidos com a aplicação das equações de colinearidade, conforme mostrado nas equações (2.99) a (2.102).

$$x_{iD}^0 = -f \frac{m_{11}(X_i^0 - X_0) + m_{12}(Y_i^0 - Y_0) + m_{13}(Z_i^0 - Z_0)}{m_{31}(X_i^0 - X_0) + m_{32}(Y_i^0 - Y_0) + m_{33}(Z_i^0 - Z_0)}, \quad i = 1, 2, \dots, n, \tag{2.99}$$

$$y_{iD}^0 = -f \frac{m_{21}(X_i^0 - X_0) + m_{22}(Y_i^0 - Y_0) + m_{23}(Z_i^0 - Z_0)}{m_{31}(X_i^0 - X_0) + m_{32}(Y_i^0 - Y_0) + m_{33}(Z_i^0 - Z_0)}, \quad i = 1, 2, \dots, n \tag{2.100}$$

$$x_{iE}^0 = -f \frac{m_{21}(X_i^0 - X_0) + m_{22}(Y_i^0 - Y_0) + m_{23}(Z_i^0 - Z_0)}{m_{31}(X_i^0 - X_0) + m_{32}(Y_i^0 - Y_0) + m_{33}(Z_i^0 - Z_0)}, \quad i = 1, 2, \dots, n \tag{2.101}$$

$$y_{iE}^0 = -f \frac{m_{21}(X_i^0 - X_0) + m_{22}(Y_i^0 - Y_0) + m_{23}(Z_i^0 - Z_0)}{m_{31}(X_i^0 - X_0) + m_{32}(Y_i^0 - Y_0) + m_{33}(Z_i^0 - Z_0)}, \quad i = 1, 2, \dots, n \tag{2.102}$$

As injunções nas coordenadas geodésicas são as da forma apresentada na equação (2.103)

$$\begin{cases} X_i^{obs} - X_i^a = E_x \\ Y_i^{obs} - Y_i^a = E_y \\ Z_i^{obs} - Z_i^a = E_z \end{cases} \quad (2.103)$$

Na equação (2.103) X_i^{obs}, Y_i^{obs} e Z_i^{obs} , representam as coordenadas observadas de pontos, no referencial geodésico local; X_i^a, Y_i^a e Z_i^a , representam as coordenadas de pontos no referencial geodésico local, ajustadas; E_x, E_y e E_z , são os resíduos nos pontos no referencial geodésico local.

A matriz C , que é representada na equação (2.95), é obtida a partir das derivadas parciais da função das injunções da equação (2.103). As derivadas parciais são obtidas em relação aos seis parâmetros $k, \omega, \varphi, X_o, Y_o, Z_o$, das fotos da esquerda e da direita, formando as 12 primeiras colunas da matriz C . As derivadas parciais em relação as coordenadas geodésicas formam outras $3n$ colunas. Observa-se que as 12 primeiras colunas são formadas por elementos nulos. Nas $3n$ colunas restantes figuram matrizes identidades de dimensões 3 por 3 nos pontos em cujas coordenadas geodésicas são elaboradas injunções.

A equação (2.104) apresenta o aspecto da matriz C que admite $3n$ linhas por $(12+3n)$ colunas.

$$C_{3n \times (12+3n)} = [0_{3n \times 12} \quad I_{3n \times 3n}] \quad (2.104)$$

A matriz dos pesos para as injunções (P^C) tem dimensão de $3n$ por $3n$. Sendo assim, a matriz normal relativa às injunções terá o seguinte aspecto:

$$N^C = C^T P^C C = \begin{bmatrix} 0_{12 \times 12} & 0_{12 \times 3n} \\ 0_{12 \times 3n} & P_{3n \times 3n}^C \end{bmatrix} \quad (2.105)$$

A forma da matriz U^C está mostrada na equação (2.106)

Na equação (2.95), X é o vetor das correções dos parâmetros, X_0 é o vetor dos valores aproximados iniciais dos parâmetros e X_a representa o vetor dos parâmetros ajustados.

$$U_{(12+3n) \times 1}^C = C^T P^C E = \begin{bmatrix} 0_{3n \times 12} \\ I_{3n \times 3n} \end{bmatrix} \begin{pmatrix} P^C \\ E \end{pmatrix}_{3n \times 1} = \begin{bmatrix} 0_{12 \times 1} \\ (P^C E)_{3n \times 1} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \cdot \\ \cdot \\ \cdot \\ 0 \\ UC(13) \\ UC(14) \\ UC(3n+12) \end{bmatrix} \quad (2.106)$$

A matriz variância e covariância dos parâmetros ajustados é obtida por:

$$\sum X_a = \sigma_0^2 (N + NC)^{-1} \quad (2.107)$$

Na equação (2.107) σ_0^2 é a variância das observações de peso a posteriori, calculada por:

$$\sigma_0^2 = \frac{V^T P V + E^T P E}{n - u} \quad (2.108)$$

Na equação (2.108), $n - u$ representa o número graus de liberdade (diferença entre o número total de equações e o número de incógnitas).

2.9.12 Teste de Hipótese Qui-Quadrado

Segundo HAMILTON (1964), a forma quadrática $V^T \sum_{L_b}^{-1} V$ tem distribuição de χ^2 com $S = \nu$ graus de liberdade, isto é:

$$V^T \sum_{L_b}^{-1} V \sim \chi^2(\nu). \quad (2.109)$$

De acordo com GEMAEL (1994, p.121), a matriz dos pesos das observações é:

$$P = \sigma_0^2 \sum_{L_b}^{-1}. \quad (2.110)$$

Nas equações (2.109) e (2.110) $\sum_{L_b}^{-1}$ significa a matriz inversa da matriz variância-covariância dos valores observados ajustados.

Desta forma, substituindo a equação (2.110) na equação (2.109), resulta:

$$\frac{V^T P V}{\sigma_0^2} \sim \chi^2(\nu). \quad (2.111)$$

Testa-se a hipótese básica:

$$H_0 : \sigma_0^2 = \hat{\sigma}_0^2. \quad (2.112)$$

Contra a hipótese alternativa:

$$H_1 : \sigma_0^2 \neq \hat{\sigma}_0^2. \quad (2.113)$$

De acordo com KRAKIWSKI (1975), comparando o valor calculado

$$\chi^{*2} = \frac{\hat{\sigma}_0^2}{\sigma_0^2} \nu = \frac{V^T P V}{\sigma_0^2}, \quad (2.114)$$

com os valores teóricos

$$\chi^2_{\nu, \frac{\alpha}{2}} \text{ e } \chi^2_{\nu, 1 - \frac{\alpha}{2}} \quad (2.115)$$

a hipótese básica não é rejeitada, ao nível de significância α , se:

$$\chi^2_{\nu, \frac{\alpha}{2}} < \chi^{*2} < \chi^2_{\nu, 1 - \frac{\alpha}{2}} \quad (2.116)$$

3 MATERIAIS

3.1 PONTOS PRÉ-SINALIZADOS EM PAREDES VERTICAIS

Com a finalidade de se iniciar com as técnicas de identificação de pontos de apoio pré-sinalizados ou naturais em aerofotos, foram fotografados alvos em uma parede vertical externa do Centro Politécnico da Universidade Federal do Paraná, conforme representado na FIGURA 3.1

3.1.1 Pontos pré-sinalizados dos tipos “cruz” e “círculo”, em uma parede.

Na FIGURA 3.1 representa-se a imagem colorida digital de “pontos pré-sinalizados em uma parede externa do Centro Politécnico .

FIGURA 3.1 - FOTO DIGITAL DA PRÉ-SINALIZAÇÃO NA PAREDE



3.2 ÁREA DE ESTUDOS

3.2.1 Trabalhos de Campo

A região de estudos abrange o Campus Centro Politécnico da Universidade Federal do Paraná, parte dos bairros Cajuru, Jardim das Américas e parte do bairro Jardim Botânico. Após a escolha da região de estudos, com o auxílio de mapas topográficos e fotos aéreas existentes da região, foram pré-sinalizados trinta e dois pontos de apoio, sendo 16 em forma de círculo contido num quadrado com lado três vezes a dimensão do diâmetro do círculo, e 16 em forma de cruz, com dimensões

adequadas à cobertura aerofotogramétrica na escala de 1/8000. Os trinta e dois pontos foram sinalizados de forma a se situarem nas fotos aproximadamente nas regiões de Von Grueber, sendo um em forma de cruz e outro em forma de círculo contido no quadrado, com a finalidade de se verificar qual tipo de ponto melhor se adapta para a identificação com o uso de redes neurais artificiais e correlação. Sinalizaram-se os pontos sempre sobre regiões com asfalto, usando tintas comuns de pintar paredes, nas cores preta e branca, com a finalidade de se obter bom contraste na identificação dos referidos pontos nas fotos aéreas, conforme aparecem representados na FIGURA 3.2 e na FIGURA 3.3. O círculo foi pintado com a cor preta e o quadrado, conforme aparece na FIGURA 3.3, foi pintado com a cor branca.

FIGURA 3.2 - PONTO PRÉ-SINALIZADO EM FORMA DE "CRUZ"



FIGURA 3.3 - PONTO PRÉ-SINALIZADO EM FORMA DE CÍRCULO



3.2.2 Planejamento do Vôo e Fotos Aéreas

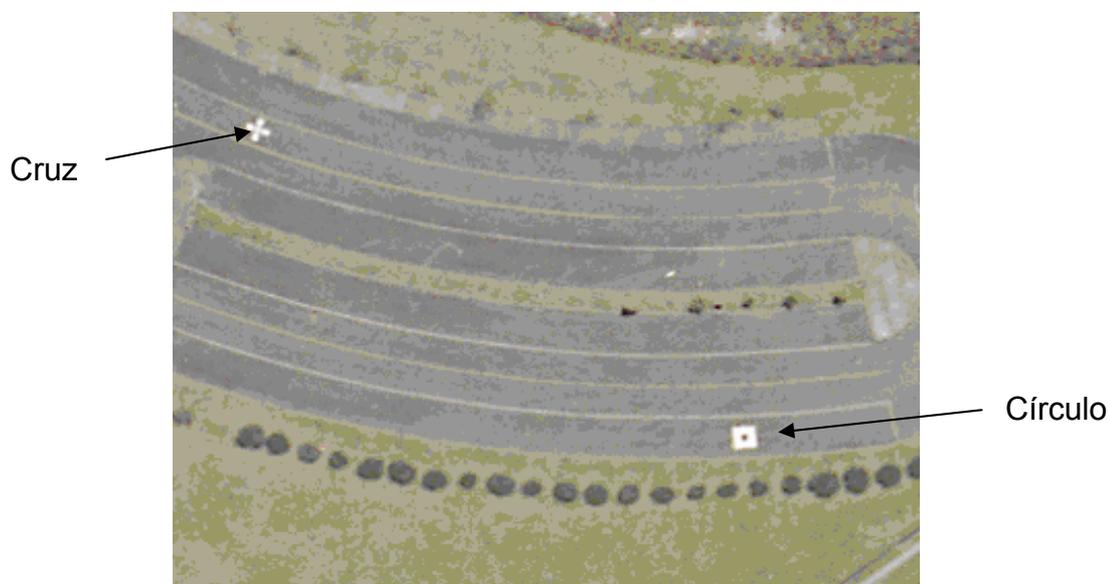
O vôo teve o seu planejamento feito de forma a recobrir a área descrita na seção 3.2.1. Foi planejada uma faixa com 5 fotos, sendo as coordenadas do centro da primeira foto: $\varphi = 25^{\circ}27'43",26610S$; $\lambda = 49^{\circ}14'14",1373W$ e as coordenadas do centro da quinta foto: $\varphi = 25^{\circ}26'23",4924S$; $\lambda = 49^{\circ}14'15",2992W$. A escala média aproximada de cada foto foi planejada para ser de 1:8000. O vôo foi executado no ano de 2002, pela empresa Aerosat, de Curitiba. As aerofotos foram obtidas com uma câmara aerofotogramétrica WILD RC-10. As mesmas foram digitalizadas com resolução de 0,024 mm. Uma parte de uma das fotos está representada na FIGURA 3.4.

FIGURA 3.4 - PARTE DE UMA DAS AEROFOTOS



Na FIGURA 3.5 , estão apresentados um ponto pré-sinalizado em forma de cruz e outro em forma de círculo.

FIGURA 3.5 - PONTOS PRÉ-SINALIZADOS "CRUZ" E "CÍRCULO"



3.2.3 Localização dos Pontos Pré-sinalizados

A TABELA 3.1 indica os pontos, os tipos de pontos sinalizados e as respectivas localizações. Além disso, mostra-se na seqüência, por meio de partes da foto aérea, uma descrição de cada um dos pontos.

TABELA 3.1- PONTOS PRÉ-SINALIZADOS

Ponto número	Tipo do ponto	Localização
1	Circular	Jardim das Américas – Próximo ao Hospital Erasto Gaertner
2	Cruz	Jardim das Américas – Próximo ao Hospital Erasto Gaertner
3	Circular	Cancha de Esportes-Educação Física Centro Politécnico
4	Cruz	Interior da Pista de Atletismo
5	Cruz	Jardim da Américas – Próximo ao Centro Politécnico
6	Circular	Jardim da Américas – Próximo ao Centro Politécnico
7	Circular	Jardim da Américas – Próximo ao Mercadorama
8	Cruz	Jardim da Américas – Próximo ao Mercadorama
9	Circular	Cajurú – Próximo ao Mercadorama
10	Cruz	Cajurú – Próximo ao Mercadorama
11	Cruz	Cajurú
12	Circular	Cajurú
13	Circular	Cajurú
14	Cruz	Cajurú
15	Circular	Centro Politécnico – Rua do Bloco do Depto. Geomática
16	Cruz	Centro Politécnico – Próximo Copel
17	Círculo	Centro Politécnico - Próximo Mini-Usina Itaipu

Ponto número	Tipo do ponto	Localização
18	Cruz	Centro Politécnico – mesma Rua de 17
19	Círculo	Centro Politécnico – Eng. Elétrica
20	Cruz	Centro Politécnico – Eng. Química
21	Círculo	Centro Politécnico – próximo à passarela da BR116
22	Cruz	Centro Politécnico – Administração
23	Cruz	Centro Politécnico – Biológicas
24	Circular	Centro Politécnico – Biológicas
25	Circular	Centro Politécnico – Biológicas
26	Cruz	Centro Politécnico – Biológicas
27	Cruz	Setor de Educação Física – BR116
28	Circular	Campus Jardim Botânico – Eng. Florestal
29	Cruz	Campus Jardim Botânico – Farmácia
30	Circular	Campus Jardim Botânico – Odontologia
31	Circular	Jardim Botânico – Copel –UFPR
32	Cruz	Jardim Botânico – Copel –UFPR

3.2.4 Coordenadas Geodésicas dos Pontos Pré-sinalizados

As coordenadas geodésicas dos pontos de apoio pré-sinalizados foram obtidas por meio de levantamento GPS, utilizando o Laboratório de Geodésia Espacial da UFPR, nos dias 15 de novembro e 16 de novembro de 2002, contando com o auxílio de alunos estagiários do Curso de Engenharia Cartográfica da Universidade Federal do Paraná.

As coordenadas geodésicas processadas após o levantamento GPS, referidas ao elipsóide WGS84, estão sintetizadas na TABELA 3.2:

TABELA 3.2 - COORDENADAS GEODÉSICAS DOS PONTOS PRÉ-SINALIZADOS

PONTO	LATITUDE	LONGITUDE	ALTITUDE	σ_{φ}	σ_{λ}	σ_H
1	25° 27' 19,55470" S	49° 14' 19,28716" W	910,357m	0,001	0,002	0,003
2	25° 27' 25,50720" S	49° 14' 15,21279" W	911,314m	0,002	0,003	0,004
3	25° 27' 17,19060" S	49° 14' 15,37788" W	915,150m	0,008	0,008	0,009
4	25° 27' 17,19060" S	49° 14' 13,89560" W	911,420m	0,006	0,007	0,005
5	25° 27' 16,83911" S	49° 14' 3,080050" W	918,095m	0,005	0,006	0,004
6	25° 27' 21,75650" S	49° 14' 0,414620" W	922,007m	0,006	0,007	0,005
7	25° 27' 06,08726" S	49° 13' 39,44712" W	917,945m	0,007	0,007	0,006
8	25° 27' 14,47673" S	49° 13' 32,74604" W	921,464m	0,005	0,007	0,006
9	25° 26' 58,19170" S	49° 13' 32,34151" W	912,546m	0,004	0,006	0,004
10	25° 26' 56,30539" S	49° 13' 32,69912" W	913,702m	0,006	0,007	0,005
11	25° 26' 43,57783" S	49° 13' 42,50494" W	915,523m	0,006	0,007	0,005
12	25° 26' 44,53110" S	49° 13' 37,96693" W	913,201m	0,006	0,006	0,005
13	25° 26' 34,13190" S	49° 13' 42,93211" W	929,271m	0,006	0,006	0,005
14	25° 26' 32,54280" S	49° 13' 37,35154" W	925,786m	0,006	0,006	0,005
15	25° 27' 08,92410" S	49° 14' 06,80050" W	917,474m	0,006	0,006	0,005
16	25° 27' 07,42240" S	49° 14' 10,67170" W	909,329m	0,005	0,004	0,004
17	25° 27' 05,46662" S	49° 14' 08,90672" W	912,621m	0,003	0,001	0,003
18	25° 27' 06,89550" S	49° 14' 05,11430" W	911,507m	0,003	0,001	0,003
19	25° 27' 05,43280" S	49° 14' 02,18887" W	914,714m	0,003	0,001	0,003
20	25° 27' 02,97430" S	49° 14' 03,55630" W	911,507m	0,006	0,008	0,007

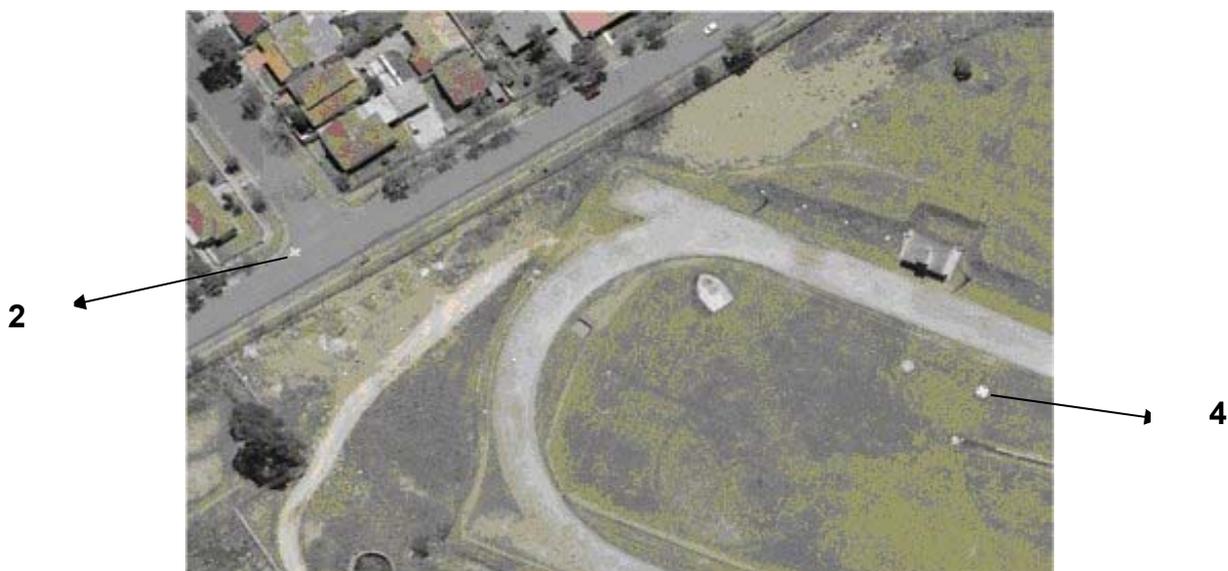
PONTO	LATITUDE	LONGITUDE	ALTITUDE	σ_{φ}	σ_{λ}	σ_H
21	25° 26' 55,98525" S	49° 14' 03,38600" W	909,493m	0,006	0,008	0,007
22	25° 26' 56,96003" S	49° 13' 59,14703" W	913,454m	0,006	0,008	0,006
23	25° 26' 55,19102" S	49° 14' 00,31235" W	914,567m	0,006	0,006	0,005
24	25° 26' 55,86680" S	49° 13' 56,74744" W	917,759m	0,005	0,006	0,005
25	25° 26' 50,95809" S	49° 13' 51,91839" W	925,100m	0,004	0,005	0,005
26	25° 26' 52,68523" S	49° 13' 53,23006" W	923,105m	0,004	0,005	0,005
27	25° 27' 04,47262" S	49° 14' 18,58945" W	894,900m	0,006	0,005	0,003
28	25° 26' 54,83340" S	49° 14' 15,47565" W	902,497m	0,006	0,005	0,005
29	25° 26' 45,05866" S	49° 14' 18,79502" W	928,146m	0,007	0,007	0,006
30	25° 26' 41,92539" S	49° 14' 25,93088" W	925,279m	0,006	0,007	0,006
31	25° 26' 45,03063" S	49° 14' 09,80844" W	918,465m	0,005	0,007	0,006
32	25° 26' 45,03063" S	49° 14' 05,66805" W	928,004m	0,005	0,007	0,006

FIGURA 3.6 – PONTOS PRÉ-SINALIZADOS 1 E 3



A FIGURA 3.6 mostra os pontos 1 e 3. O ponto 1 situa-se no cruzamento das Ruas Dr. Ovande do Amaral com Rua Maestro Romualdo, no Bairro Jardim das Américas. O ponto 3 está situado sobre uma cancha de esportes pertencente à Escola de Educação Física da Universidade Federal do Paraná, no Jardim das Américas.

FIGURA 3.7 - PONTOS PRÉ-SINALIZADOS 2 E 4



A FIGURA 3.7 contém os pontos 2 e 4. O ponto 2 localiza-se na esquina das ruas Frederico Virmond com Ovande do Amaral, no bairro Jardim das Américas, próximo ao Hospital Erasto Gaertner. O ponto 4 localiza-se na parte interna da pista de atletismo da Escola de Educação Física da Universidade Federal do Paraná.

FIGURA 3.8 – PONTOS PRÉ-SINALIZADOS 5 E 6



A FIGURA 3.8 contém os pontos 5 e 6. O ponto 5 está situado na Rua Coronel Joaquim Lacerda, no Jardim das Américas. O ponto 6 localiza-se na

esquina das Ruas Frei Fabiano de Cristo com Rua Carlos Pradi, também no Jardim das Américas.

FIGURA 3.9 - PONTO PRÉ-SINALIZADO 7



Na FIGURA 3.9 está contido o ponto 7. O mesmo está localizado ao lado do supermercado Mercadorama no bairro Jardim das Américas, na Rua Rodolfo Senff.

FIGURA 3.10 - PONTO PRÉ-SINALIZADO 8



A FIGURA 3.10 contém o ponto 8. O mesmo está localizado distante duas quadras do supermercado Mercadorama, em uma rua sem saída.

FIGURA 3.11 - PONTOS PRÉ-SINALIZADOS 9 E 10



A FIGURA 3.11 contém os pontos 9 e 10. O ponto 9 está localizado na esquina das ruas Rubens Padilha Mendes e Afonso Correia Moraes, no bairro Cajuru. O ponto 10 localiza-se na rua Marília Lacerda Carneiro, no Bairro Cajuru.

FIGURA 3.12 - PONTOS PRÉ-SINALIZADOS 11 E 12



A FIGURA 3.12 contém os pontos 11 e 12. O ponto 11 está localizado na rua José Demeterco, quase esquina com a rua Irmão Luiz Vicente, no bairro Cajuru.

O ponto 12 localiza-se no cruzamento das ruas Miguel Calluf e São Gabriel, no bairro Cajuru.

FIGURA 3.13 - PONTO PRÉ-SINALIZADO 13



O ponto 13 está contido na FIGURA 3.13. O mesmo está localizado na esquina das ruas Dom João VI e Luiz França, no bairro Cajuru.

FIGURA 3.14 - PONTO PRÉ-SINALIZADO 14



O ponto 14 está contido na FIGURA 3.14. O mesmo está localizado na esquina das ruas Irmão Luiz Vicente e Antônio Meireles Sobrinho, no bairro Cajuru.

FIGURA 3.15 - PONTOS PRÉ-SINALIZADOS 15,16 E 17



A FIGURA 3.15 contém os pontos 15 e 16 e 17. Os pontos 15 e 16 estão situados na rua do Departamento de Geomática. O ponto 17 está localizado em frente à Mini-Usina Itaipu.

FIGURA 3.16 - PONTOS PRÉ-SINALIZADOS 18,19 E 20



A FIGURA 3.16 contém os pontos 18, 19 e 20. O ponto 18 está localizado em frente ao Laboratório de Mecânica dos Flúidos. O ponto 19 localiza-se no

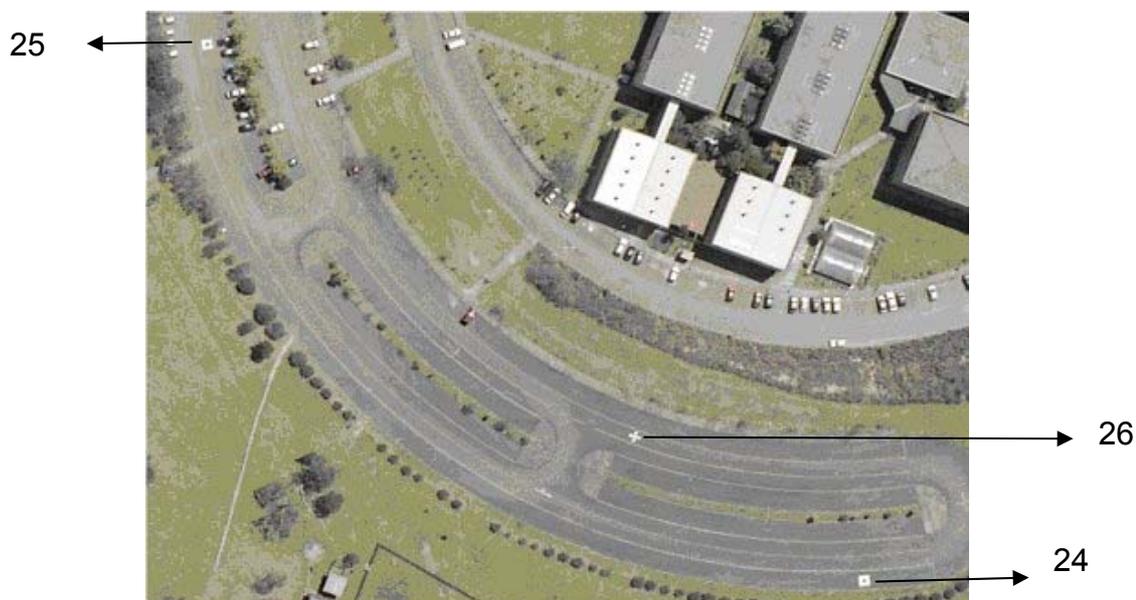
estacionamento dos professores do Curso de Engenharia Elétrica. O ponto 20 tem a sua localização na rua de fundos dos prédios da Engenharia Química.

FIGURA 3.17 - PONTOS PRÉ-SINALIZADOS 21, 22 e 23



Os pontos 21, 22 e 23 estão contidos na FIGURA 3.17. O ponto 21 está localizado nas proximidades da passarela da BR116. O ponto 23 situa-se no estacionamento do Setor de Ciências Biológicas e o ponto 22 localiza-se na entrada para os blocos dos setores de Ciências Exatas e Tecnológicas.

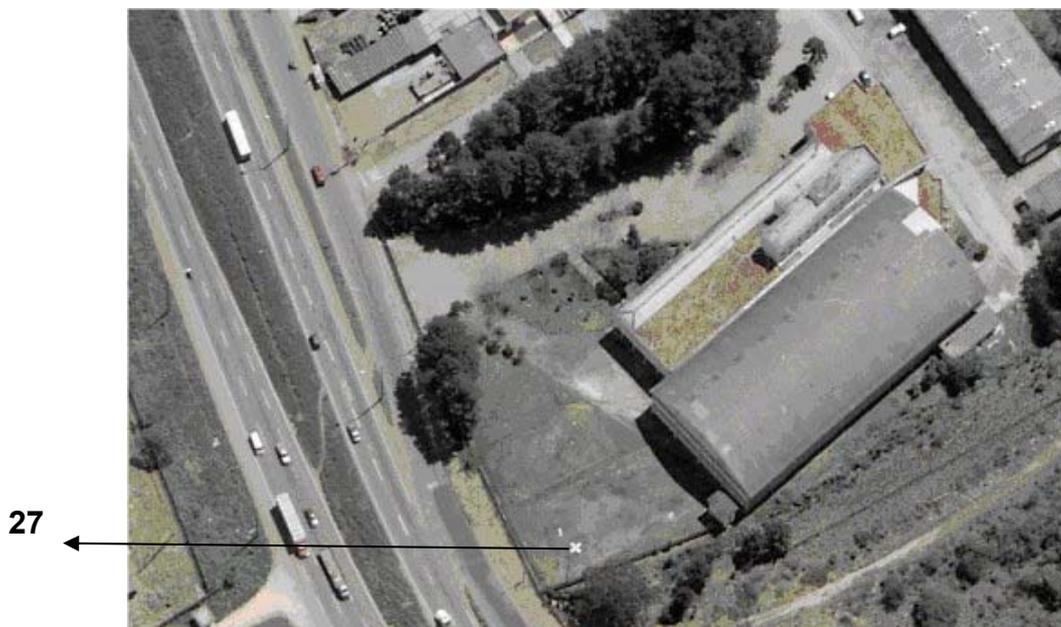
FIGURA 3.18 - PONTOS PRÉ-SINALIZADOS 24,25 E 26



Os pontos 24, 25 e 26 mostrados na FIGURA 3.18 estão localizados no estacionamento do Setor de Ciências Biológicas, no Centro Politécnico, sendo que o ponto 25 está próximo ao retorno para a entrada do Campus, e os pontos 24 e 26

estão próximos aos Laboratórios de Astronomia e de Levantamentos de Geodésia Espacial.

FIGURA 3.19 - ponto pré-sinalizado 27



O ponto 27 , contido na FIGURA 3.19, está situado em frente ao Curso de Educação Física da UFPR, ao lado da BR116.

FIGURA 3.20 - PONTO PRÉ-SINALIZADO 28



O ponto 28, representado na FIGURA 3.20 está localizado nas dependências do Curso de Engenharia Florestal da UFPR, no Campus Jardim Botânico.

FIGURA 3.21 - PONTO PRÉ-SINALIZADO 29



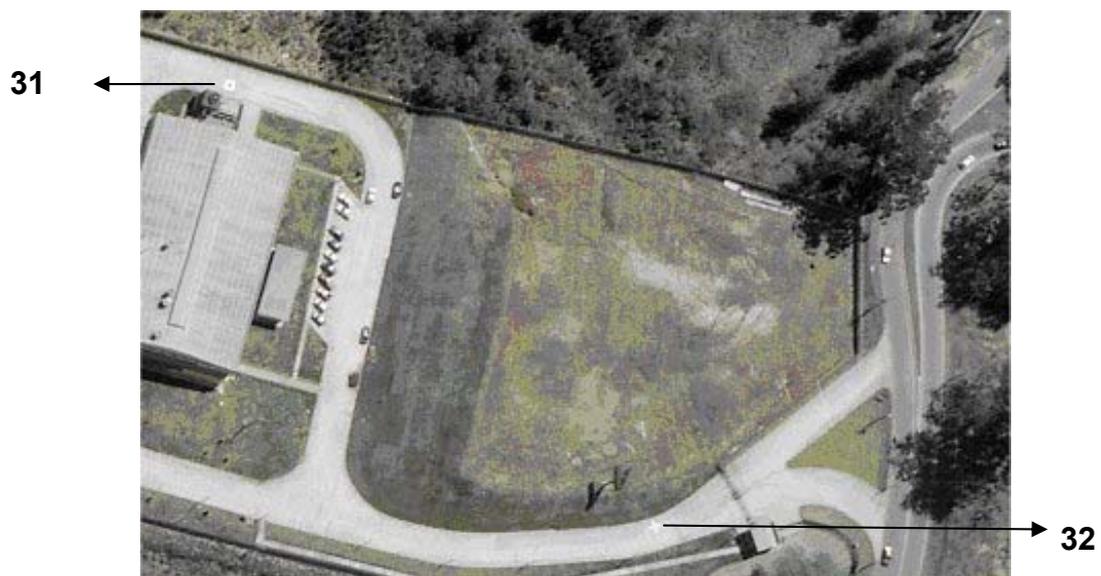
O ponto 29 , contido na FIGURA 3.21, está localizado no Campus Jardim Botânico, da UFPR, na Rua do Curso de Odontologia.

FIGURA 3.22 - PONTO PRÉ-SINALIZADO 30



O ponto 30, contido na FIGURA 3.22, está localizado no Campus Jardim Botânico da UFPR, na Rua do Curso de Farmácia e Bioquímica.

FIGURA 3.23 - PONTOS PRÉ-SINALIZADOS 31 E 32



Os pontos 31 e 32, contidos na FIGURA 3.23, estão localizados no LACTEC-LEME, do convênio da UFPR e Copel.

4 METODOLOGIA

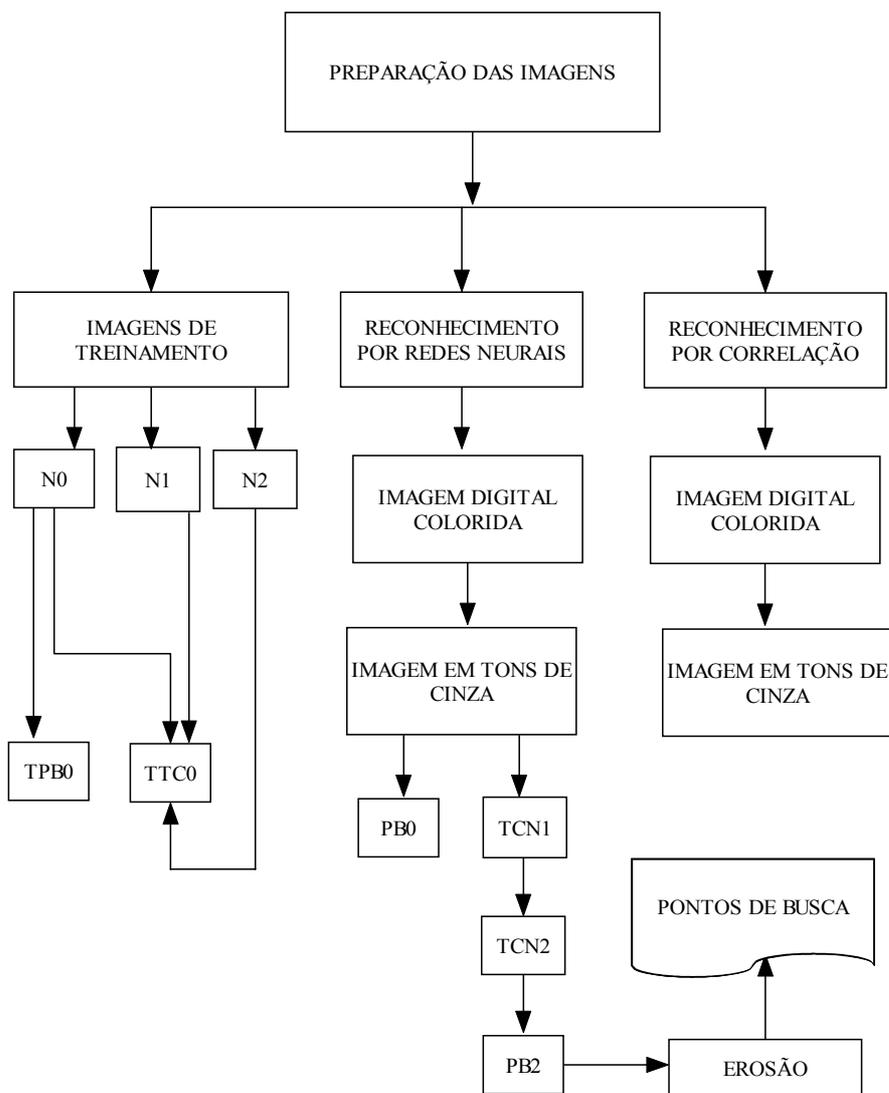
A metodologia deste trabalho está descrita em três etapas:

- preparação das imagens;
- treinamento;
- reconhecimento.

4.1 PREPARAÇÃO DAS IMAGENS

O diagrama de blocos mostrado na FIGURA 4.1 mostra a seqüência metodológica para obter os dados de entrada para o treinamento da RNA.

FIGURA 4.1 - PREPARAÇÃO DAS IMAGENS



Na FIGURA 4.1 o significado das abreviaturas são:

- N0 = imagem de treinamento no nível zero;
- N1 = imagem de treinamento em tons de cinza no nível 1;
- N2 = imagem de treinamento em tons de cinza no nível 2;
- TPB0 = imagem de treinamento em preto e branco no nível zero;
- TTC0 = imagem de treinamento em tons de cinza no nível zero;
- PB0 = imagem em preto e branco do nível zero;
- TCN1 = imagem em tons de cinza do nível um;
- TCN2 = imagem em tons de cinza do nível dois;
- PB2 = imagem em preto e branco do nível dois.

A preparação das imagens, conforme mostra a FIGURA 4.1 estão apresentadas em três grupos:

- Imagens de treinamento;
- Imagens de reconhecimento por Redes Neurais;
- Imagens de reconhecimento por Correlação.

4.1.1 Imagens de Treinamento

4.1.1.1 Considerações

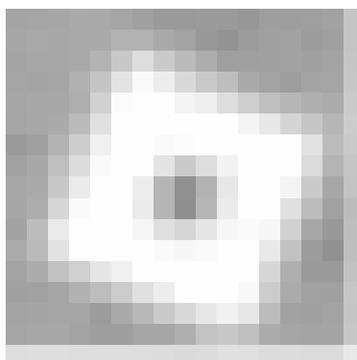
As imagens de treinamento foram construídas para que representem os dados de entrada da RNA a ser treinada. Esses dados devem ser tais que representem, em posições determinadas (coluna, linha) da imagem, o centro dos pontos pré-sinalizados, para que a partir daí se possa informar à RNA uma janela (matriz de "pixels") que contenha esse ponto ou não. A estratégia de treinamento utilizada será a de saída binária, isto é, uma determinada janela de "pixels" na saída da RNA treinada será ou não ponto pré-sinalizado.

Pelo fato de que neste trabalho optou-se por diferentes níveis da imagem que contém os pontos procurados, ocorre também a necessidade de que o treinamento seja realizado também nesses níveis, isto é, nos níveis zero (N0), um (N1) e dois (N2).

4.1.1.2 Imagem de treinamento no nível 0

A imagem de treinamento no nível 0 (N0) é construída com o auxílio do aplicativo *Paint Shop Pro* a partir de uma das aerofotos em tons de cinza. Nessa aerofoto, retira-se uma parte formada aproximadamente de 300 por 300 “pixels”. Sobre essa parte é construída a primeira imagem de treinamento. Nessa imagem, recortam-se janelas que abranjam pontos pré-sinalizados de uma das aerofotos com um tamanho de, por exemplo, 16x16 “pixels”, e cola-se essa janela na imagem de treinamento. Uma janela de 16x16 “pixels”, de um ponto pré-sinalizado está representada na FIGURA 4.2.

FIGURA 4.2 - JANELA DE UM PONTO PRÉ-SINALIZADO



Repete-se o procedimento anterior para os outros onze pontos pré-sinalizados, no caso, circulares. Após terem sido recortados e colados todos os pontos pré-sinalizados do tipo “círculo” ou “cruz”, está concluída uma versão inicial para o treinamento da RNA.

Anexou-se nesta imagem de treinamento várias feições, além dos pontos pré-sinalizados, pelo fato de que, em um primeiro reconhecimento por RNA, foram identificados como pontos pré-sinalizados os doze pontos pré-sinalizados circulares, bem como inúmeros outros “similares”, os quais causaram ambigüidades. As feições causadoras das ambigüidades foram, entre outras, tetos de automóveis (em sua maioria), teto de casas que eventualmente contrastam o preto com o branco, que é o caso típico dos alvos pré-sinalizados do tipo circular. Após este experimento inicial, foram anexadas na imagem de treinamento as feições que causaram ambigüidade, indicando-as como sendo não-alvos, com cuidado, sempre com o mesmo número de “pixels” (16x16), para que a RNA em seu novo treinamento diferencie essas feições dos pontos pré-sinalizados. Procedeu-se desta forma a um novo treinamento da

RNA em nível zero com a imagem de treinamento resultante. Após o segundo treinamento da RNA, procedeu-se a outro reconhecimento, e novamente ocorreu que a RNA acusou feições como sendo um dos pontos circulares pré-sinalizados, mas, na verdade, continuavam com ambigüidades. Novamente, foram anexadas na imagem de treinamento todas as ambigüidades ocorridas, para que as mesmas fossem eliminadas. Após nova simulação, obteve-se sucesso, cujos resultados estão apresentados no capítulo 5.

O procedimento descrito anteriormente para a formação da imagem de treinamento no nível zero apresentou um grau de dificuldade acentuado até que se conseguisse chegar a um conjunto de treinamento adequado.

O treinamento é realizado com a imagem de treinamento em tons de cinza, como binária, isto é, imagem com tons de cinza apenas preto e branco. No entanto, após experimentos, constatou-se que a imagem de treinamento adequada é a binária. As imagens de treinamento resultantes para os pontos pré-sinalizados circulares em tons de cinza (TTC0) e preto e branca (TTB0), estão representadas respectivamente na FIGURA 4.3 e na FIGURA 4.4..

FIGURA 4.3 - CONJUNTO DE TREINAMENTO EM TONS DE CINZA NO NIVEL 0 PARA OS ALVOS CIRCULARES

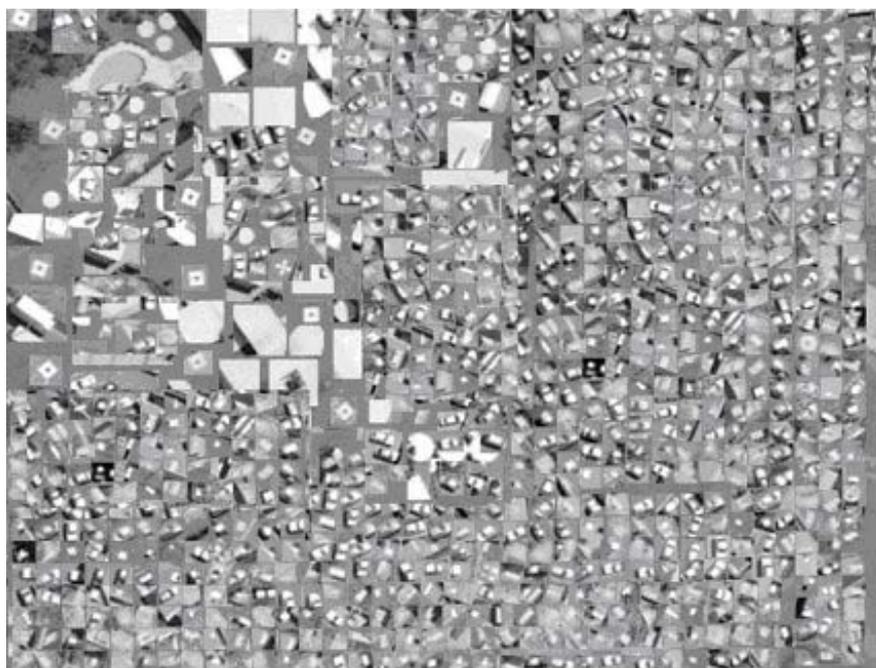
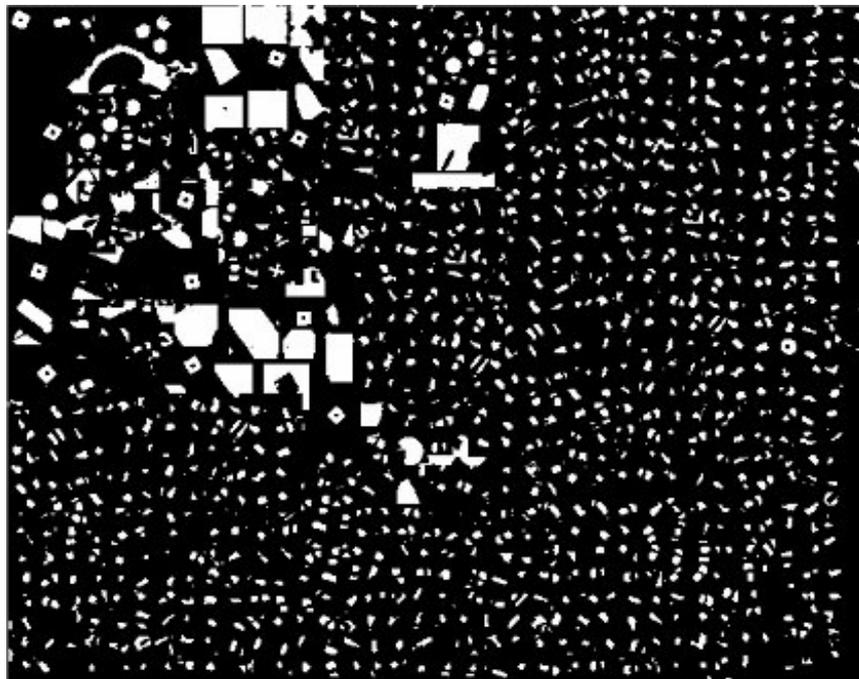


FIGURA 4.4 – CONJUNTO DE TREINAMENTO PARA O ALVO CIRCULAR NO NÍVEL 0 EM PRETO E BRANCO – IMAGEM BINÁRIA



Para a construção da imagem de treinamento no nível zero, para o reconhecimento dos pontos pré-sinalizados em forma de cruz, as estratégias foram as mesmas que para as circulares. Desta forma resultaram as imagens de treinamento para os pontos pré-sinalizados em forma de cruz apresentadas na FIGURA 4.5 e na FIGURA 4.6.

FIGURA 4.5 - IMAGEM DE TREINAMENTO NÍVEL 0 EM TONS DE CINZA PARA O PONTO PRÉ-SINALIZADO DO TIPO EM CRUZ

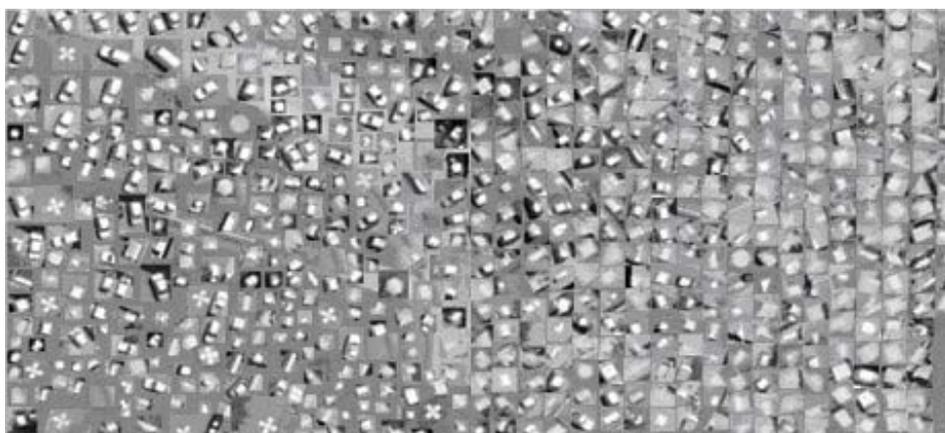


FIGURA 4.6 - IMAGEM DE TREINAMENTO NÍVEL ZERO, PRETA E BRANCA PARA O PONTO PRÉ-SINALIZADO DO TIPO EM CRUZ



janela 16x16 "pixels" em forma de cruz

4.1.1.3 Imagens de treinamento para os níveis 1 e 2

Experimentos demonstraram que não se tem necessidade de resolver ambigüidades para os treinamentos nos níveis um e dois, a exemplo do nível zero. Desta forma, as imagens de treinamento para o nível um é bem mais simples de ser construída. A partir da imagem de uma das aerofotos, retira-se uma pequena faixa da imagem (aproximadamente 800 "pixels" por 30 "pixels"). Sobre essa faixa é construída a imagem de treinamento. Como no caso do nível zero, recortam-se janelas que abranjam pontos pré-sinalizados de uma das aerofotos, com um tamanho de 16x16 "pixels", e cola-se esta janela na imagem de treinamento.

FIGURA 4.7 – IMAGEM NÍVEL 0, ORIGEM PARA O NÍVEL 1 CIRCULAR



FIGURA 4.8 – IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 1 DO ALVO CIRCULAR



FIGURA 4.9 – IMAGEM CONJUNTO DE TREINAMENTO DO NÍVEL 2 DO ALVO CIRCULAR



A FIGURA 4.7 representa o estágio de preparação para a imagem de treinamento no nível 1, representada na FIGURA 4.8, que é obtida a partir desta pela aplicação da rotina *LEVEL* (processo da pirâmide). A partir da imagem de treinamento do nível 1 para os pontos pré-sinalizados circulares, é obtida a imagem de treinamento do nível 2 pela aplicação da rotina *LEVEL*. A FIGURA 4.9 representa a imagem de treinamento do nível 2.

As imagens de treinamento para os níveis 1 e 2, dos pontos de apoio pré-sinalizados em cruz, são obtidas da mesma forma, na FIGURA 4.10, na FIGURA 4.11 e na FIGURA 4.12.

FIGURA 4.10 - IMAGEM NÍVEL 0, ORIGEM PARA O NÍVEL 1 EM CRUZ



FIGURA 4.11 - IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 1 DO ALVO EM CRUZ



FIGURA 4.12 - IMAGEM CONJUNTO DE TREINAMENTO NO NÍVEL 2 DO ALVO EM CRUZ



4.1.2 Imagens para o Reconhecimento por Redes Neurais

Por reconhecimento entenda-se aqui o procedimento de se localizar os pontos de apoio pré-sinalizados utilizando-se os resultados do treinamento já executado desses pontos.

Considerando o diagrama de blocos descrito na FIGURA 4.1, parte-se de início das imagens digitais coloridas das 4 aerofotos que contêm pontos pré-sinalizados. Como exemplo, mostra-se na FIGURA 4.13 uma parte da primeira aerofoto, na qual está situada a maioria dos pontos pré-sinalizados.

FIGURA 4.13 - PARTE DE AEROFOTO COLORIDA



Em seguida, a aerofoto colorida é transformada, com a aplicação da equação (2.11), em tons de cinza, sendo mostrada na FIGURA 4.14.

FIGURA 4.14 - PARTE DE AEROFOTO EM TONS DE CINZA



A imagem da aerofoto em tons de cinza agora deve ser transformada em imagem binária, isto é, preto e branco, com a aplicação da rotina *GRAY2BW*, cujo resultado está mostrado na FIGURA 4.15.

FIGURA 4.15 – PARTE DE AEROFOTO EM PRETO E BRANCO



Para a imagem em tons de cinza, no nível zero, representada na FIGURA 4.14, aplica-se a rotina *LEVEL*, para ser obtida a imagem em tons de cinza no nível 1, cujo resultado aparece representado na FIGURA 4.16.

FIGURA 4.16 – PARTE DE AEROFOTO EM TONS DE CINZA NO NÍVEL 1



Nesta imagem resultante em tons de cinza, aplica-se novamente a rotina *LEVEL*, obtendo-se a imagem em tons de cinza no nível 2, da aerofoto, que está mostrada na FIGURA 4.17.

FIGURA 4.17 – PARTE DE AEROFOTO EM TONS DE CINZA NO NÍVEL 2



Na aerofoto em tons de cinza no nível dois, é aplicado agora a rotina GRAY2BW, com o objetivo de transformar esta imagem em preto e branco. O resultado desta operação está mostrado na FIGURA 4.18.

Finalmente, executando-se a rotina *EROSÃO*, conforme metodologia apresentada no item 2.7.4, na imagem da aerofoto em nível preto e branco, resulta a imagem de pontos, que se denomina aqui imagem de PONTOS DE BUSCA, por estarem aí representados todos os candidatos a pontos pré-sinalizados. Este resultado está mostrado na FIGURA 4.19.

FIGURA 4.18 – PARTE DE AEROFOTO NO NÍVEL 2 EM PRETO E BRANCO



Esta imagem de pontos representa uma “nuvem” de pontos brancos no fundo preto. A erosão binária aqui é feita com uma pequena modificação daquela que aparece na teoria. A erosão binária na rotina *erosão* é elaborada de forma a que, sempre que for encontrada região branca contínua, estas serão erodidas, até que a região seja reduzida a um “pixel”, isto é, a um único ponto branco. Como a característica dos pontos de apoio pré-sinalizados é exatamente o contraste de “pixels” pretos e brancos, ao se fazer a erosão em toda a feição que é composta por pretos e brancos, isto irá resultar, no final, um ponto branco. O elemento estruturante aqui utilizado tem a forma do elemento estruturante *B* representado no item 2.7.1. , com a observação de que os *pixels* ativos são os brancos. O que irá decidir se este ponto branco representa um ponto de apoio pré-sinalizado é a aplicação de reconhecimento por RNA. O conjunto de “pontos de busca”, para o reconhecimento dos pontos pré-sinalizados, será utilizado após a Rede Neural ter sido treinada.

FIGURA 4.19 – PARTE DE AEROFOTO ERODIDA NO NÍVEL 2



4.1.3 Imagens para o Reconhecimento por Correlação

Para se reconhecer e identificar um ponto pré-sinalizado por correlação estatística, basta usar a imagem da aerofoto em tons de cinza no nível 0, conforme exemplo de parte de aerofoto representada na FIGURA 4.14.

4.2 TREINAMENTO NA REDE NEURAL ARTIFICIAL (RNA)

O treinamento na rede neural, para a identificação dos pontos pré-sinalizados foi realizado usando-se um código fonte em Visual C++, constando desse código, além do tratamento digital das imagens, o algoritmo “Backpropagation”, conforme o item 2.6.1, com a inclusão do processo alternativo *Resilien Propagation*, *RPROP*, descrito no item 2.6.4, para a atualização dos pesos entre uma camada e outra, uma camada de entrada, 1 camada escondida e uma camada de saída. O treinamento foi realizado em três etapas, descritas a seguir.

4.2.1 Treinamento da Rede Neural no Nível 0

O treinamento no nível 0, que denomina-se de “Rede 0”, usa a imagem de treinamento em preto e branco no nível 0 (TPB0), representada na FIGURA 4.4, para o treinamento dos pontos circulares, e na FIGURA 4.6, para o treinamento dos pontos em forma de cruz. A camada de entrada, para cada ponto pré-sinalizado a ser treinado, é composta por uma matriz de 256 (16x16). "pixels", uma camada escondida e uma camada de saída, com apenas um elemento, indicando este elemento a saída ou não de um alvo.

Para o treinamento da RNA no nível 0, é utilizado o sub-programa *train.exe* elaborado em VISUAL C++, que pode ser executado no ambiente MS-DOS. Para tal propósito, é necessário construir um arquivo de descrição, conforme mostrado no QUADRO 4.1:

QUADRO 4.1 - ARQUIVO DE DESCRIÇÃO DO TREINAMENTO

```
C:\Imagens\Programas>train
Digite: TRAIN <descfile.des>
Formato do arquivo de descrição <descfile.des>
<source.raw>    <= nome da imagem para treinamento
<W>,<H>        <= dimensões da imagem para treinamento
<w>,<h>        <= dimensões do target
<limiar>        <= limiar para o treinamento
<n>            <= número de targets
<x>,<y>        <= posição do primeiro ponto
<x>,<y>        <= posição do segundo ponto
...
<x>,<y>        <= posição do n-ésimo ponto
<rede.net>     <= nome da rede a ser gerada
```

Na primeira linha do QUADRO 4.1 está indicado o endereço onde se localiza o programa fonte *train*. Na segunda linha, a instrução *Digite: Train <descfile.des>* significa que deve ser digitado o comando *train* seguido do nome do arquivo de descrição. A partir da 3ª linha, está indicado o formato do arquivo de descrição. O arquivo de descrição contém o nome da imagem para treinamento (<source. Raw>); as dimensões da imagem para treinamento (<W>,<H>), sendo *W* a largura da imagem e *H* a altura dessa imagem; as dimensões do ponto pré-sinalizado (target <w>,<h>), sendo *w* a largura e *h* a altura da imagem que o representa; o limiar para o treinamento, isto é, o erro mínimo permitido; o número de pontos pré-sinalizados (<n>), aí chamados de *targets*; as posições dos *n* pontos pré-sinalizados e. na última linha, o nome da rede que será treinada <rede.net>. O treinamento da Rede Neural

no nível 0, para os pontos de apoio pré-sinalizados em forma circular, convergiu após 65 iterações, com um tempo de processamento de 2 horas e 15 minutos. Por outro lado, o tempo de treinamento para os pontos de apoio pré-sinalizados em forma de cruz foi de 2 horas e 26 minutos, com 145 iterações.

4.2.2 Treinamento da Rede Neural no Nível 1

O treinamento da Rede Neural no nível 1 constitui o treinamento dos pontos pré-sinalizados para a imagem no nível 1. Para este treinamento é utilizada a imagem de treinamento indicada na FIGURA 4.1 por N1. Os conjuntos de treinamento estão mostrados na FIGURA 4.8, para os pontos em forma circular, e na FIGURA 4.11, para os pontos em forma de cruz. A camada de entrada para cada ponto pré-sinalizado é composta por uma matriz de "pixels" de 64 elementos (8x8 "pixels"), sendo que há uma camada escondida, com o mesmo número de elementos, e uma camada de saída. O treinamento, neste caso, foi efetuado sobre a imagem em tons de cinza. O tempo de treinamento da rede em nível 1 foi de aproximadamente 1 minuto, tanto para treinar os pontos pré-sinalizados em forma circular, quanto para treinar os pontos pré-sinalizados em forma de cruz. Da mesma forma que para o treinamento no nível 0, o arquivo de descrição mostrado no QUADRO 4.1 deve ser adaptado para este treinamento.

4.2.3 Treinamento da Rede Neural no Nível 2

O treinamento da RNA no nível 2 constitui o treinamento dos pontos pré-sinalizados para a imagem no nível 2. Para este treinamento é utilizada a imagem de treinamento indicada na FIGURA 4.1 por N2. A imagem que representa o conjunto de treinamento no nível 2 para os pontos circulares está mostrada na FIGURA 4.9 e a que representa o conjunto de treinamento para os pontos em cruz está mostrada na FIGURA 4.12. A rede de treinamento aqui também é composta por uma camada de entrada, uma camada escondida e uma camada de saída. Na camada de entrada, é apresentado à rede um conjunto de 16 elementos (4x4 "pixels"), para cada alvo pré-sinalizado. A camada escondida também apresenta os mesmos 16 elementos para cada alvo pré-sinalizado. Da mesma forma que para o treinamento nos níveis 0 e 1, o arquivo de descrição mostrado no QUADRO 4.1 deve ser

adaptado para o treinamento no nível 2. O tempo de treinamento da RNA para a imagem no nível 1 foi inferior a um minuto.

4.3 SIMULAÇÃO DA RNA POR MEIO DO TREINAMENTO EXECUTADO

Para a simulação dos pontos pré-sinalizados, usou-se um sub-programa denominado *SIMULA*. Para a execução desse programa no ambiente *MS-DOS*, é necessário conhecer algumas variáveis que estão representadas no arquivo de descrição do QUADRO 4.2. Essas variáveis são:

QUADRO 4.2 - DESCRIÇÃO DO SUB-PROGRAMA SIMULA

```
C:\Imagens\Programas>simula
Digite: SIMULA <descfile.des>.
-----
Formato do arquivo de descrição <descfile.des>:
-----
<level0.raw>   <= Nome da imagem nível 0
<W0>,<H0>     <= Dimensões da imagem nível 0
<redeBW.net>   <= Rede neural nível 0
<limiarBW>     <= Limiar da imagem em preto e branco
<level1.raw>   <= Nome da imagem nível 1
<W1>,<H1>     <= Dimensões da imagem nível 1
<rede1.net>    <= Rede neural nível 1
<limiar1>     <= Limiar nível 1
<level2.raw>   <= Nome da imagem nível 2
<W2>,<H2>     <= Dimensões da imagem nível 2
<rede2.net>    <= Rede neural nível 2
<limiar2>     <= Limiar nível 2
<pontos.raw>   <= Imagem nível 2 de pontos de busca
<W>,<H>       <= Dimensões da imagem de pontos de busca
<saída.out>    <= Nome do arquivo a ser gerado
-----
```

- O nome da imagem em nível 0 preto e branca transformada da imagem original em tons de cinza e os números de linhas e colunas desta imagem.
- A rede neural nível 0 treinada, bem como o limiar da imagem em preto e branco.
- O nome da imagem em nível 1 e os números de linhas e colunas dessa imagem.
- A rede neural nível 1 treinada, bem como o limiar da imagem neste nível.
- O nome da imagem em nível 2 e os números de linhas e colunas dessa imagem.
- A rede neural nível 2 treinada, bem como o limiar da imagem neste nível.

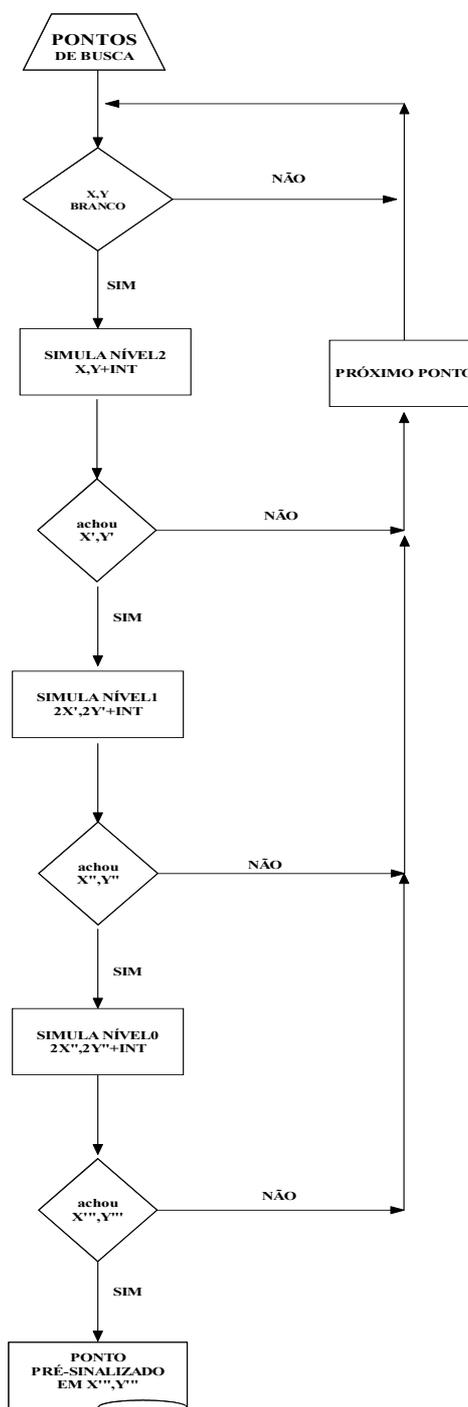
- O nome da imagem nível 2 dos pontos de busca, bem como os números de linhas e colunas desta imagem, e o nome do arquivo de saída gerado.

Na imagem erodida, indicada pelos "PONTOS DE BUSCA", no fluxograma da FIGURA 4.20 é feito o reconhecimento por RNA para localizar os possíveis pontos pré-sinalizados. Dessa estratégia resulta uma redução acentuada no tempo de processamento na busca dos pontos pré-sinalizados nas 4 fotos aéreas que contêm os mesmos. Os prováveis pontos pré-sinalizados serão gravados no arquivo de nome "saída.out".

Seguindo o fluxograma da FIGURA 4.20, pode-se "ler" o funcionamento da sub-rotina "SIMULA" da seguinte maneira:

- se, ao se fazer verificação dos "pontos de busca" na imagem erodida de pontos no nível 2, for encontrado um ponto branco com seu centro na posição (x, y) , onde x representa a posição da coluna e y a posição da linha, então é feito o reconhecimento na imagem da foto em nível 2, na posição (x, y) acrescida de um intervalo de três "pixels" para mais ou para menos, para corrigir possível problema de centro dos alvos pré-sinalizados; caso contrário, segue a procura (reconhecimento) na imagem dos pontos erodidos para o próximo ponto
- se o centro do possível ponto pré-sinalizado foi encontrado na imagem em nível 2 da foto aérea, a busca agora vai para a foto em nível 1, onde é feito o reconhecimento na imagem da foto, na posição que agora será $(2x, 2y) \pm 3$ "pixels"; caso contrário, segue a procura dos pontos na imagem erodida no nível 2.
- se o centro do possível ponto pré-sinalizado foi encontrado na imagem em nível 1 da foto aérea, a busca agora vai para a foto em nível 0, onde é feita a simulação na imagem, na posição que agora será $(4x, 4y) \pm 3$ "pixels". Caso contrário, segue a procura dos pontos na imagem erodida no nível 2

FIGURA 4.20 – FLUXOGRAMA DO PROCESSO DE RECONHECIMENTO POR REDES NEURAIS – SUBPROGRAMA SIMULA



No QUADRO 4.2, apresenta-se o arquivo de descrição do sub-programa “SIMULA”

4.4 RECONHECIMENTO POR CORRELAÇÃO

4.4.1 Reconhecimento e Identificação dos Pontos Pré-sinalizados Homólogos

A localização dos pontos de apoio pré-sinalizados, em duas fotos sucessivas que formam um par aerofotogramétrico, é feita usando-se a técnica de inteligência artificial por RNA. Este mesmo procedimento foi feito com o uso do conceito de correlação estatística. O sub-programa *alinha*, indicado no QUADRO 4.3, permite a identificação dos pontos homólogos na foto aérea, conhecida a posição dos pontos na foto da esquerda. Na primeira linha do arquivo de descrição, deve ser fornecido o nome da imagem da esquerda. Na segunda linha, as dimensões da imagem devem ser indicadas. Na terceira linha, indica-se o nome da imagem da direita, e na quarta linha, as suas dimensões. Na quinta linha, deve ser descrito o limiar para a correlação, e, na sexta linha, deve figurar o número de pontos da foto da esquerda que se deseja correlacionar com os da foto da direita. Nas linhas seguintes, devem ser indicadas as coordenadas dos centros dos pontos, na ordem: coluna, linha. As posições dos pontos da foto da esquerda foram determinadas com o uso do reconhecimento por RNA. Na antepenúltima e na penúltima linha, devem ser indicados, respectivamente, os percentuais de sobreposição horizontal e vertical. Na última linha, cria-se o nome do arquivo de saída das coordenadas dos pontos homólogos na foto da direita.

QUADRO 4.3 – ARQUIVO DE DESCRIÇÃO DO SUB-PROGRAMA ALINHA

```
C:\Imagens\Programas>alinha
Digite: ALINHA <descfile.des>.
-----
Formato do arquivo de descrição <descfile.des>:
-----
<left.raw>      <= Nome da imagem da esquerda
<wl>,<hl>      <= Dimensões da imagem da esquerda
<right.raw>    <= Nome da imagem da direita
<wr>,<hr>      <= Dimensões da imagem da direita
<limiar>       <= Limiar para correlação
<n>            <= numero de targets da imagem da esquerda
<x>,<y>        <= posição do primeiro target
<x>,<y>        <= posição do segundo target
...
<x>,<y>        <= posição do n-ésimo target
<hrz>         <= percentual de sobreposição horizontal
<vert>        <= percentual de sobreposição vertical
<saida.out>   <= Nome do arquivo a ser gerado
-----
```

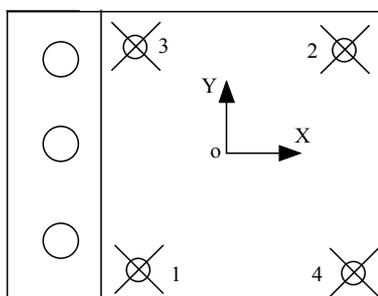
4.4.2 Reconhecimento e Identificação das Marcas Fiduciais

De acordo com o item 2.9.5, em um processo de identificação automática e leitura de coordenadas de pontos, devem ser em primeiro lugar obtidas as posições aproximadas desses pontos. O certificado de calibração da câmera usada na obtenção das fotos aéreas do presente trabalho fornece as coordenadas das marcas fiduciais, conforme esquema apresentado na FIGURA 4.21, de acordo com os dados de calibração. A FIGURA 4.21 apresenta a disposição das marcas fiduciais em sua representação do plano focal, considerando a câmara sendo vista por trás, ou o negativo visto com a emulsão para baixo. O referencial fiducial, fica definido de acordo com as coordenadas apresentadas na TABELA 4.1

TABELA 4.1 - REFERENCIAL FIDUCIAL

Marca Fiducial	Coordenada x (mm)	Coordenada y (mm)
01	-105,999	-105,978
02	105,996	106,022
03	-106,018	106,021
04	105,988	-105,978

FIGURA 4.21 - POSIÇÃO DAS MARCAS FIDUCIAIS



4.4.3 Valores Aproximados para as Marcas Fiduciais no Referencial de Imagem

As aerofotos foram digitalizadas de forma que $1 \text{ pixel} = 24 \mu\text{m}$ e com o conhecimento das coordenadas das marcas fiduciais, em mm, estas podem ser transformadas em coordenadas de imagem (coluna, linha). Considerando que as duas aerofotos usadas nos experimentos têm 9465 colunas e 9460 linhas, a relação existente entre o sistema de coordenadas de tela e o sistema fiducial é mostrada na FIGURA 4.22. Uma análise da FIGURA 4.22 permite relacionar as coordenadas de tela das marcas fiduciais (C,L) com as coordenadas do referencial fiducial, por meio das seguintes equações:

$$C = \frac{x}{0,024} + 4732,5 \quad (4.1)$$

$$L = -\frac{y}{0,024} + 4730 \quad (4.2)$$

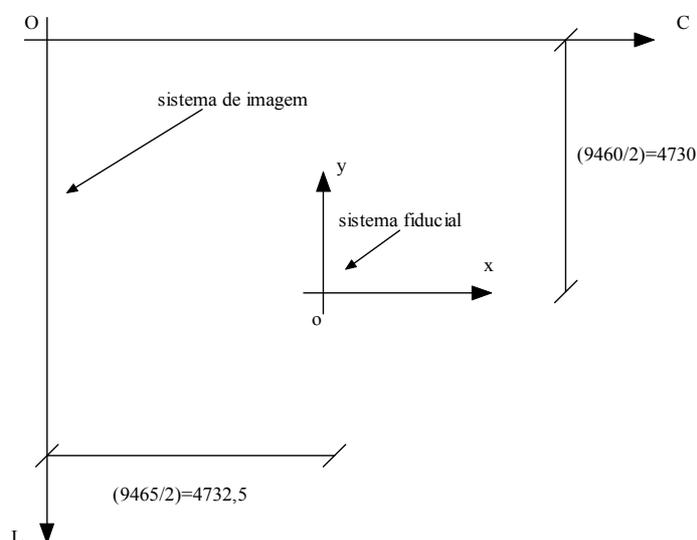
Aplicando-se as equações (4.1) e (4.2), são obtidas as coordenadas aproximadas de imagem para as marcas fiduciais representadas na TABELA 4.2.

TABELA 4.2 – COORDENADAS DE IMAGEM APROXIMADAS DOS CENTROS DAS MARCAS FIDUCIAIS

MARCA FIDUCIAL	COLUNA (C)	LINHA (L)
1	316	9146
2	9149	312
3	315	312
4	9149	9146

Com o conhecimento aproximado das coordenadas de imagem das marcas fiduciais, a área de busca dessas marcas pode ser restringida, o que diminui o tempo de processamento no processo de correlação que será aplicado na seqüência.

FIGURA 4.22 - RELAÇÃO ENTRE SISTEMA DE IMAGEM E SISTEMA FIDUCIAL



4.4.4 Identificação das Marcas Fiduciais

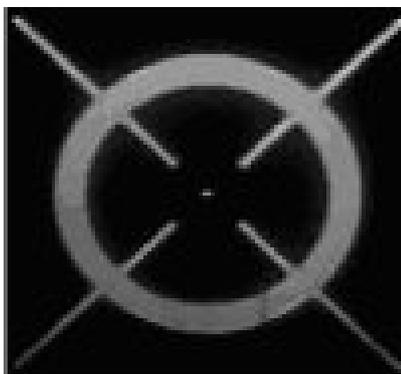
O procedimento aqui utilizado é o da correlação estatística e os valores aproximados. Para identificar a posição das marcas fiduciais, utiliza-se o arquivo de descrição mostrado do QUADRO 4.4. A primeira linha desse arquivo contém a

marca fiducial de amostra apresentada na FIGURA 4.23. A segunda linha contém as dimensões: 101 linhas por 101 colunas, da amostra. Na terceira linha, está descrita a imagem (foto) na qual se quer identificar as marcas fiduciais. Na quarta linha, é indicado o arquivo (*saída.out*) onde se deseja gravar as coordenadas das marcas fiduciais identificadas.

QUADRO 4.4 – ARQUIVO DE DESCRIÇÃO PARA IDENTIFICAR MARCAS FIDUCIAIS

```
C:\Imagens\Programas>fiducial
Digite: FIDUCIAL <descfile.des>.
-----
Formato do arquivo de descricao <descfile.des>:
-----
<left.raw>      <= Nome da imagem da esquerda
<wl>,<hl>      <= Dimensoes da imagem da esquerda
<right.raw>     <= Nome da imagem da direita
<wr>,<hr>     <= Dimensoes da imagem da direita
<saida.out>    <= Nome do arquivo a ser gerado
-----
```

FIGURA 4.23 - AMOSTRA DE MARCA FIDUCIAL



5 EXPERIMENTOS

5.1 PONTOS PRÉ-SINALIZADOS EM PAREDES VERTICAIS

A imagem para o treinamento que forneceu melhores resultados foi aquela contendo os valores dos tons de cinza dos pixels de dois pontos distintos pré-sinalizados escolhidos aleatoriamente em forma de círculo e dois pontos pré-sinalizados em forma de cruz, bem como partes da imagem do fundo da parede. A codificação do programa fonte para o treinamento com a finalidade de identificar o alvo foi elaborada no *MATLAB*. O treinamento foi executado por feed forward-Backpropagation. Os primeiros treinamentos foram executados para que o ponto pré-sinalizado fosse identificado na posição os quais foram fotografados, como aparecem na FIGURA 3.1. Estes primeiros treinamentos foram elaborados para duas situações. Na primeira foi considerado o ponto de apoio pré-sinalizado como sendo aquele em forma de cruz. Na segunda situação, considerou-se o ponto de apoio pré-sinalizado como sendo aquele em forma de círculos concêntricos.

5.1.1 Treinamento do Alvo na Forma de Cruz

A FIGURA 5.1 , apresenta o conjunto de treinamento utilizado para o treinamento do alvo em forma de cruz. Este conjunto é uma imagem de 183x33 *pixels*. O alvo cruz foi treinado em sua posição original, e também em várias outras posições , desde zero graus até 90 graus. Em relação à referência fotografada na FIGURA 3.1.

Para que a rede neural reconheça a posição exata do alvo cruz, considera-se esta cruz contida, como no presente caso em uma matriz de 20x20 *pixels*, cujo canto esquerdo superior tem as coordenadas L=5;C=5 e a partir daí é feito um cálculo para saber se o *pixel* está ou não contido nesta matriz. Este procedimento é feito novamente para a posição do canto esquerdo superior da segunda cruz da imagem de treinamento com as coordenadas L=5; C=105, isto é, na linha 5 e coluna 105. As últimas linhas do código fonte *MATLAB* indicam a criação da rede neural propriamente dita. A rede neural foi configurada com três camadas. A primeira com três neurônios *logsig* e a segunda com um neurônio *logsig*, isto é, neurônios que utilizam a função de transferência logística sigmóide. Aqui deve ser observado que

esta configuração foi obtida por sucessivas experimentações, isto é, variando o número de camadas e de neurônios. Para que o treinamento fosse encerrado, estabeleceu-se o número máximo de 600 iterações (épocas) no processo de retropropagação, bem como o mínimo valor para o desvio padrão de 10^{-20} . Finalmente, o treinamento é levado a efeito, onde a saída para o mesmo será binária, indicando 0 para a matriz de 20x20 pixels não-alvo e 1 para a matriz de 20x20 pixels alvo. Foram obtidos os resultados mostrados na TABELA 5.1, para o treinamento com alvo cruz.

FIGURA 5.1 - CONJUNTO DE TREINAMENTO PARA O ALVO EM CRUZ



TABELA 5.1 – TREINAMENTO COM ALVO CRUZ

Giro em graus	Iterações	Desvio Padrão	Tempo (min)
0	0	0,0938152	10
	157	7374×10^{-12}	
11,25	0	0,648006	09
	131	$1,21496 \times 10^{-11}$	
22,50	0	0,820623	13
	184	$6,57463 \times 10^{-12}$	
33,75	0	0,0945931	06
	69	$1,14321 \times 10^{-11}$	
45	0	0,818426	08
	95	$2,63644 \times 10^{-12}$	
56,25	0	0,326034	19
	296	$4,88471 \times 10^{-12}$	
67,50	0	0,0977985	23
	314	$1,2425 \times 10^{-11}$	
78,75	0	0,129627	25
	343	$1,3605 \times 10^{-11}$	

5.1.2 Treinamento do Alvo na Forma de Círculo

A FIGURA 5.2 apresenta o conjunto de treinamento para o alvo circular. Nesta hipótese, na qual o ponto pré-sinalizado é considerado a imagem dos círculos concêntricos, o código fonte é praticamente o mesmo para identificar cruces. As

mudanças neste caso são: o tamanho da imagem de treinamento que é de 162x36 *pixels*, mostrada na FIGURA 5.2; as coordenadas do canto esquerdo superior da primeira matriz que contém a imagem de círculos concêntricos são L=8 e C=8. Neste caso também o treinamento ficou simplificado: bastou treinar o ponto pré-sinalizado em forma de círculos para a posição de zero grau, para que a rede reconheça na fase de simulação (testes) outras posições com ângulos diferentes de zero grau. A curva que representa o desempenho deste treinamento está representada na FIGURA 5.3 . Nesta Figura, o eixo das abscissas representa o número de iterações (épocas) para o sucesso do treinamento e o eixo das ordenadas, o desvio padrão correspondente em determinada iteração. Os resultados do treinamento apresentam-se na TABELA 5.2.

FIGURA 5.2 – CONJUNTO DE TREINAMENTO PARA O ALVO CIRCULAR



FIGURA 5.3 – DESEMPENHO DO TREINAMENTO COM ALVOS CIRCULARES

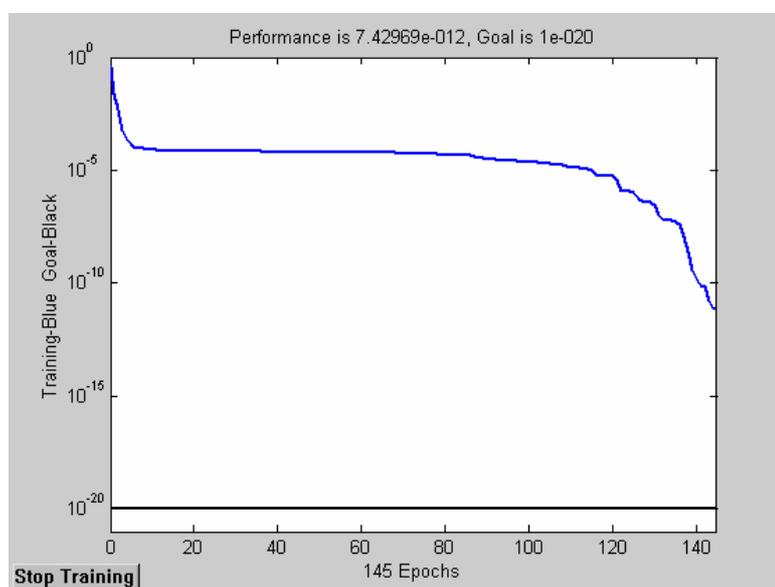


TABELA 5.2 – TREINAMENTO COM ALVO CIRCULAR

Giro em graus	Iterações	Desvio Padrão	Tempo (min)
0	0	0,39331	09
	145	$7,42969 \times 10^{-12}$	

No caso do alvo circular, não houve necessidade de efetuar treinamento para giros diferentes de zero grau.

5.1.3 Identificação dos alvos

O código fonte para a identificação das posições dos alvos elaborou-se em separado do código fonte de treinamento. Inicialmente é levada a efeito a leitura da imagem na qual se pretende identificar o alvo. Os tamanhos das matrizes para os testes de identificação devem ser aqueles do treinamento, isto é, 20x20 pixels. Se o teste for para identificar alvos do tipo cruz, então devem ser considerados todos os giros dos alvos candidatos do tipo cruz, desde zero grau até 78°45'. Se for identificado um alvo, então estará indicada a sua posição central na matriz de 20x20. *pixels*.

O primeiro teste elaborado foi na imagem I183x33.raw representada na FIGURA 5.1, que é a própria imagem de treinamento. Os resultados estão indicados na TABELA 5.3. Analisando a FIGURA 5.1, nota-se duas imagens que representam o símbolo de cruz. Os resultados dos centros dessas cruzes estão indicados em negrito na TABELA 5.3, isto é, o centro da matriz da primeira cruz ocorre na posição Linha 15 e Coluna 15, onde o valor do limiar de **0,999995577** é maior do que para as outras três posições indicadas. O centro da matriz da ocorrência da segunda cruz está na posição Linha 15 e Coluna 115, com o valor de limiar de **0,999995520**, que é maior do que as outras duas posições indicadas.

Outros testes de identificação de alvos na parede vertical podem ser consultados em (WANDRESEN; MITISHITA; ANDRADE, 2002, p.7-9).

TABELA 5.3 - IDENTIFICAÇÃO DO ALVO CRUZ NA IMAGEM DE TREINAMENTO

GIRO EM GRAUS	LINHA DA POSIÇÃO CENTRAL	COLUNA DA POSIÇÃO CENTRAL	LIMIAR
0	14	15	0,999979509
0	15	14	0,999991486
0	15	15	0,999995577
0	15	16	0,999995480
0	15	114	0,999990318
0	15	115	0,999995520
0	16	115	0,999994400

5.2 PONTOS PRÉ-SINALIZADOS USANDO RNA

Foram realizados testes com os pontos pré-sinalizados em 4 fotos aéreas, onde os mesmos aparecem. Somente os pontos pré-sinalizados da primeira foto, isto é, da foto 7213, foram usados para o treinamento generalizado da RNA.

5.2.1 Ponto Pré-sinalizado em Forma Circular

No resultado apresentado na saída da simulação, figuram os 12 alvos (pontos) pré-sinalizados em forma circular presentes na região de testes. Foram identificados todos os pontos pré-sinalizados do tipo circular, havendo interferência de uma ambigüidade, que foi o ponto com coordenadas de imagem (6044,2018). Na TABELA 5.4 e na TABELA 5.5, estão indicadas além das posições dos pontos pré-sinalizados do tipo circular na foto 1 e na foto 2, as descrições dos mesmos.

TABELA 5.4 – IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES NA FOTO 1

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
5503	1923	1,000000	Jardim das Américas (1)
5818	2380	1,000000	Cancha Educação Física
8621	2408	1,000000	Eng. Florestal
7318	3149	1,000000	Usinas Piloto
6889	3391	1,000000	Geodésia
8502	3792	1,000000	Química
7331	3931	1,000000	Eng. Elétrica
5240	4146	1,000000	Jardim das Américas (2)
8541	4554	1,000000	Biológicas (1)
9172	5107	1,000000	Biológicas (2)
7263	6578	1,000000	Mercadorama
8242	7362	1,000000	Cajuru - Favela

TABELA 5.5 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES NA FOTO 2

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
7346	1061	1,000000	Jardim Botânico
2468	1861	1,000000	Jardim das Américas (1)
2799	2320	1,000000	Cancha Educação Física
4368	3078	1,000000	Usinas Piloto
3920	3328	1,000000	Geodésia
5607	3711	1,000000	Eng. Química
4393	3869	1,000000	Eng. Elétrica
2215	4118	1,000000	Jardim das Américas (2)

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
5647	4479	1,000000	Biológicas (1)
6294	5026	1,000000	Biológicas (2)
4373	6550	1,000000	Mercadorama
5412	7324	1,000000	Cajuru (1)

Comparando-se a TABELA 5.4 com a TABELA 5.5, verifica-se que:

- 1) o ponto homólogo com descrição Eng. Florestal na TABELA 5.4 não foi identificado na TABELA 5.5;
- 2) foi identificado na TABELA 5.5 o ponto com descrição Jardim Botânico, que não consta da identificação na TABELA 5.4, pelo fato de o mesmo não pertencer à foto 1, isto é, não tem homólogo;
- 3) os pontos com descrições Cajuru (2) e Cajuru (3) não foram identificados na foto 2, porém, eles não pertencem à foto1, isto é, não estão na região de recobrimento.

Na TABELA 5.6 estão apresentadas as posições dos pontos pré-sinalizados figurantes na foto 3 e as descrições dos mesmos.

TABELA 5.6 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES NA FOTO 3

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
4574	882	1,000000	Jardim Botânico
1495	2935	1,000000	Usinas Piloto
1023	3185	1,000000	Geodésia
2781	3586	1,000000	Eng. Química
1515	3737	1,000000	Eng. Elétrica
2804	4365	1,000000	Biológicas(1)
3457	4926	1,000000	Biológicas(2)
5662	5934	1,000000	Cajurú (3)
1484	6444	1,000000	Mercadorama
2561	7236	1,000000	Cajurú(1)

Comparando-se a TABELA 5.5 com a TABELA 5.6, verifica-se que:

- 1) foram encontrados nove dos doze pontos em forma circular pré-sinalizados homólogos, nas fotos 2 e 3;
- 2) os pontos com descrições Eng. Florestal, Cajuru (2) e Cajuru (3) não foram identificados na foto 2 e nem na foto 3;
- 3) os pontos com descrição Jardim das América (1), Jardim das Américas(2) e Cancha Educação Física foram identificados na foto 2, porém os seus homólogos não estão na foto 3, isto é, não estão na região de recobrimento.

Na TABELA 5.7 estão apresentadas as posições dos pontos pré-sinalizados figurantes na foto 4 e as descrições dos mesmos.

TABELA 5.7 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CIRCULARES NA FOTO 4

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
1609	684	1,000000	Jardim Botânico
518	4809	1,000000	Biológicas (2)

Comparando a TABELA 5.6 com a TABELA 5.7, conclui-se que:

- 1) foram encontrados dois dos quatro pontos em forma circular pré-sinalizados homólogos, nas fotos 3 e 4;
- 2) os pontos com descrição Cajuru (2) e Cajuru (3) não foram identificados na foto 4.

5.2.2 Pontos Pré-sinalizados do Tipo Cruz

Nos resultados apresentados na saída da simulação, figuram 11 dos 12 alvos (pontos) pré-sinalizados em forma de cruz, presentes nas fotos 1 e 2. Foram identificados todos os 11 pontos pré-sinalizados do tipo cruz, havendo interferência de três ambigüidades, que são os pontos com coordenadas de imagem, respectivamente (6264, 1176), (5049, 2145) e (6556, 7260).

Na TABELA 5.8 e na TABELA 5.9, estão indicadas, além das posições dos pontos pré-sinalizados do tipo cruz nas fotos 1 e 2 respectivamente, as descrições dos mesmos. O ponto pré-sinalizado não identificado foi aquele com descrição Jardim das Américas (1), próximo ao Hospital Erasto Gaertner.

TABELA 5.8 -IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 1

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
7404	2051	1,000000	Departamento de Educação Física da UFPR
5404	2553	1,000000	Pista de Atletismo
7064	2947	1,000000	Copel – Centro Politécnico
7147	3590	1,000000	Usinas Piloto
7634	3774	1,000000	Engenharia Química
5874	3831	1,000000	Jardim das Américas(2)
8616	4142	1,000000	Biológicas (1)

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
8393	4279	1,0000000	Prédio da Administração
8952	4958	1,0000000	Biológicas (2)
8479	7316	1,0000000	Cajurú (1)
6202	7390	1,0000000	Jardim das Américas (Mercadorama)

. Na TABELA 5.9, estão indicadas, as posições dos pontos pré-sinalizados do tipo cruz na foto 2 e as suas descrições.

TABELA 5.9 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 2

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
6976	1881	1,0000000	Jardim Botânico
4469	1971	1,0000000	Departamento de Educação Física da UFPr
1672	2351	1,0000000	Jardim das Américas(1)
4107	2877	1,0000000	Copel – Centro Politécnico
4192	3526	1,0000000	Usinas Piloto
4709	3705	1,0000000	Engenharia Química
2878	3788	1,0000000	Jardim das Américas(2)
5721	4063	1,0000000	Biológicas (1)
5497	4204	1,0000000	Prédio da Administração
7230	6078	1,0000000	Cajurú (2)
5653	7273	1,0000000	Cajurú (1)
3283	7396	1,0000000	Jardim das Américas (Mercadorama)

O ponto de coordenadas de imagem (6566, 2670) foi uma ambigüidade.

Comparando a TABELA 5.8 com a TABELA 5.9, observa-se que:

- 1) foram encontrados, na foto 2, 10 dos 12 pontos de apoio em forma de cruz que estão na área comum de recobrimento;
- 2) o ponto com descrição Biológicas (2) foi identificado na foto 1 e não foi identificado na foto 2, e faz parte do recobrimento;
- 3) o ponto com descrição Cajuru (3) não foi identificado na foto 2, mas o seu homólogo não pertence à foto 1;
- 4) o ponto com descrição Pista de Atletismo foi identificado na foto 1, mas não foi identificado na foto 2, sendo que existe o seu homólogo na foto 2;
- 5) o ponto com descrição Cajuru, na TABELA 5.9, mostra que ele foi identificado na foto 2, mas não pertence à região de recobrimento;
- 6) foram identificados erradamente, como pontos pré-sinalizados, aqueles com coordenadas (6264,1176), (5049,2145), (6556,7260), resultado de

reconhecimento da foto 1 e o ponto com coordenadas (6556,2670) do resultado de reconhecimento da foto 2.

Na TABELA 5.10 , estão indicadas, as posições dos pontos pré-sinalizados do tipo cruz na foto 3 e as suas descrições.

TABELA 5.10 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 3

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
4176	1724	1,0000000	Jardim Botânico
1234	2729	1,0000000	Copel – Centro Politécnico
1305	3387	1,0000000	Usinas Piloto
2888	3944	1,0000000	Biológicas(2)
2658	4085	1,0000000	Prédio da Administração
3228	4775	1,0000000	Biológicas (2)
5871	6572	1,0000000	Cajuru (3)
365	7277	1,0000000	Jardim das Américas (Mercadorama)

O ponto com coordenadas de imagem (8369, 4543) não é um ponto pré-sinalizado e foi reconhecido como o sendo pela rede neural na foto 3.

Comparando a TABELA 5.9 com a TABELA 5.10 , observa-se que:

- 1) foram encontrados, na foto 2, 8 dos 12 pontos de apoio em forma de cruz que estão na área comum de recobrimento das fotos 2 e 3;
- 2) o ponto com descrição Biológicas (1) foi identificado na foto 2 e não foi identificado na foto 3, e faz parte do recobrimento;
- 3) o ponto com descrição Engenharia Química foi identificado na foto 2 e não foi identificado na foto 3, e faz parte do recobrimento;
- 4) o ponto com descrição Departamento de Educação Física foi identificado na foto 2, não foi identificado na foto 3, e faz parte do recobrimento;
- 5) o ponto com descrição Cajuru (2) foi identificado na foto 2 e não foi identificado na foto 3, e faz parte do recobrimento;
- 6) o ponto com descrição Jardim das Américas (1) foi identificado na foto 2, mas não faz parte do recobrimento;
- 7) os pontos com descrição Cajuru(1) e Cajuru(2) foram identificados na foto 2 e não foram identificados na foto 3, fazendo parte, no entanto, do recobrimento comum entre as duas fotos;

8) o ponto Cajuru(3) foi identificado na foto 3 e não foi identificado na foto 2, fazendo parte, no entanto, do recobrimento comum entre as duas fotos.

Na TABELA 5.11, estão indicadas, as posições dos pontos pré-sinalizados do tipo cruz na foto 4 e as suas descrições.

TABELA 5.11 - IDENTIFICAÇÃO DOS PONTOS PRÉ-SINALIZADOS CRUZ NA FOTO 4

COLUNA DA POSIÇÃO CENTRAL	LINHA DA POSIÇÃO CENTRAL	LIMIAR	DESCRIÇÃO
1204	1548	1,0000000	Jardim Botânico
284	4657	1,0000000	Biológicas(2)
3033	6463	1,0000000	Cajuru (3)

O ponto com coordenadas de imagem (3415, 4350) não é um ponto pré-sinalizado, mas foi reconhecido pela Rede Neural como o sendo.

Comparando a TABELA 5.10 com a TABELA 5.11, observa-se que:

- 1) foram encontrados, na foto 4, 3 dos 4 pontos pré-sinalizados em forma de cruz, pertencentes à área de recobrimento das fotos;
- 2) o ponto não encontrado nas fotos 3 e 4 foi aquele com descrição Cajuru(2).

5.3 PONTOS PRÉ-SINALIZADOS USANDO CORRELAÇÃO E RNA

Foram realizados testes para identificação dos pontos pré-sinalizados para as mesmas 4 fotos do item 5.2.

5.3.1 Ponto Pré-sinalizado em Forma Circular

USANDO OS RESULTADOS OBTIDOS NA IDENTIFICAÇÃO NA FOTO DA ESQUERDA, POR RNA DOS PONTOS PRÉ-SINALIZADOS EM FORMA CIRCULAR, DA TABELA 5.4, OS RESULTADOS DAS CORRELAÇÕES PARA OS PONTOS HOMÓLOGOS DO PAR DE FOTOS 1-2 ESTÃO APRESENTADOS A SEGUIR NA

TABELA 5.12.

O tempo de execução para encontrar as posições dos 12 pontos circulares pré-sinalizados no par de fotos 1-2 foi menor do que 1 minuto.

TABELA 5.12 – IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 1-2 POR CORRELAÇÃO

COORDENADAS DA FOTO 1 POR RNA		COORDENADAS DA FOTO 2 POR CORRELAÇÃO		VALOR DA CORRELAÇÃO	DESCRIÇÃO
COLUNA	LINHA	COLUNA	LINHA		
5503	1923	2468	1861	0,9888105	Jardim das Américas(1)
5818	2380	2799	2320	0,9787084	Cancha Educação Física
8621	2408	5714	2316	0,9554002	Engenharia Florestal
7318	3149	4368	3078	0,9806279	Usinas Piloto
6889	3391	3920	3328	0,9757326	Geodésia
8502	3792	5607	3711	0,9714036	Engenharia Química
7331	3931	4393	3869	0,9666718	Engenharia Elétrica
5240	4146	2216	4117	0,9659104	Jardim das Américas (2)
8541	4554	5647	4479	0,9590841	Biológicas (1)
9172	5107	6293	5026	0,9704794	Biológicas (2)
7263	6578	4373	6550	0,9699956	Mercadorama
8242	7362	5412	7325	0,9533399	Cajuru (1)

COMPARANDO A

TABELA 5.12, com a TABELA 5.4 e a TABELA 5.5, observa-se , com relação à identificação por RNA, na região de recobrimento da foto 1 e da foto 2, que o ponto Engenharia Florestal foi identificado na foto 1, mas não o foi na foto 2;

A TABELA 5.13 apresenta a identificação por correlação dos pontos circulares no par de fotos 2-3.

TABELA 5.13 – IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 2-3 POR CORRELAÇÃO

COORDENADAS DA FOTO2 POR RNA		COORDENADAS DA FOTO3 POR CORRELAÇÃO		VALOR DA CORRELAÇÃO	DESCRIÇÃO
COLUNA	LINHA	COLUNA	LINHA		
7346	1061	4574	881	0,9557024	Jardim Botânico
5714	2316	2911	2166	0,9787540	Engenharia Florestal
4368	3078	1495	2934	0,9725848	Usinas Piloto
3920	3328	1023	3184	0,9715321	Geodésia
5607	3711	2781	3585	0,9883682	Química
4393	3869	1515	3737	0,9791648	Engenharia Elétrica
5647	4479	2804	4365	0,9668872	Biológicas (1)
6294	5026	3457	4925	0,9795116	Biológicas (2)
8426	5997	5661	5934	0,9607312	Cajurú (3)
4373	6550	1484	6443	0,9764842	Mercadorama
7120	6600	4328	6530	0,9484487	Cajurú (2)
5412	7324	2561	7236	0,9613195	Cajurú(1)

Comparando a TABELA 5.13, com a TABELA 5.5 e a TABELA 5.6, observa-se, com relação à identificação por RNA, na região de recobrimento das fotos 2 e 3 que:

- 1) o ponto Engenharia Florestal não foi identificado nas fotos 2 e 3;
- 2) o ponto Cajuru (3) foi identificado na foto 3, mas não o foi na foto 2;
- 3) o ponto Cajuru (2) não foi identificado na foto 3 e nem na foto 2.

O tempo de execução para encontrar as posições dos 4 pontos circulares pré-sinalizados no par de fotos 3-4 foi de 15 segundos.

A TABELA 5.14 apresenta a identificação por correlação dos pontos em forma circular no par de fotos 3-4.

TABELA 5.14 - IDENTIFICAÇÃO DOS PONTOS “CIRCULARES” NO PAR DE FOTOS 3-4 POR CORRELAÇÃO

COORDENADAS DA FOTO 3 POR RNA		COORDENADAS DA FOTO 4 POR CORRELAÇÃO		VALOR DA CORRELAÇÃO	DESCRIÇÃO
COLUNA	LINHA	COLUNA	LINHA		
4574	871	1609	683	0,9535332	Jardim Botânico
3457	4926	518	4809	0,9712300	Biológicas (2)
5662	5934	2801	5817	0,9774252	Cajuru (3)
4328	6530	1465	6431	0,9590143	Cajuru (2)

Comparando a TABELA 5.14 com a TABELA 5.6 e a TABELA 5.7, observa-se, com relação à identificação por RNA, na região de recobrimento das fotos 3 e 4, que:

- 1) o ponto Cajuru (2) não foi identificado na foto 3 e nem na foto 4;
- 2) o ponto Cajuru (3) foi identificado na foto 3 e não foi identificado na foto 4.

5.3.2 Pontos Pré-sinalizados em Forma de Cruz

Usam-se, a seguir, os resultados obtidos na identificação, por RNA, dos pontos pré-sinalizados em forma de cruz da TABELA 5.8. Os resultados das correlações para os pontos homólogos estão apresentados a seguir na TABELA 5.15. O ponto apresentado em negrito nesta tabela não foi identificado por RNA.

A TABELA 5.14 apresenta a identificação por correlação dos pontos circulares no par de fotos 2-3.

A TABELA 5.15 apresenta a identificação por correlação dos pontos circulares no par de fotos 1-2

TABELA 5.15 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 1-2 POR CORRELAÇÃO

COORDENADAS DA FOTO 1 POR RNA		COORDENADAS DA FOTO 2 CORRELAÇÃO		VALOR DA CORRELAÇÃO	DESCRIÇÃO
COLUNA	LINHA	COLUNA	LINHA		
7404	2051	4469	1970	0,9680901	Curso de Educação Física da UFPR
4729	2398	1671	2351	0,9651465	Jardim das Américas (1)
5404	2553	2377	2500	0,9834654	Pista de Atletismo
7063	2946	4107	2877	0,9748217	Copel – Centro Politécnico
7147	3590	4192	3526	0,8565168	Usinas Piloto
7634	3774	4709	3706	0,8322947	Engenharia Química
5874	3831	2877	3788	0,9639765	Jardim das Américas(2)
8616	4142	5722	4063	0,9567567	Biológicas (1)
8393	4279	5498	4204	0,9561897	Prédio da Administração
8952	4958	6068	4880	0,9817763	Biológicas (2)
8479	7316	5653	7273	0,9518303	Cajuru (1)
6202	7390	3283	7397	0,9599069	Mercadorama

Comparando a TABELA 5.15 com a TABELA 5.8 e a TABELA 5.9, observa-se, com relação à identificação por RNA, na região de recobrimento da foto1 e da foto 2, que:

- 3) O ponto Pista de Atletismo foi identificado na foto1, mas não o foi na foto 2;
- 4) o ponto Jardim das Américas1 foi identificado na foto1, mas não o foi na 2;
- 5) o ponto Biológicas (2), foi identificado na foto1, mas não o foi na foto 2.

A TABELA 5.16 apresenta a identificação por correlação dos pontos circulares no par de fotos 3-4.

TABELA 5.16 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 2-3 POR CORRELAÇÃO

COORDENADAS DA FOTO 2 POR RNA		COORDENADAS DA FOTO 3 POR CORRELAÇÃO		VALOR DA CORRELAÇÃO	DESCRIÇÃO
COLUNA	LINHA	COLUNA	LINHA		
6976	1881	4175	1724	0,9547829	Jardim Botânico
4469	1971	1637	1810	0,9617282	Curso de Educação Física da UFPR
4107	2877	1233	2729	0,9641983	Copel – Centro Politécnico
4192	3526	1305	3387	0,8352554	Usinas Piloto
4709	3705	1847	3573	0,8379992	Engenharia Química
5721	4064	2888	3945	0,9632181	Biológicas (1)
5497	4204	2658	4085	0,9632181	Prédio da Administração
6068	4880	3228	4775	0,9702519	Biológicas (2)
7230	6078	4441	6002	0,9070644	Cajuru(2)
8625	6622	5871	6572	0,9383291	Cajuru(3)
5653	7273	2807	7188	0,9555639	Cajuru(1)
3283	7396	364	7276	0,9566431	Mercadorama

Comparando a TABELA 5.16 com a TABELA 5.9 e a TABELA 5.10, observa-se, com relação à identificação por RNA, na região de recobrimento da foto 2 e da foto 3, que:

- 1) o ponto Biológicas (2) foi identificado na foto 3, mas não o foi na foto 2;
- 2) o ponto Cajuru (2) foi identificado na foto 2, mas não o foi na foto 3;
- 3) o ponto Cajuru (3) foi identificado na foto 3, mas não o foi na foto 2;
- 4) O ponto Cajuru (1) foi identificado na foto 2, mas não o foi na foto 3.

A TABELA 5.17 apresenta a identificação por correlação dos pontos circulares no par de fotos 3-4.

TABELA 5.17 - IDENTIFICAÇÃO DOS PONTOS “CRUZ” NO PAR DE FOTOS 3-4 POR CORRELAÇÃO

COORDENADAS DA FOTO 3 (COLUNA, LINHA)	COORDENADAS DA FOTO 4 (COLUNA,LINHA)	VALOR DA CORRELAÇÃO	DESCRIÇÃO
3228,4775	284,4658	0,9567938	Biológicas (2)
4176,1724	1204,1548	0,9854099	Jardim Botânico
5871,6572	3033,6464	0,9363725	Cajuru (3)
4441,6002	1569,5894	0,8804936	Cajuru(2)

Comparando a TABELA 5.17 com a TABELA 5.10 e TABELA 5.11, observa-se, com relação à identificação por RNA, na região de recobrimento da foto 3 e da foto 4, que o ponto Cajuru (2) não foi identificado na foto 3, bem como não o foi na foto 4.

Na TABELA 5.18 e na TABELA 5.19 estão apresentados os percentuais de identificação dos pontos pré-sinalizados em cada uma das fotos e também nos pares que estas fotos formam.

TABELA 5.18 – RESUMO DO DESEMPENHO DO RECONHECIMENTO DOS PONTOS PRÉ-SINALIZADOS DO TIPO CÍRCULO POR RNA

FOTO	PAR	Nº. PONTOS CIRCULARES	PONTOS COMUNS DO PAR	RECONHECIMENTO			
				PONTOS	%	PONTOS - PAR	%
1	1-2	12	12	12	100	---	---
2	-----	14	----	11	78,6	11	91,7
3	2-3	12	12	10	83,3	9	75
4	3-4	4	4	2	50	2	50

TABELA 5.19 - RESUMO DO DESEMPENHO DO RECONHECIMENTO DOS PONTOS PRÉ-SINALIZADOS DO TIPO CRUZ POR RNA

FOTO	PAR	Nº. PONTOS EM FORMA DE CRUZ	PONTOS COMUNS DO PAR	RECONHECIMENTO			
				PONTOS	%	PONTOS - PAR	%
1	1-2	12	12	11	91,7	---	----
2	-----	16	---	12	75	9	75
3	2-3	---	12	+8	66,7	5	41,7
4	3-4	4	4	3	75	3	75

5.4 PONTOS NATURAIS USANDO CORRELAÇÃO

Usando-se 15 pontos naturais, escolhidos na foto1, na região de recobrimento com a foto 2, foi feita a aplicação do programa *alinha*, e obtiveram-se os seguintes resultados para a localização dos homólogos desses 15 pontos na foto 2, indicados no QUADRO 5.1

QUADRO 5.1 – ARQUIVO DE SAÍDA DA CORRELAÇÃO PARA OS PONTOS NATURAIS

<4427,2634> -- <1350,2594,9.232418e-001>
<5768,2317> -- <2745,2257,9.461639e-001>
<5384,5063> -- <2384,5046,9.378204e-001>
<7460,5852> -- <4555,5809,8.501960e-001>
<6731,7051> -- <3829,7041,9.299665e-001>
<6611,4640> -- <3653,4597,9.881865e-001>
<8038,4694> -- <5136,4629,9.196640e-001>
<8705,5063> -- <5816,4990,9.615046e-001>
<8603,3745> -- <5709,3662,9.877671e-001>
<9091,2788> -- <6201,2692,9.726203e-001>
<8618,4398> -- <5726,4321,9.682081e-001>
<8578,5477> -- <5693,5410,9.689121e-001>
<7331,2870> -- <4387,2797,8.529521e-001>
<6834,2013> -- <3863,1938,9.755607e-001>
<6248,4318> -- <3273,4275,7.210630e-001>

5.5 MARCAS FIDUCIAIS USANDO CORRELAÇÃO

5.5.1 Marcas Fiduciais da Foto 1

Com o uso de uma das marcas fiduciais da foto 1, como imagem de amostra, para a correlação estatística, e com os valores aproximados das marcas fiduciais, conforme obtidos no item 4.4.3, foram obtidas as coordenadas dos centros das marcas fiduciais das 4 fotos usadas na região de testes.

A TABELA 5.20, a TABELA 5.21, a TABELA 5.22 e a TABELA 5.23, apresentam os resultados da identificação das marcas fiduciais por correlação, respectivamente das fotos 1, 2,3 e 4.

A marca fiducial do canto esquerdo inferior da foto 1, conforme indicado na TABELA 5.20, representa a marca usada como matriz de *pixels* de amostra para as correlações.

TABELA 5.20 – MARCAS FIDUCIAIS DA FOTO 1

COLUNA	LINHA	CORRELAÇÃO	DESCRIÇÃO
408	467	0,7761003	Canto esquerdo superior
8946	501	0,8027423	Canto direito superior
359	8948	1,0000000	Canto esquerdo inferior
8899	8986	0,9116442	Canto direito inferior

TABELA 5.21 - MARCAS FIDUCIAIS DA FOTO 2

COLUNA	LINHA	CORRELAÇÃO	DESCRIÇÃO
468	477	0,7836457	Canto esquerdo superior
9007	513	0,8096662	Canto direito superior
417	8959	0,9881501	Canto esquerdo inferior
8958	8999	0,9022185	Canto direito inferior

TABELA 5.22 - MARCAS FIDUCIAIS DA FOTO 3

COLUNA	LINHA	CORRELAÇÃO	DESCRIÇÃO
440	500	0,7794369	Canto esquerdo superior
8978	533	0,8067393	Canto direito superior
391	8981	0,9865282	Canto esquerdo inferior
8931	9019	0,9009550	Canto direito inferior

TABELA 5.23 - MARCAS FIDUCIAIS DA FOTO 4

COLUNA	LINHA	CORRELAÇÃO	DESCRIÇÃO
432	466	0,7701063	Canto esquerdo superior
8972	469	0,8090387	Canto direito superior
413	8950	0,9910274	Canto esquerdo inferior
8956	8959	9028681	Canto direito inferior

5.6 ANÁLISE NA IDENTIFICAÇÃO DOS PONTOS

5.6.1 Pontos em Forma de Círculo

Nas duas primeiras colunas da TABELA 5.24 até a TABELA 5.33 estão registrados os resultados das observações diretas feitas manualmente sobre as fotos digitais com uso do software “PAINT SHOP PRO”. Considera-se neste trabalho essas observações, como valores corretos das posições dos centros dos pontos de

apoio pré-sinalizados. Nas colunas 3 e 4, estão registrados os resultados da correlação do primeiro par de fotos, obtidos na TABELA 5.2. Nas colunas 5 e 6, registram-se as coordenadas obtidas por simulação por Redes Neurais e esses resultados são transcritos da TABELA 5.4. Nas colunas 7 a 14, estão registradas as eventuais diferenças encontradas entre os valores das observações diretas e correlação ou redes neurais; F1 significa foto1; F2 significa foto 2; L e C significam, respectivamente, diferença em linha e coluna. Na última linha das tabelas dos pares de fotos, estão as somas das diferenças encontradas.

TABELA 5.24 – PAR DE FOTOS 1-2

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIS (3)		DIFERENÇAS							
FOTO 1 COL,LIN	FOTO 2 COL,LIN	FOTO 1 COL,LIN	FOTO 2 COL,LIN	FOTO 1 COL,LIN	FOTO 2 COL,LIN	(1)-(2)				(1)-(3)			
						F1		F2		F1		F2	
						C	L	C	L	C	L	C	L
5503,1923	2468,1861	5503,1923	2468,1861	5503,1923	2468,1861	0	0	0	0	0	0	0	0
5818, 2381	2799,2320	5818, 2380	2799,2320	5818, 2380	2799,2320	0	1	0	0	0	1	0	0
8621,2408	5714,2316	8621,2408	5714,2316	8621,2408	-----	0	0	0	0	0	0	--	--
7318,3149	4368,3078	7318,3149	4368,3078	7318,3149	4368,3078	0	0	0	0	0	0	0	1
6889,3391	3920,3328	6889,3391	3920,3328	6889,3391	3920,3328	0	0	0	0	0	1	0	0
8502,3792	5607, 3712	8502,3792	5607, 3711	8502,3792	5607, 3711	0	0	0	0	0	0	1	1
7331,3931	4393,3869	7331,3931	4393,3869	7331,3931	4393,3869	0	0	0	1	0	0	0	0
5240,4146	2215,4118	5240,4146	2216,4117	5240,4146	2215,4118	0	0	-1	1	0	0	0	0
8541,4554	5647,4479	8541,4554	5647,4479	8541,4554	5647,4479	0	0	1	0	0	0	0	0
9172,5107	6294,5026	9172,5107	6293,5026	9172,5107	6294,5026	0	0	1	0	0	0	0	0
7263,6578	4373,6550	7263,6578	4373,6550	7263,6578	4373,6550	0	0	0	0	0	0	0	0
8242,7362	5412, 7324	8242,7362	5412, 7325	8242,7362	5412, 7324	0	0	0	-1	0	0	0	0
					Σ	0	1	1	1	0	1	1	1

TABELA 5.25 – PAR DE FOTOS 2-3

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIS (3)		DIFERENÇAS							
FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	(1)-(2)				(1)-(3)			
						F2		F3		F2		F3	
						C	L	C	L	C	L	C	L
7346,1061	4574,881	7346,1061	4574,881	7346,1061	4574, 882	0	0	0	0	0	0	0	-1
5714,2316	2911, 2165	5714,2316	2911, 2166	-----	-----	0	0	0	-1	--	--	--	--
4368,3078	1495, 2935	4368,3078	1495, 2934	4368,3078	1495, 2935	0	0	0	1	0	0	0	0
3920,3328	1023, 3185	3920,3328	1023, 3184	3920,3328	1023, 3184	0	0	0	1	0	0	0	1
5607, 3712	2781, 3586	5607, 3711	2781, 3585	5607, 3711	2781, 3586	0	0	0	1	0	1	0	0
4393,3869	1515,3737	4393,3869	1515,3737	4393,3869	1515,3737	0	1	0	0	0	0	0	0
5647,4479	2804,4365	5647,4479	2804,4365	5647,4479	2804,4365	0	0	0	0	0	0	0	0
6294,5026	3457, 4926	6294,5026	3457, 4925	6294,5026	3457, 4926	0	0	0	1	0	0	0	0
8426,5997	5662,5934	8426,5997	5661,5934	-----	5662,5934	0	0	1	0	--	--	0	0
4373,6550	1484, 6444	4373,6550	1484,6443	4373,6550	1484, 6444	0	0	0	1	0	0	0	0

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIIS (3)		DIFERENÇAS								
FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	(1)-(2)		(1)-(3)						
						F2		F3						
						C	L	C	L					
7120,6600	4328,6530	7120,6600	4328,6530	-----	-----	0	0	0	0	--	--	---	---	
5412,7324	2561,7236	5412,7324	2561,7236	5412,7324	2561,7236	0	0	0	0	0	0	0	0	
						Σ	0	1	1	4	0	1	0	0

TABELA 5.26 – PAR DE FOTOS 3-4

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIIS (3)		DIFERENÇAS							
FOTO 3 COL,LIN	FOTO 4 COL,LIN	FOTO 3 COL,LIN	FOTO 4 COL,LIN	FOTO 3 COL,LIN	FOTO 4 COL,LIN	(1)-(2)		(1)-(3)					
						F3		F4					
						C	L	C	L				
3228,4775	283,4657	3228,4775	284, 4657	3228,4775	284,4658	0	0	-1	0	0	0	0	-1
4176,1724	1204,1548	4176,1724	1204,1548	4176,1724	1204,1548	0	0	0	0	0	0	0	0
5871,6572	3034,6463	5871,6572	3033,6464	5871,6572	3033,6463	0	0	1	-1	0	0	0	1
4441,6002	1569,5894	4441,6002	1569,5894	-----	-----	0	0	0	0	0	0	--	--
						Σ	0	0	0	-1	0	0	0

5.6.2 Ponto em Forma de Cruz

TABELA 5.27 – PAR DE FOTOS 1-2

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIIS (3)		DIFERENÇAS							
FOTO 1 COL,LIN	FOTO 2 COL,LIN	FOTO 1 COL,LIN	FOTO 2 COL,LIN	FOTO 1 COL,LIN	FOTO 2 COL,LIN	(1)-(2)		(1)-(3)					
						F1		F2					
						C	L	C	L				
7404,2051	4469, 1971	7404,2051	4469,1970	7404,2051	4469, 1971	0	0	0	1	0	0	0	-1
4730,2398	1672,2350	4729,2398	1671,2351	-----	1672,2351	1	0	1	-1	--	--	0	0
5404,5553	2377,2500	5404,2553	2377,2500	5404,2553	-----	0	0	0	0	0	0	--	0
7063,2946	4107,2877	7063,2946	4107,2877	7063,2946	4107,2877	0	0	0	0	0	0	0	0
7147,3590	4192,3526	7147,3590	4192,3526	7147,3590	4192,3526	0	0	0	0	0	0	0	0
7634,3774	4709, 3705	7634,3774	4709, 3706	7634,3774	4709, 3705	0	0	0	-1	0	0	0	1
5875,3831	2878,3788	5874,3831	2877,3788	5874,3831	2878,3788	0	0	1	0	0	0	0	0
8616,4142	5721,4063	8616,4142	5722,4063	8616,4142	5721,4063	0	0	-1	0	0	0	0	0
8393,4279	5498,4204	8393,4279	5498,4204	8393,4279	5497,4204	0	0	0	0	0	0	0	1
8952,4958	6068,4880	8952,4958	6068,4880	8952,4958	-----	0	0	0	0	0	0	--	--
8479,7316	5653,7273	8479,7316	5653,7273	8479,7316	5653,7273	0	0	0	0	0	0	0	0
6202,7390	3283, 7396	6202,7390	3283,7397	6202,7390	3283,7396	0	0	0	-1	0	0	0	1
						Σ	1	0	1	-2	0	0	1

TABELA 5.28 – PAR DE FOTOS 2-3

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIS (3)		DIFERENÇAS							
FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	FOTO 2 COL,LIN	FOTO 3 COL,LIN	(1)-(2)				(1)-(3)			
						F2		F3		F2		F3	
						C	L	C	L	C	L	C	L
6976,1881	4176 ,1724	6976,1881	4175 ,1724	6976,1881	4176,1724	0	0	1	0	0	0	-1	0
4469,1971	1637,1810	4469,1971	1637,1810	4469,1971	-----	0	0	0	0	--	0	0	--
4107,2877	1233,2729	4107,2877	1233,2729	4107,2877	1234 ,2729	0	0	0	0	-1	0	-1	0
4192,3526	1305,3387	4192,3526	1305,3387	4192,3526	1305,3387	0	-1	0	0	0	0	0	0
4709,3705	1848 ,3573	4709,3705	1847 ,3573	4709,3705	-----	0	0	1	0	--	0	--	--
5721, 4063	2888,3945	5721, 4064	2888, 3945	5721, 4063	2888, 3944	0	0	0	0	0	1	0	1
5498 ,4204	2658,4085	5497 ,4204	2658,4085	5497 ,4204	2658,4085	1	0	0	0	0	0	0	0
6068,4880	3228,4775	6068,4880	3228,4775	-----	3228,4775	0	0	0	0	0	0	0	0
7230,6078	4441,6002	7230,6078	4441,6002	7230,6078	-----	0	0	0	0	--	--	0	0
8625,6622	5871,6572	8625,6622	5871,6572	-----	5871,6572	0	0	0	0	0	0	0	0
5653,7273	2807,7188	5653,7273	2807,7188	5653,7273	-----	0	0	0	0	--	--	0	0
3283,7396	365 , 7277	3283,7396	364 , 7276	3283,7396	365,7277	0	0	1	1	-1	0	-1	-1
Σ						1	-1	3	1	-2	1	-3	0

TABELA 5.29 – PAR DE FOTOS 3-4

OBSERVAÇÃO DIRETA (1)		CORRELAÇÃO (2)		SIMULAÇÃO POR REDES NEURAIS (3)		DIFERENÇAS							
FOTO 3 COL,LIN	FOTO 4 COL,LIN	FOTO 3 COL,LIN	FOTO 4 COL,LIN	FOTO 3 COL,LIN	FOTO 4 COL,LIN	(1)-(2)				(1)-(3)			
						F3		F4		F3		F4	
						C	L	C	L	C	L	C	L
4574, 881	1609, 684	4574,881	1609, 683	4574, 882	1609, 684	0	0	0	1	0	-1	0	-1
3457,4926	518,4809	3457, 4926	518,4809	3457,4926	518,4809	0	0	0	0	0	0	0	0
5662,5934	2801,5817	5662,5934	2801,5817	5662,5934	-----	0	0	0	0	0	0	--	--
4328,6530	1465 ,6431	4328,6530	1466 ,6431	-----	-----	0	0	-1	0	--	--	--	--
Σ						0	0	-1	1	0	-1	0	-1

5.6.3 Marcas Fiduciais

TABELA 5.30 – DIFERENÇAS OBSERVADAS NA FOTO 1

OBSERVAÇÃO DIRETA		CORRELAÇÃO		DIFERENÇAS OBSERVADAS EM PIXELS		DESCRIÇÃO
COL	LIN	COL	LIN	COL	LIN	
409	467	408	467	1	0	Canto esquerdo superior
8947	500	8946	501	1	-1	Canto direito superior
359	8948	359	8948	0	0	Canto esquerdo inferior
8899	8986	8899	8986	0	0	Canto direito inferior

TABELA 5.31 - DIFERENÇAS OBSERVADAS NA FOTO 2

OBSERVAÇÃO DIRETA		CORRELAÇÃO		DIFERENÇAS OBSERVADAS EM PIXELS		DESCRIÇÃO
COL	LIN	COL	LIN	COL	LIN	
468	477	468	477	0	0	Canto esquerdo superior
9008	513	9007	513	1	0	Canto direito superior
417	8959	417	8959	0	0	Canto esquerdo inferior
8958	8999	8958	8999	0	0	Canto direito inferior

TABELA 5.32 - DIFERENÇAS OBSERVADAS NA FOTO 3

OBSERVAÇÃO DIRETA		CORRELAÇÃO		DIFERENÇAS OBSERVADAS EM PIXELS		DESCRIÇÃO
COL	LIN	COL	LIN	COL	LIN	
441	499	440	500	1	-1	Canto esquerdo superior
8979	533	8978	533	1	0	Canto direito superior
391	8981	391	8981	0	0	Canto esquerdo inferior
8932	9019	8931	9019	1	0	Canto direito inferior

TABELA 5.33 - DIFERENÇAS OBSERVADAS NA FOTO 4

OBSERVAÇÃO DIRETA		CORRELAÇÃO		DIFERENÇAS OBSERVADAS EM PIXELS		DESCRIÇÃO
COL	LIN	COL	LIN	COL	LIN	
432	466	432	466	0	0	Canto esquerdo superior
8973	468	8972	469	1	-1	Canto direito superior
413	8950	413	8950	0	0	Canto esquerdo inferior
8957	8959	8956	8959	1	0	Canto direito inferior

5.7 ORIENTAÇÃO EXTERIOR

Como teste de consistência do anteriormente pesquisado, faz-se agora uma aplicação de orientação exterior ao par de aerofotos 7213-7212, da área de testes.

5.7.1 Formação do Modelo Matemático Fotogramétrico

O modelo matemático para o ajustamento das coordenadas de pontos no par de aerofotos 7213-7212, visando a formação analítica do modelo fotogramétrico, é obtido a partir das equações projetivas (2.75).

O método de ajustamento aqui utilizado foi o paramétrico com injeção de coordenadas, de acordo com as fórmulas de (2.95) a (2.108).

Os parâmetros são os três ângulos de Euler, as coordenadas do ponto principal do referencial fotogramétrico e as coordenadas dos pontos no espaço objeto, isto é, pontos da superfície física no referencial geodésico local.

Foi elaborado um programa utilizando o “software” MATLAB para efetuar o ajustamento das coordenadas de foto, considerando o modelo aerofotogramétrico formado pelo par de fotos 7213-7212 da área de testes, visto que este par contém todos os pontos da pré-sinalização.

Escolheu-se um conjunto de 14 pontos da pré-sinalização que estão apresentados na tabela a seguir, com as suas coordenadas dadas em “pixels”.

TABELA 5.34 – COORDENADAS EM “PIXELS” POS PONTOS DO MODELO

FOTO 7213				FOTO 7212			
Ponto	Marca	Coluna (x)	Linha (y)	Ponto	Marca	Coluna(x)	Linha (y)
01	01	5503	1923	01	01	2468	1861
02	02	4729	2398	05	02	1671	2351
03	03	5818	2380	03	03	2799	2320
28	04	8621	2408	28	04	5714	2316
17	05	7318	3149	17	05	4368	3078
15	06	6889	3391	15	06	3920	3328
21	07	8502	3792	21	07	5607	3711
19	08	7331	3931	19	08	4393	3869
06	09	5240	4146	06	09	2216	4117
25	10	8541	4554	25	10	5647	4479
24	11	9172	5107	24	11	6293	5026
07	12	7263	6578	07	12	4373	6550
09	13	8242	7362	09	13	5412	7325
27	14	7404	2051	27	14	4469	1970

As colunas “Ponto” da TABELA 5.34 estão referidas à numeração dos pontos, respectivamente, na TABELA 3.1 e TABELA 3.2. As colunas “Marca” da TABELA 5.34 referem-se ao número de ordem dos pontos de apoio utilizados no modelo.

Na primeira parte do programa da formação do modelo em MATLAB, foi prevista a eliminação dos erros sistemáticos na imagem fotogramétrica. A correção do erro sistemático de deformação do filme foi planejada de forma a ser aplicada uma transformação afim geral no plano, conforme descrito no item 2.9.9.1, pelo fato de as aerofotos do par apresentarem 4 marcas fiduciais. As distorções radial simétrica e descentrada são corrigidas com a aplicação das fórmulas (2.87) à (2.90).

A refração fotogramétrica é corrigida com a aplicação das fórmulas (2.91) e (2.92).

Em uma segunda parte do programa em MATLAB, é realizada a orientação exterior do modelo, a partir das equações de colinearidade (2.75)

O método utilizado no ajustamento das coordenadas fotogramétricas desse modelo foi o paramétrico, com injunções de coordenadas em 4 dos 14 pontos (X,Y,Z) da superfície física. A formulação matemática dessa programação está inserida nos itens 2.9.10 e 2.9.11.

Os dados dos pontos fotogramétricos observados representados na TABELA 5.34 devem ser transformados em unidades em mm, levando-se em conta que, para as aerofotos digitais da área de testes, 1 “pixel” representa aproximadamente 0,024mm. Após essa transformação, esses dados são considerados valores observados para o ajustamento e após fazer todas as correções indicadas anteriormente, as coordenadas de foto para o par de fotos 7213-7212 são mostradas na tabela a seguir:

TABELA 5.35 - COORDENADAS FOTOGAMÉTRICAS DO PAR CORRIGIDAS DOS ERROS SISTEMÁTICOS

FOTO 7213		FOTO 7212	
x (mm)	y (mm)	x (mm)	y (mm)
17,712601683	64,790208614	-52,715272298	66,253585805
-0,168842184	53,810370148	-71,025346780	54,931977353
24,997792507	54,228850291	-45,051638601	55,637769514
89,818026652	53,618042285	22,031948319	55,733324687
59,676863455	36,470174143	-8,876923744	38,118533806
49,761676823	30,875885226	-19,164393989	32,342001631
87,066533519	21,625586973	19,683055721	23,500188187
59,984817712	18,404805500	-8,235759374	19,845869125
11,663394176	13,432850232	-58,315290046	14,116136975
87,976619107	4,021142838	20,666473823	5,767834259
102,591414645	-8,752301505	35,575363328	-6,867950078
58,453833897	-42,726031051	-8,475606840	-42,068279552
81,118914297	-60,846916978	15,496096314	-59,964187089
61,660092515	61,849461305	-6,646008485	63,725406655

A TABELA 5.35 apresenta as fotocoordenadas corrigidas dos erros. Estas fotocoordenadas representam agora os valores observados do modelo a ser ajustados.

A TABELA 5.36 e a TABELA 5.37 apresentam as fotocoordenadas observadas e ajustadas respectivamente nas fotos 7213 e 7214.

TABELA 5.36 – FOTOCOORDENADAS OBSERVADAS E AJUSTADAS NA FOTO 7213

Nº da marca	Valores Observados				Valores Observados Ajustados			
	x (pixels)	y (pixels)	x (mm)	y (mm)	x (mm)	σ_x (mm)	y (mm)	σ_y (mm)
01	5503	2468	17,713	64,790	17,722	0,031	64,780	0,031
02	4729	1671	-0,169	53,810	-0,156	0,036	53,797	0,036
03	5818	2799	24,998	54,228	25,004	0,027	54,222	0,027
04	8621	5714	89,818	53,618	89,812	0,040	53,626	0,040
05	7318	4368	59,677	36,470	59,674	0,022	36,472	0,022
06	6889	3920	49,762	30,876	49,761	0,020	30,876	0,020
07	8502	5607	87,066	21,626	87,058	0,026	21,635	0,026
08	7331	4393	59,985	18,405	59,981	0,019	18,408	0,019
09	5240	2216	11,663	13,433	11,670	0,037	13,427	0,037
10	8541	5647	87,977	4,021	88,011	0,052	3,987	0,052
11	9172	6293	102,591	-8,752	102,566	0,024	-8,728	0,024
12	7263	4373	58,453	-42,726	58,445	0,040	-42,718	0,040
13	8242	5412	81,119	-60,845	81,105	0,043	-60,833	0,043
14	7404	4469	61,660	61,850	61,660	0,033	61,850	0,033

TABELA 5.37 – FOTOCOORDENADAS OBSERVADAS E AJUSTADAS NA FOTO 7212

Nº da marca	Valores Observados				Valores Observados Ajustados			
	x (pixels)	y (pixels)	x (mm)	y (mm)	x (mm)	σ_x (mm)	y (mm)	σ_y (mm)
01	2468	1861	-52,715	66,253	-52,705	0,031	66,243	0,031
02	1671	2351	-71,025	54,932	-71,012	0,036	54,919	0,036
03	2799	2320	-45,052	55,638	-45,044	0,028	55,630	0,028
04	5714	2316	22,032	55,733	22,024	0,040	55,741	0,040
05	4368	3078	-8,877	38,118	-8,879	0,022	38,120	0,022
06	3920	3328	-19,164	32,342	-19,165	0,020	32,342	0,020
07	5607	3711	19,683	23,500	19,673	0,027	23,510	0,027
08	4393	3869	-8,236	19,846	-8,240	0,019	19,849	0,019
09	2216	4117	-58,315	14,116	-58,307	0,037	14,110	0,037
10	5647	4479	20,666	5,762	20,703	0,052	5,727	0,052
11	6293	5026	35,575	-6,868	35,549	0,024	-6,845	0,024
12	4373	6550	-8,476	-42,068	-8,484	0,040	-42,059	0,040
13	5412	7325	15,496	-59,964	15,480	0,043	-59,949	0,043
14	4469	1970	-6,646	63,725	-6,647	0,033	63,727	0,033

Na TABELA 5.38 estão mostradas as coordenadas UTM (Universal Transverse de Mercator) aproximadas e as coordenadas UTM ajustadas. Nesta tabela, as linhas marcadas em negrito indicam os pontos para os quais foram efetuadas injunções de peso e, nesses casos, as coordenadas coincidiram. As coordenadas UTM foram calculadas a partir da transformação para o elipsóide de

referência WGS84, que foi a mesma referência utilizada para se obter as coordenadas geodésicas no levantamento GPS realizado.

TABELA 5.38 – COMPARAÇÃO ENTRE AS COORDENADAS UTM APROXIMADAS E COORDENADAS UTM AJUSTADAS

Nº do ponto	Coordenadas UTM em metros: Parâmetros Aproximados			Coordenadas UTM em metros: Parâmetros Ajustados		
	X	Y	Z	X	Y	Z
01	677090,1506	7183451,2240	910,357	677090,150600	7183451,224000	910,357000
02	677201,5444	7183266,5663	911,314	677201,544389	7183266,566303	911,314003
03	677200,3170	7183522,5214	915,150	677200,316996	7183522,521400	915,149997
04	677206,6820	7184210,4676	902,497	677206,682008	7184210,467584	902,496950
05	677385,8629	7183880,8657	912,621	677385,862900	7183880,865700	912,621000
06	677443,3927	7183773,7033	917,474	677443,392702	7183773,703302	917,474024
07	677543,9521	7184170,5666	909,493	677543,952103	7184170,566592	909,492987
08	677573,5438	7183879,4210	914,714	677573,543802	7183879,421002	914,714026
09	677616,4508	7183376,4983	922,007	677616,450792	7183376,498306	922,006970
10	678420,1684	7184831,4493	925,100	678420,168400	7184831,449300	925,100000
11	677729,4567	7184171,7432	917,759	677729,456706	7184171,743199	917,759079
12	678208,5811	7183850,8505	917,945	678208,581099	7183850,850515	917,945047
13	678410,3148	7184091,1493	912,546	678410,314791	7184091,149311	912,545918
14	677115,7746	7183915,0278	894,900	677115,774600	7183915,027800	894,900000

Na TABELA 5.39 apresentam-se as diferenças entre as coordenadas de campo obtidas por observações GPS (Global Position System) e estas coordenadas ajustadas, bem como os seus desvios padrões.

TABELA 5.39 – DIFERENÇAS ENTRE COORDENADAS DE CAMPO E COORDENADAS AJUSTADAS

Nº do ponto	DIFERENÇA ENTRE COORDENADAS DE CAMPO E COORDENADAS AJUSTADAS EM METROS			DESVIOS PADRÕES		
	ΔX	ΔY	ΔZ	σ_X	σ_Y	σ_Z
01	0,000000	0,000000	0,000000	0,00001	0,00001	0,00001
02	0,000011	-0,000003	-0,000003	0,00001	0,00001	0,00001
03	-0,000008	0,000000	0,000003	0,00001	0,00001	0,00001
04	0,000000	0,000016	0,000005	0,00001	0,00001	0,00001
05	0,000000	0,000000	0,000000	0,00001	0,00001	0,00001
06	-0,000002	-0,000002	-0,000024	0,00001	0,00001	0,00001
07	-0,000003	0,000008	0,000013	0,00001	0,00001	0,00001
08	-0,000002	-0,000002	-0,000026	0,00001	0,00001	0,00001
09	0,000008	-0,000006	0,000003	0,00001	0,00001	0,00001
10	0,000000	0,000000	0,000000	0,00001	0,00001	0,00001
11	-0,000006	0,000001	-0,000079	0,00001	0,00001	0,00001
12	0,000001	-0,000015	-0,000047	0,00001	0,00001	0,00001
13	0,000009	-0,000011	0,000082	0,00001	0,00001	0,00001
14	0,000000	0,000000	0,000000	0,00001	0,00001	0,00001

5.7.2 Análise Estatística

A análise estatística do ajustamento das coordenadas representadas na TABELA 5.39 pode ser feita com a aplicação do teste de hipótese com base na distribuição de Qui-Quadrado (Gemael, 1994, p.28). No ajustamento das coordenadas é arbitrado para variância da unidade de peso a priori ($\sigma_0^2 = 1$). O valor da variância da unidade de peso a posteriori resulta, com a aplicação da equação (2.108), o valor de $\hat{\sigma}_0^2 = 0,0849176$. Com a aplicação da hipótese básica (2.112) contra a hipótese alternativa (2.113), o valor de Qui-Quadrado calculado pela (2.114) é $\chi^{*2} = 0,0849176 \times 2 = 0,1698352$, sendo que o número de graus de liberdade é $\nu = 2$ (56 equações de observações – 54 incógnitas). Considerando um nível de significância $\alpha = 5\%$, os valores teóricos da equação (2.115) são respectivamente, $\chi^2_{\nu, \frac{\alpha}{2}} = \chi^2_{2; 0,025} = 0,05$ e $\chi^2_{\nu, 1 - \frac{\alpha}{2}} = \chi^2_{2; 0,975} = 7,38$. Desta forma o valor calculado comparado com os valores teóricos, verificam a (2.116) e isto permite concluir que a condição (2.116) é verificada, pois $0,05 < \chi^{*2} (= 0,1698) < 7,38$ e portanto a hipótese básica não é rejeitada ao nível de significância de 5%.

5.7.3 Diferenças entre Coordenadas de Campo Observadas e Ajustadas

As diferenças toleráveis entre as coordenadas de campo e as coordenadas de campo ajustadas estão relacionada com a altura de vôo. O erro máximo tolerável para as diferenças em X e Y é calculado pela relação $H/10000$, sendo H a altura de vôo. O erro máximo tolerável para as diferenças em Z é calculado por $H/9000$. A escala E das fotos do vôo é de $1/8000$ e a distancia focal f da câmara de $153,176\text{mm}$. Nestas condições, a altura de vôo é $H = 1225,408\text{m}$. Usando a relação $H/10000$ encontra-se o resultado de $0,1225\text{m}$. A diferença máxima permitida é, portanto de $12,25\text{ cm}$ em X e Y . O uso da relação $H/9000$ fornece o resultado de $13,61\text{cm}$, que representa a diferença máxima permitida em Z .

Uma análise da TABELA 5.39 permite concluir que as máximas diferenças em X e Y , em valor absoluto, são respectivamente, 0,0009 cm e 0,0016cm. Estas diferenças são bem inferiores do que a máxima permitida de 12,25 cm. Ainda analisando a TABELA 5.39, conclui-se também que a maior diferença em Z , em valor absoluto é de 0,0082 cm, bem inferior aos 13,61cm permitidos.

6 CONSIDERAÇÕES FINAIS

O presente trabalho possibilitou um estudo de RNA, correlação estatística e morfologia matemática para implementar, computacionalmente, procedimentos para identificar pontos pré-sinalizados e marcas fiduciais visando aplicações fotogramétricas. Localizaram-se, automaticamente, pontos pré-sinalizados na imagem de um modelo aerofotográfico.

Por meio de um ajustamento simultâneo, foi feita a formação analítica do modelo, visando verificar a qualidade das observações realizadas. As seguintes conclusões foram obtidas no desenvolvimento deste trabalho:

- a) foi necessário, de início, transformar as imagens digitais coloridas das fotos aéreas em imagens em tons de cinza, devido à grande quantidade de cálculo envolvida em algoritmos para tratar com as três bandas R,G,B de uma aerofoto colorida;
- b) também, devido ao grande volume de processamento, 9465x9460 “pixels” em cada aerofoto, exigiu-se aplicação do conceito de pirâmide de imagens;
- c) a partir da imagem em tons de cinza, houve necessidade de transformá-la em preto e branco, para obter valores aproximados para a busca dos pontos pré-sinalizados;
- d) a identificação automática dos pontos de apoio pré-sinalizados nas duas fotos pôde ser feita com o uso de RNA ou correlação estatística. A aplicação da correlação estatística depende de RNA para a identificação das posições dos pontos na aerofoto da esquerda do par aerofotográfico onde se realizam as operações fotogramétricas. Por outro lado, a correlação estatística apresenta desempenho melhor quando se trata do reconhecimento dos pontos, na aerofoto da direita do par aerofotográfico;
- e) o treinamento da RNA foi feito em uma imagem nos três níveis do processo da pirâmide, cujo esquema está representado na FIGURA 2.26, visando diminuir o esforço computacional e viabilizar a aplicação em computadores pessoais (PC). Exigiu-se, para o treinamento dos pontos pré-sinalizados na imagem no primeiro nível do processo da pirâmide,

treinamento reiterado com o objetivo de excluir as ambigüidades ocorridas;

- f) visando a diminuição do esforço computacional, o reconhecimento dos pontos pré-sinalizados com uso das redes neurais treinadas foi feito também nos três níveis da imagem. Inicialmente, o reconhecimento foi executado na imagem em nível dois e erodida, procurando pontos brancos, candidatos a serem pontos pré-sinalizados, tendo em vista que a imagem erodida é fundamental para a busca de valores aproximados;
- g) a identificação dos pontos pré-sinalizados na forma de círculo teve maior acerto, se comparada com a forma em cruz (TABELA 5.18 e TABELA 5.19) Ao se compararem os resultados dos testes com pontos pré-sinalizados em forma circular e em cruz, fica claro que os pontos de apoio pré-sinalizados circulares levam nítida vantagem em relação aos em forma de cruz, o que de fato confirma o que se encontra na literatura a respeito de pontos pré-sinalizados;
- h) as ambigüidades ocorridas, isto é, a verificação de um ponto pré-sinalizado, sendo que este é uma outra entidade qualquer na imagem, normalmente resulta em pequenas áreas em que pode haver contraste com preto e branco, como, por exemplo, teto de automóveis, cobertura de edificações e outros;
- i) após a identificação, por RNA, dos pontos pré-sinalizados na foto da esquerda do par, as posições desses pontos na foto da direita foram determinadas com o uso de correlação estatística e RNA. Isto significa que, para que se possa ter um procedimento automatizado, as técnicas de correlação e RNA devem ser trabalhadas em conjunto;
- j) com o uso de correlação estatística, foram determinadas também as posições de pontos naturais na foto da direita do par, a partir de escolhas desses pontos na foto da esquerda;
- k) na determinação das posições das marcas fiduciais, a correlação estatística mostrou-se eficiente, sendo que as 4 marcas fiduciais foram encontradas em menos de 2 minutos em cada uma das fotos. Com o uso isolado da técnica de correlação estatística, o problema de identificação automática das marcas fiduciais ficou plenamente resolvido;

- l) a identificação dos pontos de apoio pré-sinalizados usando RNA mostrou-se satisfatória em termos de esforço computacional, uma vez que, para a identificação dos 12 pontos pré-sinalizados em uma foto do par, o tempo de computação esteve próximo de 30 minutos, em um computador da geração Pentium com 512 MB de memória RAM e *clock* de 1,2 GHz. A metodologia desenvolvida neste trabalho permite a aplicação de RNA em computadores PCs de baixo custo existentes no mercado.;
- m) a identificação, tanto dos pontos pré-sinalizados, quanto dos pontos naturais com o uso da correlação estatística, ocorreu com tempo de computação inferior a 1 minuto para 12 pontos, no mesmo computador, citado no item l);
- n) os valores dos resultados obtidos nas determinações manuais e automatizadas não apresentaram diferenças significativas;
- o) a análise dos resultados apresentados permite concluir que, com a metodologia apresentada, comparando-se RNA com a Correlação Estatística, a correlação leva vantagens nos resultados, tanto em termos de confiabilidade quanto em termos de tempo de computação, pelos motivos já explanados.

7 RECOMENDAÇÕES

Este trabalho pode se constituir em um embrião para futuras pesquisas envolvendo redes neurais artificiais, correlação e morfologia matemática no reconhecimento de padrões, tanto em imagens aerofotogramétricas como em outras áreas do conhecimento, como, por exemplo, em reconhecimento de tumores em tomografias digitais na área médica.

Próximos trabalhos poderão também envolver um estudo de mínimos quadrados em adição ao estudo de correlação estatística, para interagir com o reconhecimento utilizando-se redes neurais artificiais.

Novos estudos de reconhecimento de pontos de apoio pré-sinalizados podem envolver outras arquiteturas de redes neurais artificiais, diferentemente da empregada neste trabalho, como por exemplo, Redes Fuzzi Art-Map., como uma tentativa de melhorar o desempenho no treinamento e reconhecimento desses pontos.

Um estudo mais aprofundado pode ser conduzido com o objetivo de identificar pontos naturais em aerofotos.

REFERÊNCIAS

- ADHEMAR, M., V. F. et al. **Uma Visão Peral Sobre Rede Neural Artificial com ART2 Architecture**. Disponível em : http://www.din.uem/RNA_ART2.pdf/ Acesso em 09 set. 2004
- AGOURIS P.; SHENK T. Automated Aerotriangulation Using Multiple Image Multipoint Matching. **Photogrammetric Engineering & Remote Sensing**, Vol. 62, No. 6, June 1996, pp. 703-710.
- ACKERMANN, F. High precision digital image correlation. In Proceedings of 3. th Photogrammetric Week, Stuttgart , p.231-244.
- ANDRADE, J. B. **Fotogrametria**. Curitiba: SBEE, 1998, 258 p.
- BÄHR, H. P. Digitale Bilverarbeitung. Anwendung in Photogrammetrie und **Fernerkundug**. Karlsruhe: Herbert Wichmann , 1985.
- ESTEN, R.D. Automation of stereocompilation. In American Society of **photogrammetry**. Falls church V. A. , 1966 . v.2 , cap.15, p. 759-802.
- FACON, J. **Morfologia Matemática: Teoria e Exemplos**. Curitiba. Champagnat. 1996,304p.
- FAUSETT, L. **Fundamentals of Neural Networks** Prentice Hal , Englewood, New Jersey. 1994, 461p.
- FILHO, O.M.;NETO,H.V.**Processamento Digital de Imagens**. Editora Brasport Livros e Multimídia Ltda. 1999, 406 p.
- FÖRSTNER, W. Matching Strategies for Point Transfer. **Photogrammetric Week'95** p. 173. Stuttgart, Germany, 1995.
- FRITSCH, W. Introduction into Digital Aerotriangulation. **Photogrammetric Week'95**, p. 173, Stuttgart, Germany, 1995.
- GEMAEL, C. **Introdução ao Ajustamento de Observações. Aplicações Geodésicas**. Curitiba. Editora UFPR, 1994, p. 121.
- GONZALES, R. C; WOODS, R. E. **Processamento de Imagens Digitais**. Tradução de Roberto Marcondes César Junior e Luciano da Fontoura Costa. Editora Edgard Blücher Ltda. 2000, 509 p.
- GRUEN, A. W.; BEYER, H. A . **Real time photogrammetry at the digital photogrammetric station (DIPS) of the Zürich**. The Canadian Surveuyor, Zürich, Summer 1987, p. 181-199.

HAGGREN, H. **Real time photogrammetry as used for machine vision applications**. The Canadian Surveyor 41(2). p. 201-209, summer, 1987.

HAMILTON, W. C. **Statistics in physical science**. Ronald Press, New York, 1964.

HAYKIN, S. **Redes Neurais Princípios e Prática**. Tradução de: Paulo Martins Engel. Porto Alegre: Bookman, 2001.

_____. **Neural Networks A Comprehensive Foundation**. New York: Macmillan College Publishing Company, Inc., 1994, 696 p.

KEATING, T. J., WOLF P. R. **An Improved Method of Digital Image Correlation**. Photogrammetric Engineering and Remote Sensing, 51(8) p 99-10002 August 1975.

KĚPUSKA, V.Z.; MASON, S.O. A Hierarchical Neural Network System for Signalized Point Recognition in Aerial Photographs. **Photogrammetric Engineering & Remote Sensing**, v 61, n. 7, July 1995, p. 917-925.

KRAKIWSKI, E. J. **A syntesis of recent advances in the method of least squares**. Dep. Of Surveying Engineering, Lecture Notes n.42. Fredericton:UNB, 1975.

KRAUS, K. Fernerkundung. **Auswertung photographischer und digitaler Bilder**. Bonn Dümmler, 1990, 614p.

KRZYSTEK, P. et al. A New Concept for Automatic Digital Aerial Triangulation, Photogrammetric **Week'95**, Stuttgart, Germany, 1995.

KRUPNIK, A., Using Theoretical Intensity Values as Unknowns in Multiple-Patch Least-Square Matching. **Photogrammetric Engineering & Remote Sensing**, v 62, n. 10, October 1996, p. 1151-1155

MCCULLOCH, W.S.; PITTS, W. **A Logical Calculus of Ideas Immanent in Nervous Activity**. Bulletin of Mathematical Biophysics, 5 p 115-133, 1943.

MAKAROVIC, B. **Image correlation algorithms**. ITC Journal, 1981-1.

MARINOV, B. In International Archives of Photogrammetry and Remote Sensing . Amsterdam, 2000, vol. XXXIII, Part B2, p. 371-378.

MERCHANT, D.C. **Analytical Photogrammetry: Theory and Practice, pat I**. Columbus, Ohio, 1979. Department of Geodetic Science, The Ohio State University.

MITISHITA, E. A. Monorestituição digital de aerofotos, associada com sistema de computação gráfica C. A. D., para fins de mapeamento na área florestal. Curitiba, 1997, 253 p. Tese de Doutorado. Curso de Pós Graduação em Engenharia Florestal, Universidade Federal do Paraná.

NIEVOLA, J. C. **Uso de Redes Neurais Artificiais do Tipo RTRL e MLP FIR para Previsão de Séries Temporais**. Tese para professor titular da PUCPR, 1998.

PEREZ, A. A. **Segmentação e Quantificação de Tecidos em Imagens Coloridas de Úlceras de Perna**. São Carlos, 2001. 86 f. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

PERTL, A. **Digital image correlation with analytical plotter Planicomp C-100**: In International Society for Photogrammetry and Remote Sensing. International Archives of Photogrammetry, Commission III. **Digital image correlation with analytical plotter Planicomp C-100**. Hamburg, XIV International Congress, 1980 Hamburg.

PIEHEL, J. Procedimientos Para La Correlación de Imágenes Estereoscópicas. In: **Procesamiento Digital de Imágenes – Aplicaciones en Fotogrametría y Teledetección**. Editor: Hans Peter Bähr. Traduzido do alemão para o espanhol por Anita E. Schwender. Copyright da versão alemã 1985, Herbert Wichmann, Karlsruhe, Germany, 1991.

REZENDE, S. O. **Sistemas Inteligentes Fundamentos e Aplicações**. São Paulo: Editora Manole Ltda. 2003, 525 p.

RIEDMILLER, M.; BRAUN, H. In Proceedings of the IEEE, International Conference on Neural Network (ICNN), 1993, San Francisco-USA. **A Direct Adaptative Method for Faster Backpropagation Learning: The RPROP Algorithm**, p. 586-591.

ROGERS, F. David. **Algorithmes por l'infographie**. Paris . Mc GrawHill. 1988.

ROSENBLATT, F. **The Perceptron: A probabilistic model for information storage and organization in the brain**. Psychol. Rev. 65, p. 386-408.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, London, v.323, p.533-536, 1986.

SCHMIDT, H. **Messabweichungen, Korrelationen und Messunsicherheit**. Zeitschrift .für Vermesungswesen. Stuttgart. Heft 11. p. 545-555, Nov. 1995.

SIDNEY, A. A. V. et al. In CONGRESSO BRASILEIRO DE REDES NEURAI,4. , 1999, São José dos Campos, **Interpretação Visual de Alvos 3D usando Redes Neurais de Aprendizagem Não Supervisionado**, p. 220-225.

STRAUCH, J. C. M. **Correlação de Imagens Digitais**. Curitiba, 1991, 77p Dissertação de Mestrado em Ciências Geodésicas. Curso de Pós Graduação em Ciências Geodésicas, Universidade Federal do Paraná.

THOMPSON, Morris M., **Manual of Photogrammetry**. Third Edition. Falls Church. American Society of Photogrammetry, 1966, 1199 p.

TOTH, C.; AMMON, K. Concept, Implementation, and Results of an Automatic Aerotriangulation System. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 6, p. 711-717, June 1996

TSINGAS, V. Automatische Aerotriangulation. **Photogrammetric Week'91**. Stuttgart, Germany, 1991

VETON, Z. K.; SCOTT, O, M. A Hierarchical Neural Network System for Signalized Point Recognition in Aerial Photographs. **Photogrammetric Engineering & Remote Sensing**, v. 61, n. 7, p 917-925, July 1995.

YANNIRIS, Y. **Improvements to the of-line epipolar correlation**. Fredericton, 1974, p.104, Tese de Doutorado. UNB. Canada.

WALKERS, A. S. **Development of a system for stereomedel hehthing Band on Epipolar Scaning**. Fredericton, 1975, Tese de Doutorado. UNB. Canadá.

WANDRESEN, R.; MITISHITA, E. A.; ANDRADE, J. B. In. SIMPÓSIO BRASILEIRO DE GEOMÁTICA, 1. , 2002, Presidente Prudente SP. **Identificação de pontos de apoio pré-sinalizados com o uso de redes neurais artificiais**, p.7-9.

WANGENHEIM, A. Introdução à Visão Computacional. Morfologia Matemática. Disponível em : <http://www.inf.ufsc.br/~visão/> Acesso em 09 fev. 2004.

WEEKS, A. R. **Fundamentals of Electronic Image and Methods, Quantitative Data and Formulae**. New York, 1996.

ANEXO 1 – ARQUIVO DE DESCRIÇÃO PARA IDENTIFICAR OS PONTOS NATURAIS

```
c:\imagens\Imagens\politecnico9465x9460b.raw
9465,9460
c:\imagens\Imagens\politecnico9465x9460a(3).raw
9465,9460
15
4427, 2634,
5768, 2317,
5384, 5063,
7460, 5852,
6731, 7051,
6611, 4640,
8038, 4694,
8705, 5063,
8603, 3745,
9091, 2788,
8618, 4398,
8578, 5477,
7331, 2870,
6834, 2013,
6248, 4318,
69.5
100
c:\imagens\Experimentos\naturais\alinhanatural.out
```

**ANEXO 2 - ARQUIVO DE SAÍDA DOS PONTOS NATURAIS,
USANDO CORRELAÇÃO.**

COORDENADAS NA FOTO 1		COORDENADAS NA FOTO 2		VALOR DA CORRELAÇÃO
COLUNA	LINHA	COLUNA	LINHA	
,4427	2634	1350	2594	0,9232418
5768	2317	2745	2257	0,9461639
5384	5063	2384	5046	0,9378204
7460	5852	4555	5809	0,8501960
6731	7051	3829	7041	0,9299665
6611	4640	3653	4597	0,9881865
8038	4694	5136	4629	0,9196640
8705	5063	5816	4990	0,9615046
8603	3745	5709	3662	0,9877671
9091	2788	6201	2692	0,9726203
8618	4398	5726	4321	0,9682081
8578	5477	5693	5410	0,9689121
7331	2870	4387	2797	0,8529521
6834	2013	3863	1938	0,9755607
6248	4318	3273	4275	0,7210630

ANEXO 3 – CARACTERÍSTICAS DA CÂMARA

Conforme o certificado de calibração da câmara, as suas características são as que seguem:

- tipo de câmara: Wild RC10;
- número de série: 2061;
- tipo de lentes: Wild 15 UAGI;
- número de série: 6029;
- dimensão do quadro do negativo: 230mm x 230mm;
- máxima abertura focal: f;5,6;
- tipo de cone : grande angular;
- distância focal nominativa: 153.000mm.

ANEXO 4 – CARACTERÍSTICAS DAS AEROFOTOS UTILIZADAS

- distância focal calibrada; 153,176mm;
- número de marcas fiduciais: 04;
- número de aerofotos na área de testes: 07;
- escala média das aerofotos: 1:8000;
- valor de cada pixel: 0,024mm;
- coordenadas do ponto principal no referencial fiducial:
 $X_0 = 0,001\text{mm} \pm 0,011\text{mm}$
 $Y_0 = -0,053\text{mm} \pm 0,011$
- coeficientes de distorção radial simétrica:
 $K_0 = -3,33333333 \times 10^{-5}$
 $K_1 = 2,99778547 \times 10^{-6} \text{mm}^{-2} \pm 0,9919899 \times 10^{-8} \text{mm}^{-2}$
 $K_2 = -3,15091119 \times 10^{-12} \text{mm}^{-4} \pm 0,96386154 \times 10^{-12} \text{mm}^{-4}$
 $K_3 = 6,05776623 \times 10^{-17} \text{mm}^{-6} \pm 0,28212357 \times 10^{-16} \text{mm}^{-6}$
- coeficiente de distorção descentrada:
 $P_1 = 2,76490955 \times 10^{-7} \text{mm}^{-2} \pm 0,89952996 \times 10^{-7} \text{mm}^{-2}$
 $P_2 = -1,06518601 \times 10^{-7} \text{mm}^{-2} \pm 0,99010440 \times 10^{-7} \text{mm}^{-2}$
- parâmetro de correção da refração fotogramétrica:
 $\varepsilon_{45/12.00} = -1,39588721 \times 10^{-4} \pm 5,53832025 \times 10^{-5}$;
- as fórmulas de correção da distorção radial simétrica em coordenadas fotogramétricas estão mostradas no item 2.9.9.3.1, nas fórmulas (2.87 e (2.88)
- as fórmulas de correção da distorção descentrada em coordenadas fotogramétricas estão mostradas no item 2.9.9.3.2, nas fórmulas (2.89) e (2.90);
- a posição das marcas fiduciais está mostrada na FIGURA 2.22 e as suas coordenadas estão indicadas na TABELA 4.1