



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



REDES NEURAIS ARTIFICIAIS APLICADAS A VISÃO COMPUTACIONAL

Márcio Mendonça

Dissertação apresentada à Faculdade de
Engenharia da UNESP - Campus de Bauru,
para obtenção do título de Mestre em
Engenharia Industrial.

BAURU
2003



1. Bapex - 1030 2000 - Matemática da Computação
Redes Neurais (Computação)
Engenharia Industrial

Número de chamada
Clas. T/UNESP
PHA M 496 R
Tombo n.º 1121



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



REDES NEURAIS ARTIFICIAIS APLICADAS A VISÃO COMPUTACIONAL

MÁRCIO MENDONÇA



Dissertação apresentada à
Faculdade de Engenharia da
UNESP - Campus de Bauru, para
obtenção do título de Mestre em
Engenharia Industrial.

BAURU - SP
Abril -2003





UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



Mendonça, Márcio
Redes neurais artificiais aplicadas a visão
computacional / Márcio Mendonça -- Bauru : [s.n.], 2003.
143 p.

Dissertação (Mestrado) – Universidade Estadual
Paulista. Faculdade de Engenharia de Bauru.

Orientador: José Eduardo Cogo Castanho.

1. Visão computacional. 2. Redes neurais artificiais. 3.
Calibração de câmeras. 4. Imagens range. 5. Visão estéreo. I
– Título. II – Universidade Estadual Paulista. Faculdade de
Engenharia de Bauru.





ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE *MÁRCIO MENDONÇA*, ALUNO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA INDUSTRIAL, DA FACULDADE DE ENGENHARIA DA UNESP – CAMPUS DE BAURU.

No dia dezessete de abril de dois mil e três, às oito horas, no anfiteatro do prédio da Pós-graduação da Faculdade de Engenharia da UNESP, Campus de Bauru, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos Professores Doutores: José Eduardo Cogo Castanho do Departamento de Engenharia Elétrica da Faculdade de Engenharia - UNESP – Campus de Bauru, Presidente da Banca, Ivan Nunes da Silva do Departamento de Engenharia Elétrica da Faculdade de Engenharia - UNESP – Campus de Bauru e Waldomiro Pelágio Diniz de Carvalho Loyolla do Instituto de Informática – Pós-graduação da Pontifícia Universidade Católica – PUC - Campinas, a fim de proceder a arguição pública da Dissertação de Mestrado do candidato **Márcio Mendonça**, intitulada “REDES NEURAIIS ARTIFICIAIS APLICADADAS À VISÃO COMPUTACIONAL”. O Professor Doutor José Eduardo Cogo Castanho, Presidente da Banca, apresentou o candidato, que dissertou sobre seu trabalho, em quarenta minutos, após, o candidato foi argüido oralmente pelos membros componentes da Comissão Examinadora no tempo regulamentar exigido. Logo após, reuniu-se a Comissão Examinadora, tendo apresentado o conceito final: **APROVADO**. Nada mais havendo, foi lavrada a presente ata, que após, lida e aprovada, será assinada pelos Senhores Membros da Comissão Examinadora. Bauru, dezessete de abril de dois mil e três.

Prof. Dr. Waldomiro Pelágio Diniz de Carvalho Loyolla - Membro

UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia - Bauru

Av. Engº Luiz Edmundo Carrijo Coube s/nº • Caixa Postal 473 • CEP 17 033-360 • Bauri • SP • Fone: 14 221 6000 e 14 221 6108 • Fax: 14 221 5104
E-mail: spg@feb.unesp.br • home page: www.feb.unesp.br/pos/fe.htm

**REDES NEURAIIS ARTIFICIAIS APLICADAS A VISÃO
COMPUTACIONAL**

MÁRCIO MENDONÇA

Orientador: Prof. Dr. José Eduardo C. Castanho

**Dissertação apresentada à
Faculdade de Engenharia da
UNESP - Campus de Bauru, para
obtenção do título de Mestre em
Engenharia Industrial.**

**BAURU – SP
Abril - 2003**



Bem-aventurado o homem que suporta a provação, no final,
receberá a recompensa que o Senhor prometeu.



AGRADECIMENTOS

A Deus, que por sua misericórdia torna tudo possível.

Ao meu orientador, Professor Doutor José Eduardo Cogo Castanho, pela competência, dedicação e paciência nas orientações deste trabalho.

Ao Professor Doutor Ivan Nunes da Silva pelas suas orientações, contribuições e incentivo.

Ao CEFET-PR / unidade de Cornélio Procópio e a Faculdade de Filosofia de Ciências e Letras de Jacarezinho pela liberação parcial de meus horários, para realização deste trabalho.

À Faculdade de Engenharia Elétrica do Centro Politécnico da Unopar Londrina pelo incentivo.

Aos colegas do programa de mestrado: Alexandre, Claudia, Luiz Marcelo, Jonas, Everaldo, Jancer e Luciana pelo apoio e amizade.

Ao meu amigo Professor Márcio Aurélio Furtado Montezuma, colega de trabalho, pelas contribuições e amizade.

Aos meus familiares, que de maneira decisiva sempre me apoiaram para realização deste trabalho, e em especial a meu pai que aos meus seis anos, deu-me as primeiras lições de eletrônica.

Ao Professor Doutor Naasson Pereira Alcântara Junior que me auxiliou para o ingresso no programa de mestrado.

À Karolinne X. F. Martins pela ajuda nas correções de português e também pela sua companhia, incentivo e dedicação que me ajudaram a concluir este trabalho.



RESUMO

Este trabalho apresenta uma proposta para calibração de câmera utilizando Redes Neurais Artificiais do tipo Perceptron Multicamadas. A calibração de câmera é empregada em visão computacional para determinar posição da câmera e o relacionamento entre coordenadas de pontos no espaço e suas projeções na imagem, e usualmente requer a solução de um sistema não-linear de equações. Empregando-se redes neurais, torna-se desnecessário conhecer o modelo matemático da câmera, ou se preocupar com seus parâmetros como foco, distorção além de minimizar os requisitos da geometria do aparato utilizado para calibração. Como um dos principais resultados do trabalho, é sugerida a aplicação das redes de neurais como uma ferramenta de calibração para a recuperação de informação tridimensional (scanner 3-D) em um sistema de visão estéreo. São utilizadas simulações matemáticas de câmeras (dados sintéticos) e experiências reais com imagens para demonstrar e avaliar o procedimento proposto. O método apresenta, como vantagem, a possibilidade de ser empregado por pessoas com pouco conhecimento técnico. Ressalta-se que este trabalho apresenta potencial para aplicação nas indústrias, como por exemplo, em inspeção visual automática por computador e robótica.

PALAVRAS CHAVE: visão computacional, redes neurais artificiais, calibração de câmeras, imagens range, visão estéreo.



ABSTRACT

This work presents a proposal for camera calibration using Artificial Neural Networks of type multilayer perceptron. Camera calibration is employed in computer vision to determine camera pose and the relationship between the points coordinates in space and their projections in the image, and it usually requires solving a non-linear system of equations. By employing Artificial Neural Networks, it becomes unnecessary to know the model or parameters of the cameras, such as focus or distortions. Also the geometry and accuracy of the apparatus used in the calibration process are less important and so it becomes easier to employ the method. The application of the developed method to recover 3-D information is demonstrated using a stereo vision system (3-D scanner). Camera simulations (synthetic data) and real experiments are used to demonstrate and evaluate the procedure. It must be observed that this work has several applications in industry as for example automated visual inspection and robotics.

KEY WORDS: computer vision, artificial neural networks, camera calibration, range images, stereo vision.



SUMÁRIO

AGRADECIMENTOS.....	V
RESUMO	VI
ABSTRACT	VII
LISTA DE FIGURAS	IX
LISTA DE TABELAS.....	X
ABREVIACÕES	XI
CAPÍTULO 1 INTRODUÇÃO.....	1
1.1. PROPOSTA DA DISSERTAÇÃO.....	2
1.2. ORGANIZAÇÃO DA DISSERTAÇÃO.....	4
CAPÍTULO 2 CALIBRAÇÃO DE CÂMERAS	6
2.1. TÉCNICAS DE CALIBRAÇÃO DE CÂMERAS	7
2.2. FUNDAMENTOS DA CALIBRAÇÃO DE CÂMERA.	13
2.2.1. Modelo de Câmera.....	15
2.3. SOLUÇÃO MATEMÁTICA DO PROBLEMA DA CALIBRAÇÃO.	18
2.4. RECUPERAÇÃO DE INFORMAÇÃO 3-D.	21
2.5. SISTEMA ESTÉREO PARA RECUPERAÇÃO DE INFORMAÇÃO 3-D.....	24
CAPÍTULO 3 REDES NEURAIS ARTIFICIAIS.....	27
3.1. INTRODUÇÃO.....	27
3.2. FUNDAMENTOS DE REDES NEURAIS ARTIFICIAIS.	28
3.2.1. Topologia de Redes Neurais Artificiais.....	32
3.2.2. Treinamento de Redes Neurais Artificiais.	40
3.2.3. Redes Perceptrons Multicamadas.	45
3.3. PROCESSOS DE APRENDIZAGEM DE REDES PERCEPTRONS.	46
3.3.1. A Regra Delta Generalizada (<i>Backpropagation</i>).....	46
3.3.2. Derivação do algoritmo (<i>Backpropagation</i>).....	47
CAPÍTULO 4 APLICAÇÃO DE R.N.A. NA CALIBRAÇÃO DE CÂMERAS.....	53
4.1. A TÉCNICA PROPOSTA.....	53
4.1.1. Modelo Matemático da Câmera.	54
4.1.2. Método de Hall Aplicado à Visão Estéreo.....	58
4.2. NEUROCALIBRAÇÃO	64
4.2.1. Vantagens para o emprego de Redes Neurais.....	64
4.2.2. Aplicação de Redes Neurais Artificiais em Calibração	65
4.2.3. Características da rede neural empregada no trabalho. ...	67
4.3. MATERIAIS E METODOLOGIA	70
4.4. EQUIPAMENTO UTILIZADO	73
CAPÍTULO 5 RESULTADOS E DISCUSSÃO	75
5.1. RESULTADOS.....	76
CAPÍTULO 6	94
CONCLUSÕES.....	94
6.1. TRABALHOS FUTUROS	96
BIBLIOGRAFIA.....	98
ANEXO I SIMULAÇÃO PARA AQUISIÇÃO 3-D.	104
ANEXO II RESULTADOS DOS EXPERIMENTOS	108



LISTA DE FIGURAS

FIGURA 2.1. MODELO DE TRANSFORMAÇÃO PERSPECTIVA DE UMA CÂMERA COM OS EIXOS GLOBAIS E DE IMAGEM ALINHADOS.....	15
FIGURA 2.2. MODELO DO PROCESSO DE IMAGEAMENTO ESTÉREO.	24
FIGURA 3.1. PRINCIPAIS COMPONENTES DO NEURÔNIO.	29
FIGURA 3.2. MODELO GERAL DO NEURÔNIO ARTIFICIAL.....	33
FIGURA 3.3. FUNÇÃO DEGRAU.....	34
FIGURA 3.4. FUNÇÃO DEGRAU BIPOLAR.....	35
FIGURA 3.5. FUNÇÃO RAMPA.	35
FIGURA 3.6. FUNÇÃO SIGMÓIDE.....	36
FIGURA 3.7. FUNÇÃO TANGENTE SIGMÓIDE.	37
FIGURA 3.8. ORGANIZAÇÃO EM CAMADAS.....	38
FIGURA 3.9. EXEMPLO DE REDES FEEDFORWARD (CAMADA ÚNICA)	39
FIGURA 3.10. EXEMPLO DE REDES FEEDFORWARD (MULTICAMADAS).39	
FIGURA 3.11. EXEMPLO DE REDES RECORRENTES.....	40
FIGURA 3.12. DIAGRAMA ESQUEMÁTICO DA REDE PERCEPTRON.....	47
FIGURA 4.1. MODELO DE SISTEMA ESTÉREO MOSTRANDO A PROJEÇÃO DE UM PONTO W NAS DUAS CÂMERAS.	60
FIGURA 4.2. MODELO DA REDE NEURAL	67
FIGURA 4.3. EXEMPLO DE TREINAMENTO DE UMA REDE NEURAL ARTIFICIAL.	69
FIGURA 4.4. FLUXOGRAMA PARA REALIZAÇÃO DAS EXPERIÊNCIAS.	71
FIGURA 5.1. IMAGENS DO GRID, OBTIDOS COM UMA WEBCAM CREATIVE EM UM SISTEMA ESTÉREO.....	80
FIGURA 5.2. IMAGENS DO GRID OBTIDAS ATRAVÉS DE UMA CÂMERA SONY.	81
FIGURA 5.3. GRIDS VERTICAIS DESLOCADOS PARALELAMENTE.....	83
FIGURA 5.4. SISTEMA ESTÉREO COM CÂMERAS DIFERENTES.	84
FIGURA 5.5. DUAS VISTAS DA SUPERFÍCIE RECUPERADA COM 10 GRIDS HORIZONTAIS.....	85
FIGURA 5.6. DUAS VISTAS DA SUPERFÍCIE RECUPERADA COM 5 GRIDS HORIZONTAIS.....	85
FIGURA 5.7. DUAS VISTAS DA SUPERFÍCIE RECUPERADA COM 20 GRIDS HORIZONTAIS.....	86
FIGURA 5.8. GRIDS PARALELOS DESLOCADOS HORIZONTALMENTE.....	86
FIGURA 5.9 - MOUSE CAPTADO PELA CÂMERA ESQUERDA E DIREITA RESPECTIVAMENTE.....	87
FIGURA 5.10. SUPERFÍCIE 3-D RECUPERADA PELA RNA.	87
FIGURA 5.11. RECUPERAÇÃO DOS PONTOS MEDIDOS NA SUPERFÍCIE DO MOUSE.....	88
FIGURA 5.12. GRIDS PARALELOS DESLOCADOS HORIZONTALMENTE...	88
FIGURA 5.13. IMAGENS DA RAMPA.	89
FIGURA 5.14. IMAGENS DO MOUSE 2.....	89
FIGURA 5.15. RECUPERAÇÃO DOS PONTOS MEDIDOS NA SUPERFÍCIE DA RAMPA.....	90
FIGURA 5.16. RESULTADOS R.N.A. DA RAMPA.....	90
FIGURA 5.17. RECUPERAÇÃO DOS PONTOS MEDIDOS NA SUPERFÍCIE DO MOUSE2.....	91
FIGURA 5.18. RECUPERAÇÃO 3-D MOUSE2 PELA R.N.A.....	91



LISTA DE TABELAS

TABELA 5.1A - RESULTADO DOS EXPERIMENTOS R.N.A.....	76
TABELA 5.1B - RESULTADO DOS EXPERIMENTOS M.M.Q.	77
TABELA 5.2 – CARACTERÍSTICAS DA REDE NEURAL.....	78
TABELA 5.3. – R.N.A. X M.M.Q. (RESULTADOS PARCIAIS).....	81
TABELA 5.4. – R.N.A. X M.M.Q. (RESULTADOS FINAIS)	82



ABREVIACÕES

R.N.A. – Redes Neurais Artificiais.

M.M.Q. – Método dos Mínimos Quadrados.

L.M. – Levenberg Marquardt.

X_{mundo} – Coordenada *X* Global ou de Mundo.

Y_{mundo} – Coordenada *Y* Global ou de Mundo.

Z_{mundo} – Coordenada *Z* Global ou de Mundo.

xi – Coordenada *x* da projeção da imagem.

yi – Coordenada *y* da projeção da imagem.

3-D – Espaço tridimensional.

2-D – Espaço bidimensional.



CAPÍTULO 1

INTRODUÇÃO

A digitalização e reconstrução de formas 3-D têm numerosas aplicações em áreas que incluem manufatura, inspeção, simulação, engenharia reversa, ciência, medicina e engenharia de controle. Diversos métodos são possíveis para obtenção de imagens 3-D e os equipamentos usados para aquisição são, genericamente, denominados scanners 3-D.

Embora existam diversas tecnologias na área de aquisição de informações 3-D como ultra-som, campo elétrico, radiação (ferramentas não ópticas), o scanner óptico é um dos mais usados porque não requer contato com a superfície e ainda garante boa precisão na aquisição de informações 3-D, possibilitando inspeções totalmente automáticas (Groover, 2000). Em áreas de aplicação da engenharia e manufatura, os scanners são empregados com o propósito de obter modelos geométricos tridimensionais, os quais poderão ser posteriormente manipulados em sistemas CAD (Computer Aided Design). Neste campo de aplicação a obtenção das informações é feita por triangulação óptica (Batlle,



1998). Embora a triangulação óptica possa fazer uso de imagens obtidas passivamente, com o uso de técnicas de visão estéreo, na construção de scanners também é usual o emprego de luz estruturada. A finalidade de se empregar luz estruturada é a de simplificar o processamento das imagens e aumentar a precisão dos resultados. Nestes casos, a iluminação dos objetos que devem ser digitalizados é realizada por um padrão de luz bem definido, o que em geral é realizado pela projeção de lasers (Kim, 1998). Um método bastante usado para o emprego de tal técnica é a aplicação de luz que varre o objeto em um determinado sentido, produzindo um conjunto de imagens de luz ou sombras deslocadas espacialmente.(Bouguet, 1998).

1.1. Proposta da Dissertação

Este trabalho aborda a calibração de câmeras, dentro do contexto da construção de um scanner 3-D, no qual é feita a aquisição das características 3-D de um objeto através de um sistema de visão estéreo. Como um primeiro passo no processo as duas câmeras do sistema de visão estéreo deverão ser calibradas para só então permitir a recuperação das características das dimensões e formas 3-D do objeto.

A calibração de câmeras é um passo necessário em visão computacional, e, a rigor, é indispensável para se extrair informações métricas tridimensionais com base na aquisição de coordenadas das imagens captadas por câmeras e projetadas no espaço bidimensional de imagem. A calibração consiste basicamente em determinar os parâmetros do modelo que permite relacionar pontos no espaço tridimensional da cena com os seus correspondentes pontos projetados no plano de imagem de uma câmera. Muitos trabalhos têm sido apresentados sobre calibração, e os primeiros apareceram na área de fotogrametria (Batlle, 1998), (Aguilar, 1996), (Guisser, 2000), (Kozankiewicz, 2002), (Viana, 1999). Normalmente, os métodos de calibração de câmera exigem a utilização de modelos matemáticos não lineares e de aparatos complexos e precisos para permitir uma boa precisão nos resultados.



Na proposta deste trabalho, a calibração do sistema é realizada aplicando uma Rede Neural Artificial (R.N.A), com diversas vantagens sobre as técnicas usuais. No desenvolvimento desta proposta de aplicação, a R.N.A é treinada valendo-se somente de objetos simples de calibração, com *grids* dispostos em planos paralelos horizontais superpostos em um espaço 3-D, com dimensões conhecidas e definidas. Além disso, a utilização de Redes Neurais não se restringe à utilização de um único modelo de câmera, já que o ajuste é realizado automaticamente durante o treinamento da rede. Este fato é importante, pois permite que o mesmo procedimento seja utilizado para diferentes câmeras sem a necessidade de se determinar o modelo matemático mais adequado ou preciso para diferentes situações. Assim, o método pode ser utilizado nos mais diferentes tipos de câmera, inclusive aquelas de geometria variável, com lentes ativas, o que usualmente não é possível para os métodos clássicos. Também pode ser utilizado em câmeras de baixo custo, com lentes de baixa qualidade e com distorções irregulares de difícil modelagem matemática.

As vantagens da utilização de redes neurais para a calibração de câmeras podem ser resumidas como:

- Os modelos matemáticos para solução do problema de calibração, que levam em conta as distorções ópticas e os ruídos (parâmetros intrínsecos), que são geralmente muito complexos, não são necessários;
- Qualquer aparato de dimensões conhecidas pode ser utilizado para a aquisição das imagens de calibração, facilitando o processo. Com isso o método pode ser aplicado por pessoas com pouco conhecimento técnico.
- Diferentemente dos métodos tradicionais, baseados em técnicas de otimização, as estimativas de parâmetros intrínsecos e extrínsecos iniciais são desnecessárias, tornando-se um método de mais fácil aplicação que os métodos tradicionais.

Para validar e demonstrar a proposta, um sistema de visão estéreo é usado para a localização da câmera, fornecendo a posição no espaço 3-D desta em relação ao um sistema global. Os resultados são obtidos através de uma rede



neural previamente treinada com a configuração do sistema, isto é, com a posição de pontos conhecidos no sistema de coordenadas globais. É feita também uma comparação com o método de Hall cuja solução é obtida pela técnica do método dos mínimos quadrados (Salvi, 2002).

Os resultados obtidos demonstram robustez da aplicação das Redes Neurais para: 1) reconhecimento de posição da câmera no espaço; 2) para um sistema estéreo composto de câmeras diferentes, ou seja, características intrínsecas diferentes, com o foco e distorções de imagens e 3) reconhecimento de foco da câmera utilizada, o que pode permitir a sua extensão para aplicações com lentes ativas.

1.2. Organização da Dissertação

Esta dissertação está organizada da seguinte forma:

O Capítulo 2 apresenta o estado da arte e revisão bibliográfica das técnicas de calibração de câmera, descrição do problema de calibração, fundamentos e modelos de câmeras e visão computacional e a recuperação da informação 3-D. O Capítulo 3 apresenta uma revisão da teoria e da aplicação das Redes Neurais Artificiais. No Capítulo 4 são apresentados o desenvolvimento do trabalho, a sua implementação e a metodologia empregada para a validação da proposta. No Capítulo 5, são apresentados os resultados obtidos e uma discussão dos mesmos com a comparação entre o método proposto e o método dos mínimos quadrados aplicados à calibração, bem como uma avaliação crítica dos experimentos. No Capítulo 6, são tecidas as conclusões finais da aplicação das redes neurais na calibração de câmeras. O Anexo I apresenta uma simulação de um sistema para a aquisição de informação 3-D com um sistema de visão estéreo. O Anexo II apresenta em tabelas que exibem em detalhes os resultados dos experimentos.

Os tópicos e resultados relacionados a essa dissertação foram submetidos e aprovados na forma de artigo para diversas reuniões científicas nacionais e internacionais listadas a seguir:



Mendonça, Márcio, J. E. C. Castanho e I. N. da Silva. **REDES NEURAIAS APLICADAS A VISÃO COMPUTACIONAL**. Aplicon 2001, p. 99-101. São Carlos, Brasil.

Mendonça, Márcio; Silva, Ivan Nunes da; Castanho, José Eduardo Cogo. **CAMERA CALIBRATION USING NEURAL NETWORKS**. Proceedings of WSCG'2002 - The 10th International Conference in Central Europe on Computer Graphics. p. 61-64, 2002, Plzen, Rep. Theca.

Mendonça, Márcio; Silva, Ivan Nunes da; Castanho, José Eduardo Cogo. **APPLYING NEURAL NETWORKS IN 3-D VISION**. In: GRMELA, Ales; MASTORAKIS, Nikos E. (Org.). Advances in Neural Networks World, p. 233-238, 2002, Interlaken, Suíça.

Mendonça, Márcio, J. E. C. Castanho e I. N. da Silva. **REDES NEURAIAS APLICADAS A VISÃO 3-D**. 47ª Reunião Anual da Região Brasileira da Sociedade Internacional de Biometria 2002. p. 18. Rio Claro, Brasil.

Mendonça, Márcio, J. E. C. Castanho e I. N. da Silva. **APPLYING NEURAL NETWORKS IN CAMERA CALIBRATION**. 6th World Multiconference on Systemics, Cybernetics and Informatics SCI 2002. Orlando, USA



CAPÍTULO 2

CALIBRAÇÃO DE CÂMERAS

Em virtude das limitações sensoriais, alguns sistemas robóticos possuem flexibilidade limitada e baixa adaptação a mudanças no ambiente de trabalho. Este fator tem constituído uma grande motivação para pesquisas em visão computacional (Dorf,1998), pois a visão computacional possui grande potencial para dotar sistemas robóticos com a necessária flexibilidade exigida em um grande número de situações. A calibração de câmeras é um passo inicial na maioria dos processos de visão computacional, em especial para aplicações tais como obtenção de imagens de profundidade, navegação autônoma, localização de objetos, controle de robôs, reconhecimento de imagens, entre outras. Neste capítulo, são apresentadas as principais técnicas de calibração de câmeras presentes na literatura. É apresentada também uma possível classificação para os métodos existentes. Na Seção 2.2, é feita uma introdução modelagem de sistemas de aquisição de imagens e alguns métodos de solução para o problema, que



utilizam solução analítica e também métodos que empregam redes neurais artificiais.

2.1. Técnicas de Calibração de Câmeras

A calibração de câmeras tem por objetivo a identificação de parâmetros que caracterizam a óptica (parâmetros intrínsecos), a posição e a orientação da câmera (parâmetros extrínsecos) e é empregada para permitir a extração de informações métricas 3-D a partir das projeções de imagens 2-D. Muitos trabalhos sobre calibração de câmera têm sido apresentados, inicialmente na área de fotogrametria, e mais recentemente em visão computacional (Zhengyou, 1998).

Uma revisão bastante atual das técnicas de calibração de câmeras pode ser encontrada em Salvi (Salvi, 2002). Neste trabalho é feita uma detalhada revisão de alguns dos principais métodos utilizados para calibração de câmeras, tratada como um problema crucial para medidas métricas de uma cena, nas quais as principais técnicas são apresentadas utilizando uma mesma notação. Comparações e resultados são apresentados e discutidos, permitindo uma visão comparativa entre os métodos. Entretanto, essa revisão não aborda métodos que utilizam neurocalibração. De acordo com os trabalhos prévios encontrados na literatura, é possível classificar as técnicas existentes em duas grandes categorias: calibração fotogramétrica e autocalibração.

Calibração de Fotogrametria: A calibração de câmera é executada observando um objeto cuja geometria no espaço 3-D é conhecida com alta precisão. Pode ser realizada muito eficazmente. O objeto de calibração, normalmente, consiste em dois ou três planos ortogonais entre eles. Nesses métodos o objetivo é utilizar um sistema de câmeras para obtenção de medidas dos objetos em cena.

Kozankiewicz em (Kozankiewicz, 2002) apresenta um algoritmo rápido para computar imagens estéreo que necessitam de um pouco mais tempo do que os algoritmos com imagens monoculares. O algoritmo apresentado utiliza uma



imagem simples com informação 3-D (coordenada z). Uma característica importante deste método, é que o mesmo não necessita conhecer todos os parâmetros da câmera. Somente são necessárias, resoluções das imagens, o ângulo da vista horizontal e a distância entre a câmera e um plano de projeção utilizado na recuperação das imagens estéreo. Uma justificativa para desenvolvimento de algoritmos com a utilização de apenas uma câmera, de acordo com o trabalho de Kozankiewicz é que os processos que empregam imagens estéreo gastam de 1,5 a 2 vezes mais tempo que os algoritmos aplicados em sistemas com uma câmera. Nayar em (Nayar, 2000) relata que imagens tomadas com grande campo de visão (ângulo de abertura grande) tendem a ter severas distorções, as quais puxam os pontos em direção aos eixos ópticos. Neste trabalho é proposto um método simples para melhorar as distorções usando um objeto qualquer de calibração. As distorções aparecem diretamente nas linhas visualizadas como curvas nas cenas (imagens). A recuperação dos parâmetros referentes às distorções é realizada com a minimização de uma função objetivo designada para a distorção em pontos selecionados da imagem. Dados reais e sintéticos são apresentados.

Autocalibração: Estas técnicas não utilizam qualquer objeto de calibração. Tal técnica emprega somente o movimento de câmera em uma cena estática. No trabalho de Zhengyou (Zhengyou, 1998), é proposta uma técnica para facilitar a calibração de câmera, necessitando apenas observar padrões de imagens planas (no mínimo duas) sob diferentes orientações. O método pode ser empregado, ou pelo deslocamento da câmera ou de um padrão de imagem. O movimento não precisa ser conhecido para esta técnica e as distorções radiais são modeladas. Assim, o processo consiste em uma solução através de um refinamento não linear baseado em um critério da máxima probabilidade. Ambas experiências, com simulações e dados reais, apresentam resultados muito bons. Comparando-as com técnicas clássicas (Salvi, 2002), pode-se considerar que são de utilização fácil e flexível.

Existem, entretanto, outras técnicas que não se enquadram na classificação anterior, as quais destacam-se pela utilização de características intrínsecas dos



objetos da cena, como a forma e as dimensões conhecidas de objetos para determinar os parâmetros intrínsecos e extrínsecos da câmera. Um exemplo é a utilização de linhas de fuga (Vanishing Line), (Wang, 1990), em que um paralelepípedo é utilizado como objeto de calibração. As projeções do objeto são adquiridas através de uma imagem monocular que gera três linhas e três pontos perdidos, necessários para aplicação dessa técnica. O emprego das linhas de fuga determina a orientação, a posição da câmera, a distância focal e o centro da lente (ou seja, parâmetros extrínsecos e intrínsecos). Echico em (Echico, 1990) propôs uma técnica de calibração de câmeras utilizando a rotação de linhas paralelas, através de uma câmera com seis graus de liberdade que permite estabelecer o relacionamento entre os pontos 3-D dos objetos e as projeções 2-D de uma câmera.

William Chen em (Chen, 1999) utiliza uma técnica a qual utiliza um algoritmo de aquisição e tratamento dos dados, que apresenta a seguinte seqüência: tratamento da imagem, localização dos pontos de fuga, identificação das linhas de fuga. Tal técnica consiste em se determinar os pontos de fuga dos planos verticais e horizontais, possibilitando determinar a localização da câmera utilizando equipamento de baixo custo. Yuncai em (Yuncai, 1990), apresenta um trabalho que propõe um método para a determinação da localização da câmera com pontos correspondentes. Com esse método, a determinação da matriz de rotação é feita por um algoritmo linear usando oito ou mais linhas correspondentes, ou por um algoritmo não linear usando três ou mais linhas correspondentes. Essas linhas são ligações dos pontos correspondentes. O vetor translação pode ser obtido pela utilização de três ou mais linhas correspondentes. Oito linhas correspondentes de coordenadas 2-D para 3-D ou seis linhas são necessárias para o método linear. Bons resultados são obtidos mesmo na presença de ruídos (distorções). Aplicação do método, em sistemas autônomos, é comentada no trabalho.

Também é possível classificar as técnicas de calibração de câmeras com relação ao método empregado para a solução do modelo. Entre essas técnicas, pode-se citar as técnicas de otimização e de aplicação de redes neurais



(neurocalibração), na qual uma rede neural é aplicada em sistemas de visão para solução de tarefas de calibração. No trabalho (Lynch, 1999), Mark B. Lynch propôs um sistema de calibração utilizando estéreo visão sem nenhum conhecimento prévio da geometria do aparato, conhecendo somente as coordenadas globais e coordenadas das projeções das duas câmeras. Essa técnica determina o relacionamento entre as coordenadas globais e das câmeras, ressaltando a vantagem da aplicação das redes neurais sem nenhum prévio conhecimento do aparato (*setup*) do sistema. A rede utilizada é uma Perceptron Multicamadas com três camadas e 15 neurônios intermediários. A aplicação do trabalho de Lynch foi a uma célula de fabricação, em que um sistema consiste em reconhecimento de componentes para operações de montagem em uma linha de produção. O desempenho da técnica é avaliado com uma comparação entre as coordenadas X , Y e Z do espaço e as coordenadas estimadas pela rede neural. O erro médio quadrado é apresentado como uma comparação entre as coordenadas estimadas pela rede e as coordenadas reais, em todos os experimentos utilizados no desenvolvimento do trabalho de Lynch. Algumas considerações e conclusões são relevantes à esta pesquisa, devido à semelhança no desenvolvimento da técnica e quanto à aplicação das redes neurais artificiais, tais considerações, observadas no trabalho de Lynch, são importantes justificativas para o emprego de R.N.A.

- O número de pontos de teste é totalmente empírico, o qual é otimizado através de resultados da aplicação das redes neurais.
- São utilizadas somente três camadas (entrada, intermediária e saída).
- Os dados de treinamento são normalizados.
- Os modelos matemáticos para solução do problema de calibração, que levam em conta as distorções ópticas e os ruídos são geralmente muito complexos.
- A solução do problema de calibração não necessita de soluções matemáticas com aplicação das redes neurais.
- O método pode ser aplicado a qualquer tipo de aparato (*setup*), ou seja, qualquer disposição do aparato utilizado para a aquisição das imagens.



- Estimativas de parâmetros intrínsecos e extrínsecos iniciais são desnecessários, tornando-se um método de fácil aplicação.

Su Chao Tonem em (Su, 1995) utiliza redes neurais artificiais aplicadas a tarefas de inspeção, em situações nas quais ferramentas tradicionais não são consideradas adequadas para inspeção, em razão de distorções dimensionais e erros de aquisição. Assim, a rede neural artificial é treinada sobre um modelo de sistema de coordenadas de imagem, com peças padrões e, finalmente, aplicada para correção de erros de tarefas de inspeção. Observa-se que a R.N.A. é treinada no trabalho de Su Chao sem nenhum conhecimento prévio do relacionamento entre os padrões de entrada e saída. Moumem em (Moumem, 1999) propôs o uso de uma rede neural perceptron multicamadas como ferramenta para solução de problemas relacionados à calibração de câmeras, utilizando dados sintéticos, dados sintéticos com ruídos e dados reais para a demonstrar o emprego da técnica. Iniciando o treinamento da rede neural com pesos sinápticos randômicos, a rede pode especificar os parâmetros do modelo da câmera satisfazendo a ortogonalidade da transformação rotacional. A técnica de neurocalibração, no trabalho de Moumem é apresentada para resolver quatro tipos de problemas de calibração:

- Estimativa de parâmetros da câmera simultaneamente;
- Determinação de outros parâmetros da câmera através das coordenadas do centro de imagem;
- Estimativa de parâmetros extrínsecos e parâmetros intrínsecos;
- Estimativa de parâmetros intrínsecos a partir dos parâmetros extrínsecos.

As soluções das quatro situações de calibração permitem várias aplicações em visão computacional. Trabalhos futuros empregando neurocalibração são propostos para utilização em câmeras com lentes ativas. A precisão dos resultados obtidos é comparada com o método clássico de Tsai (Tsai, 1986), com relato de melhor precisão. Em (Wells, 1996), Wells apresenta uma técnica com redes neurais artificiais que aprende os posicionamentos de um robô, através de um treinamento de aprendizagem da rede neural com os movimentos arbitrários do



robô. Devido à aplicação de redes neurais artificiais não é necessário o emprego de complexos modelos matemáticos necessários para relacionamento entre as posições do robô e as projeções de imagem das cenas observadas. Tal técnica tem aplicação no posicionamento de máquinas industriais, descrevendo a complexidade do sistema com precisão aceitável, e é aplicada em tarefas complexas e navegação móvel. Observa-se a utilização de três camadas na rede neural e regra delta para otimização. Em (Qing, 1999), Qing aplicou redes neurais artificiais para calibrar um sistema de câmeras e o braço de um robô, com a importante vantagem de usar sensores diferentes, os quais dificultam o cálculo por meio de métodos matemáticos usados nos sistemas tradicionais. Outra característica importante no trabalho de Qing, é que se pode obter uma nova informação de posição do sistema sem ter que realizar novo treinamento da rede, demonstrando a robustez da aplicação das Redes Neurais Artificiais. Moumem, em (Moumem, 2002), aplicou redes neurais artificiais para calibração de sistemas de aquisição com lentes ativas. Sistemas de calibração de câmeras com lentes ativas são inerentemente mais utilizados do que sistemas com lentes passivas em situações que necessitam de maior flexibilidade e controlabilidade. Este tipo de calibração vislumbra importantes aplicações, devido à dificuldade de se discretizar e aproximar as variações de parâmetros intrínsecos e extrínsecos das câmeras (foco e distorções), por métodos tradicionais de otimização. O trabalho de Moumem utiliza uma rede Perceptron Multicamadas, com algoritmo de treinamento Back Propagation, a qual captura complexas variações de parâmetros do modelo de câmera através de um domínio contínuo, minimizando os erros de calibração em todas as situações de aquisição aplicados durante os experimentos. A aplicação da ferramenta necessita de uma tediosa aquisição de dados de calibração, os quais são preparados para possíveis situações de fronteiras ou limites do domínio do espaço calibrado. Importantes considerações resultantes da pesquisa de Moumem são a robustez e a baixa sensibilidade com regiões de fronteiras de domínio. A validação da ferramenta é obtida com o uso de dados sintéticos, com base em modelos *pin-hole* (também conhecido como: câmera caixa) e aquisição de dados de imagens reais de câmeras CCD com lentes ativas.



2.2. Fundamentos da Calibração de Câmera.

A calibração de câmera consiste em obter os parâmetros que definem o modelo do sistema de aquisição, permitindo estabelecer uma relação entre as coordenadas do ambiente e de suas projeções. Estas coordenadas de ambiente são chamadas de coordenadas globais, as quais possibilitam a extração de informações métricas em três dimensões através das coordenadas bidimensionais das imagens (Salvi, 2002). Em outras palavras, o principal objetivo da calibração de câmera é estabelecer a relação das coordenadas 3-D globais para as coordenadas de imagem da câmera em 2-D (Echico, 1990).

O procedimento de calibração de câmeras podem ser dividido em duas fases: na primeira, é feita a modelagem da câmera, com aproximações matemáticas do comportamento físico e óptico usando um conjunto de parâmetros iniciais; na segunda fase, é utilizado um método direto ou indireto para estimar esses parâmetros (intrínsecos e extrínsecos). Deste modo, dois tipos de parâmetros têm que ser considerados: o conjunto de parâmetros intrínsecos, os quais são os modelos da geometria interna da câmera e características ópticas do sensor. Basicamente, os principais parâmetros intrínsecos são formados por características de construção da lente como foco e centro da lente que determinam como a luz é projetada sobre a imagem do sensor. Os outros parâmetros são chamados parâmetros extrínsecos, como por exemplo, as coordenadas globais do sistema de fixação da câmera, as quais determinam a posição e orientação da câmera no espaço em coordenadas globais. Resumindo, a calibração intrínseca se preocupa em determinar somente os parâmetros físicos e ópticos de uma câmera. A calibração extrínseca objetiva determinar a posição e a orientação da câmera na cena.

A calibração de câmera pode ser classificada em duas categorias diferentes quando considerado o modelo de distorção de lentes utilizado: calibração linear versus calibração não-linear. No primeiro caso não se leva em conta possíveis distorções na construção da lente, apenas a transformação de projeção perspectiva da projeção da cena no sensor de imagem. No segundo caso, as várias distorções



ópticas das lentes são consideradas e o modelo matemático torna-se então não linear, exigindo técnicas adequadas para determinação dos parâmetros. Considerando-se o método para determinação dos parâmetros do modelo, pode-se ainda dividir as técnicas de calibração de câmara como apresentado a seguir.

Técnica não-linear de otimização: Uma técnica de calibração torna-se não linear quando qualquer tipo de imperfeição de lente é incluído no modelo da câmara. Nestes casos, os parâmetros das câmaras são, habitualmente, determinados por métodos de reiteração, com restrição da minimização de determinada função.

A minimização da função é comumente determinada pela distância entre os pontos de imagem e as projeções modeladas obtidas por reiteração. A vantagem da técnica de reiteração é a calibração de qualquer modelo, entretanto, estas técnicas precisam de uma excelente estimativa real inicial para garantir a convergência. Alguns exemplos são aplicados em fotogrametria.

Técnicas lineares com cálculo das matrizes de transformação: Nestas, usa-se o método dos mínimos quadrados para obter uma matriz de calibração que aproxima as matrizes de transformação projeção perspectiva dos pontos 3-D as suas projeções 2-D. A vantagem é a simplicidade e rapidez da aplicação do método para calibração. A desvantagem é que técnicas lineares não usam modelos que incorporam as distorções das lentes, os quais são não lineares, e que melhoram a precisão do sistema de calibração. Alguns métodos, como o de Hall, e os trabalhos de Toscani, Faugeras e Ito (apud Salvi, 2002) são exemplos de aplicação dessa técnica de cálculo de matrizes.

Técnicas em dois passos: Estas técnicas usam a otimização linear para calcular alguns parâmetros e, em uma segunda etapa, os outros parâmetros são calculados iterativamente. Permitem uma rápida calibração, considerando um pequeno número de iterações. A convergência é garantida em razão dos parâmetros obtidos no primeiro passo. Tal técnica pode utilizar vantagens das outras duas técnicas anteriores. Observa-se, que o emprego desta técnica e para soluções não-lineares (apesar do primeiro passo utilizar técnicas lineares de



otimização). Alguns autores com Tsai, Weng e Wei utilizam tal técnica (apud Salvi, 2002).

2.2.1. Modelo de Câmera.

O modelo de câmera é necessário para se definir uma relação entre os pontos no espaço tridimensional (3-D) e um plano bidimensional da imagem (2-D) (Gonzalez, 2000). A calibração permite, portanto, estabelecer a posição da câmera (ou do sistema de visão) em relação ao sistema de coordenadas globais, as quais, em três dimensões – (X, Y, Z) , são mapeadas para apenas duas coordenadas da imagem (x, y) .




Figura 2.1. Modelo de transformação perspectiva de uma câmera com os eixos globais e de imagem alinhados.

Em um sistema de aquisição monocular, tem-se uma transformação de muitos para um conforme mostra a Figura 2.1. Isso significa que todos os pontos da reta que liga o ponto de coordenadas (X, Y, Z) a um ponto do plano da câmera com coordenadas (x', y') passando pelo centro da lente, terão a mesma projeção.

Na figura 2.1, tem-se:

X - Coordenada X global ou de mundo.

Y - Coordenada Y global ou de mundo.

Z - Coordenada Z global ou de mundo.

x - Coordenada x na câmera.

y - Coordenada y da câmera.

λ - Distância focal da câmera.

A matriz calibração que define o relacionamento dos pontos no espaço com os pontos na imagem é descrita pela composição das transformações deslocamento, rotação em x , y , e z , e da projeção perspectiva. O desenvolvimento desta matriz é apresentado em detalhes no Capítulo 4.

Os pontos com diferentes coordenadas espaciais terão a mesma projeção ou as mesmas coordenadas na imagem. Dessa maneira, é impossível obter as coordenadas de um ponto no espaço (coordenadas de mundo) diretamente das coordenadas projetadas do mesmo na imagem. Este problema é crucial para a recuperação da informação 3-D a partir de uma imagem 2-D. A maneira como isto pode ser feita, através do uso de sistemas de câmera estéreo, será apresentada posteriormente.

O modelo apresentado acima é um dos mais simples, conhecido como câmera caixão (ou *pin-hole*), e é adequado para um grande número de problemas. Entretanto, como já foi mencionado anteriormente, pode-se melhorar o modelo da câmera ao se acrescentar ao mesmo as distorções de lentes. Tsai (Tsai, 1986) tem modelada as distorções representando δ_x e δ_y como as distorções radiais, que



representam deslocamentos nas coordenadas de projeção do ponto. O modelo de Weng (Weng, 1992) é mais completo, pois considera os três tipos de distorções equacionadas a seguir.

As distorções das câmeras são modeladas usualmente em três tipos básicos: distorção radial, distorção de centro e distorção prismática. Sendo a distorção total a somatória das três e sendo a distorção radial a mais comumente empregada. Observamos que as coordenadas x e y equacionadas são as coordenadas das projeções nas câmeras.

$$\delta_{total} = \delta r + \delta d + \delta p \quad (2.1)$$

A distorção radial causa um deslocamento e é modelada por um coeficiente K conforme equações (2.2) e (2.3):

$$\delta x r_1 = \kappa \times x \times (x^2 + y^2) \quad (2.2)$$

$$\delta y r_2 = \kappa \times y \times (x^2 + y^2) \quad (2.3)$$

A distorção de centro é devido ao eixo óptico das lentes não ser corretamente alinhado com o centro da câmera. Esse tipo de distorção afeta a distorção radial e tangencial, as quais podem ser descritas pelas equações (2.4) e (2.5):

$$\delta x d = p_1(3 \times x^2 + y^2) + 2 \times p_2 \times x \times y \quad (2.4)$$

$$\delta y d = 2 \times p_1 \times x \times y + p_2 \times (x^2 + 3 \times y^2) \quad (2.5)$$

A distorção prismática surge de imperfeições na construção das lentes, causando distorções radial e tangencial, modelada por um prisma no sistema óptico. Esta distorção pode ser equacionada por:

$$\delta x p = s_1(x^2 + y^2) \quad (2.6)$$



$$\delta y p = s_2 (x^2 + y^2) \quad (2.7)$$

Onde s_1 é o coeficiente de distorção prismática no eixo x e s_2 é o coeficiente de distorção prismática no eixo y .

Apesar da incorporação das distorções trazer uma maior precisão para o modelo de câmera, também traz o inconveniente de tornar o modelo muito mais complexo, bem como dificultar a busca da sua solução. Além do mais, por melhor que seja o modelo da distorção empregada, é difícil assegurar que ele seja completamente fiel a todos os tipos de câmeras usados.

2.3. Solução Matemática do problema da calibração.

Uma maneira para se encontrar matriz de calibração e utilizando o método matemático que melhor ajusta as equações de transformação através de minimização quadrática.

O método consiste na determinação dos parâmetros da matriz relacionando os pontos da cena, medidos em um sistema de coordenadas globais com os pontos da imagem, medidos nas coordenadas do plano da imagem (Gonzalez, 2000).

Expressando essa matriz e a relação de pontos em termos de coordenadas homogêneas.

$$\begin{bmatrix} Wx_i \\ Wy_i \\ W \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \end{bmatrix} \times \begin{bmatrix} X_{og} \\ Y_{og} \\ Z_{og} \\ 1 \end{bmatrix} \quad (2.8)$$

Na equação (2.8), expressa em termos de coordenadas homogêneas, a_{ij} são as posições da matriz de calibração (matriz A), as quais representam todas as transformações necessárias para a projeção de um ponto do espaço no plano de imagem da câmera, e X_{og} , Y_{og} e Z_{og} são as coordenadas globais do ponto no espaço e x_i e y_i são as coordenadas do pontos locais no plano de imagem.



$$Xi = h(X_0, A) \quad (2.9)$$

Um conjunto de pares de pontos correspondentes permite a estimação dos parâmetros a_{ij} da equação devido à falta de unicidade.

Assim, reescrevendo temos:

$$Xi = \frac{(a_{11}X_0 + a_{12}Y_0 + a_{13}Z_0 + a_{14})}{(a_{31}X_0 + a_{32}Y_0 + a_{33}Z_0 + a_{34})} \quad (2.10)$$

$$Yi = \frac{(a_{21}X_0 + a_{22}Y_0 + a_{23}Z_0 + a_{24})}{(a_{31}X_0 + a_{32}Y_0 + a_{33}Z_0 + a_{34})} \quad (2.11)$$

Fazendo arbitrariamente $a_{34}=1$ e manipulando a equação, teremos:

$$X_i \times a_{34} = a_{11} \times X_0 + a_{12} \times Y_0 + a_{13} \times Z_0 + a_{14} - x_i \times X_0 - x_i \times Y_0 - x_i \times Z_0 \quad (2.12)$$

De maneira análoga para X_i , obtém-se as equações de Y_i .

A equação 2.8 pode ser escrita de forma matricial, $Q \times A = d$, assim:

$$\begin{bmatrix} X_0 & Y_0 & Z_0 & 1 & 0 & 0 & 0 & 0 & -x_0X_0 & -x_0Y_0 & -x_0Z_0 \\ 0 & 0 & 0 & 0 & X_0 & Y_0 & Z_0 & 1 & -y_0X_0 & -y_0Y_0 & -y_0Z_0 \\ \vdots & & & \vdots & & & & \vdots & & & \vdots \\ X_n & Y_n & Z_n & 1 & 0 & 0 & 0 & 0 & -x_nX_n & -x_nY_n & -x_nZ_n \\ 0 & 0 & 0 & 0 & X_n & Y_n & Z_n & 1 & -y_nX_n & -y_nY_n & -y_nZ_n \end{bmatrix} \times \begin{bmatrix} a_{11} \\ a_{12} \\ a_{13} \\ \vdots \\ a_{31} \\ a_{32} \\ a_{33} \end{bmatrix} = \begin{bmatrix} x_0 \\ y_0 \\ x_1 \\ y_1 \\ \vdots \\ x_n \\ y_n \end{bmatrix} \quad (2.13)$$

Onde:

X_0 - Coordenada Global X do primeiro ponto de calibração.

Y_0 - Coordenada Global Y do primeiro ponto de calibração.

Z_0 - Coordenada Global Z do primeiro ponto de calibração.

X_n - Coordenada Global X do n ésimo ponto de calibração.

Y_n - Coordenada Global Y do n ésimo ponto de calibração.

Z_n - Coordenada Global Z do n ésimo ponto de calibração.

x_0 - Coordenada x da imagem projetada do primeiro ponto.

y_0 - Coordenada y da imagem projetada do primeiro ponto.

x_n - Coordenada x da imagem projetada do n ésimo ponto.

y_n - Coordenada y da imagem projetada do n ésimo ponto.

A matriz de parâmetros foi convertida pela concatenação de linhas em um vetor de parâmetros ($a_{11}.. a_{33}$) a serem estimados.

Dessa maneira trabalhando com o método dos mínimos quadrados, a solução poderá ser um vetor escrito em função de sua base. Assim, obtendo alguns pontos, no mínimo seis (embora na prática, o número de pontos seja muito maior), necessários para escrever uma projeção mais próxima do vetor. Assim pode-se trabalhar em uma solução do tipo:

$$Q \times A = d \quad (2.14)$$

Onde Q é a matriz com 11 colunas e 2 vezes o número de pontos de calibração (*grid*), cujas linhas são da forma das equações discutidas; A é um vetor de parâmetros a serem estimados e d é um vetor dos pontos da imagem.

Para solução usando o método dos mínimos quadrados, são necessários no mínimo seis pontos no objeto e imagem, entretanto, na prática esse número e da ordem de 60 pontos ou mais. O sistema pode ser solucionado por decomposição $Q-R$ (Gonzalez, 2000), ou aplicando-se o método da pseudo-inversa.

$$A = (Q^+) \times d \quad (2.15)$$



Onde:

$$Q_+ = (Q^T \times Q)^{-1} \times Q^T \quad (2.16)$$

Matematicamente, Q_+ é uma solução na qual multiplicam-se os dois termos pela transposta, tornando a matriz quadrada, e depois pela matriz inversa deste produto, para que se determine o vetor A . (Lay, 1999).

A determinação dos parâmetros a_{ij} permite encontrar os pontos da imagem a partir do objeto no espaço, considerando as especificações da câmera.

Deve-se lembrar que a determinação do vetor A calibra apenas uma câmera. Dessa forma, é preciso resolver um sistema de equações para encontrar o vetor A duas vezes, obtendo a relação de pontos conhecidos no espaço (*grid*), para as coordenadas das duas câmeras.

2.4. Recuperação de Informação 3-D.

Um dos principais objetivos da visão computacional é a recuperação de informações 3-D. Este problema está, intrinsecamente, associado ao problema da calibração de câmeras (embora alguma medição de informação 3-D possa ser obtida sem a calibração). Existem vários métodos para a obtenção de informações 3-D, assim o emprego de calibração de câmeras é essencial quando a informação métrica é requerida e tal informação é obtida através da projeção de imagens bidimensionais nas câmeras. Alguns sistemas utilizam informações contidas na própria imagem e a calibração de câmeras para a obtenção da informação 3-D. Outros utilizam sistemas de múltiplas câmeras ou sistemas de luz estruturada para prover a informação necessária para a recuperação da informação 3-D.

Para a recuperação da informação 3-D em visão computacional, existem várias alternativas (Wang; Heikkila; Trucco; Guisser; 1990, 2000, 1998, 2000). Entre as mais comuns, está a estéreo visão (Aguilar; Weng; Chen; 1996, 1992, 1999). Entretanto, alguns trabalhos da literatura aplicam técnicas de aquisição utilizando luz estruturada (Kim; Trucco; Guisser; 1998, 1998, 2000), como, por



exemplo, Tommaselli em (Tommaselli, 1998) empregou luz estruturada para aquisição de dados em fotogrametria em vez de um sistema estéreo por dificuldade de determinação de correspondência de pontos e também pela geração de alguns ruídos presentes nas imagens de um sistema estéreo dificultando a aquisição de medidas do corpo humano e diagnóstico de escoliose. Ou também um sistema de calibração móvel com uma câmera presa a um braço de um robô (Andreff, 2000).

Na visão estéreo, duas câmeras são utilizadas para visualizar um mesmo ponto no espaço, dentro de uma região denominada campo de visão das câmeras. Assim cada câmera obtém duas coordenadas em suas respectivas imagens. Desse modo, cada ponto no espaço poderá gerar somente um par de coordenadas (x_1, y_1) e (x_2, y_2) , respectivamente, nas duas câmeras.

Algumas aplicações com aquisição de informação 3-D:

Reconstrução Densa: Cada ponto de imagem determina um raio óptico através do ponto focal da câmera em direção a cena. O uso de mais do que uma única vista de uma cena estática (tomada por um sistema estéreooscópico, com o movimento de uma câmera, ou mesmo de um emissor de luz estruturada) permitindo o cruzamento dos raios ópticos obtendo as posições métricas de pontos 3-D. Obviamente, o problema de correspondência de pontos tem que ser previamente solucionado.

Inspeção visual: Desde que a reconstrução 3-D de um objeto é obtida, a reconstrução do objeto pode ser comparada com um modelo armazenado para se detectar qualquer erro ou imperfeição de manufatura como trincos, alongamento entre outros. Uma aplicação potencial é o controle de qualidade através de inspeções visuais computadorizadas, possibilita exames exaustivos dos produtos, em oposição à inspeção humana é lenta e usualmente baseada em abordagem estatística.

Localização de objetos: Quando consideramos vários pontos de imagem vindos de diferentes objetos, a posição relativa entre estes objetos pode ser facilmente determinada. Isto tem muitas aplicações industriais em sistemas de coleta de peças e desvio de obstáculos para navegação de robôs entre outras.



Localização câmera: Quando a câmera é colocada no manipulador do braço de um robô, ou em um robô móvel, a posição e orientação da câmera podem ser calculadas pela localização de algumas posições marcadas na cena. Se estas medidas são armazenadas, uma análise temporal permite ao manipulador determinar a trajetória do robô. Estas informações podem ser usadas para controle do robô ou planejamento de trajetória. A seguir são apresentados alguns trabalhos encontrados na literatura.

Sistemas utilizando uma câmera e luz estruturada (codificada) e sistemas com duas câmeras (visão estéreo). Guisser em (Guisser, 2000), apresentou um trabalho descrevendo um sistema de visão com luz estruturada, usando a projeção de um *grid*, dos quais as superfícies são os parâmetros dos objetos. O trabalho é fundamentado na parametrização de um *grid* com formas básicas projetado sobre a superfície de um objeto. É um método rápido e robusto é apresentado para aquisição das linhas das curvas projetadas. A precisão para recuperação 3-D do método apresentado tem erro médio de 0,1%. Tem aplicações em metrologia e estudo de superfície dos objetos. Sampaio Viana em (Viana, 1999), expôs a aplicação de uma técnica “batch” à calibração de um sistema de visão ativa objetivando a identificação dos parâmetros ópticos que caracterizam a câmera (parâmetros intrínsecos). Essa identificação vislumbra dois propósitos fundamentais: recuperação 3-D, associada à localização de objetos no ambiente ou a determinação do movimento da câmera, assim como a correção de imageamento em razão das distorções ópticas e montagem imperfeita do conjunto câmera-lente. Determina-se uma estimativa dos parâmetros iniciais mediante o emprego de um modelo *pin-hole* dotado de óptica ideal, produzindo uma solução analítica baseada no método dos mínimos quadrados. Em seguida, busca-se refinar o resultado interativamente mediante o emprego de um modelo de distorção de óptica radial. Resultados da calibração usando dados sintéticos e reais são apresentados. O valor calibrado da distância focal da câmera real foi usado com sucesso no rastreamento de objetos por movimentos sacádicos, indicando que a calibração efetuada apresenta exatidão visual para tarefas visuais. Tommaselli em (Tommaselli, 1998), apresentou um trabalho de recuperação de superfície tendo como principal



proposta o uso de luz estruturada. Este sistema de aquisição 3-D é baseado em uma câmera de baixo custo e um projetor de padrões. O modelo matemático aplicado na reconstrução é baseado em equações paramétricas das projeções de retas combinadas com equações colineares. São desenvolvidas e apresentadas as aproximações sequenciais para solução do sistema utilizado na calibração do projetor e da câmera. Resultados do trabalho obtidos utilizando-se dados reais são apresentados e discutidos.

2.5. Sistema estéreo para recuperação de informação 3-D.

Uma possível solução para recuperação dos pontos 3-D é apresentada em [Gonzalez, 2000], o qual considera que as duas câmeras sejam idênticas e que os sistemas de coordenadas estejam perfeitamente alinhados, diferenciando-se apenas na posição de suas origens, como mostra a Figura 2.2.




Figura 2.2. Modelo do processo de imageamento estéreo.

É importante observar que, uma vez que os sistemas de coordenadas de mundo coincidam, o plano (x,y) da imagem está alinhado com o plano (X,Y) do sistema de coordenadas de mundo. Então, nessas condições, a coordenada Z do plano do ponto w , no espaço, é exatamente a mesma para ambos os sistemas de coordenadas das câmeras.

Se a primeira câmera coincidir com o sistema de coordenadas de mundo, com o mostrado na Figura 2.2., então w fica na reta dada pela seguinte equação em coordenadas parciais.

$$X_1 = \frac{x_1}{\lambda} \times (\lambda - Z_1) \quad (2.18)$$

Onde:

X_1 e Z_1 são respectivamente as coordenadas X e Z do ponto w .

x_1 é a coordenada x da projeção do ponto w .

λ é o foco da câmera.

Se a segunda câmera for trazida para a origem do sistema de coordenadas do mundo, w ficará na reta dada pela seguinte equação em coordenadas parciais.

$$X_2 = \frac{x_2}{\lambda} \times (\lambda - Z_2) \quad (2.19)$$

Entretanto, devido à separação entre as câmeras e que a coordenada Z é a mesma para ambos os sistemas de coordenadas das câmeras, temos:

$$X_2 = X_1 + B \quad (2.20)$$

e

$$Z_1 = Z_2 = Z \quad (2.21)$$

sendo que B é a distância da linha de base.

A substituição das equações (2.20) e (2.21) nas equações (2.18) e (2.19) implica.

$$X_1 = \frac{x_1}{\lambda} \times (\lambda - Z) \quad (2.22)$$

e

$$X_1 + B = \frac{x_1}{\lambda} \times (\lambda - Z) \quad (2.23)$$

Subtraindo-se a equação (2.22) da (2.23) e resolvendo-se temos:

$$Z = \lambda - \frac{\lambda \times B}{x_2 - x_1} \quad (2.24)$$

Onde:

Z é a coordenada do ponto no espaço.

x_1 e x_2 são as coordenadas das projeções do ponto w nas duas câmeras.

Assim, pelas equações desenvolvidas, é possível recuperar pontos do espaço (3-D) utilizando-se um sistema de aquisição estéreo, uma simulação do método é apresentada no Anexo I. A solução através do método dos mínimos quadrados, apresentada na seção anterior, pode ser aplicada em cada uma das câmeras separadamente, em situações em que se utilize a própria câmera como um instrumento para determinar parâmetros intrínsecos ou extrínsecos.



CAPÍTULO 3

REDES NEURAIS ARTIFICIAIS

3.1. Introdução.

Este capítulo é baseado no Capítulo 3 - Fundamentos de Redes Neurais Artificiais - da dissertação de mestrado “Uma Abordagem Neural para Identificação de Gases Dissolvidos em Óleo Isolante em Função de Parâmetros Físico-Químicos em Transformadores” (Imamura, 2000), no qual são apresentados os conceitos necessários para compreensão e aplicação das redes neurais artificiais, desde um histórico e da modelagem do neurônio biológico até o desenvolvimento e as topologias das redes. Importantes conceitos, como treinamento e teste das redes neurais, são revisados. Esta revisão tem o objetivo de dar suporte ao desenvolvimento do trabalho realizado, que apresentado em detalhes no capítulo 4.



3.2. Fundamentos de Redes Neurais Artificiais.

O cérebro humano é considerado o mais fascinante processador baseado em carbono existente, sendo composto por aproximadamente 100 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada rede neural biológica. As sinapses transmitem estímulos através de diferentes concentrações de Na^+ (Sódio) e K^+ (Potássio), e os resultados delas podem ser estendidos por todo o corpo humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação.

O sistema nervoso é formado por um conjunto extremamente complexo de neurônios. Nos neurônios a comunicação é realizada através de impulsos. Quando um impulso é recebido, o neurônio o processa, e se o resultado do processamento for maior que um determinado limite de ação, o mesmo dispara um segundo impulso que produz uma substância neurotransmissora que flui do corpo celular para o axônio (que por sua vez pode ou não estar conectado a um dendrito de outra célula). O neurônio que transmite o pulso pode controlar a frequência de pulsos aumentando ou diminuindo a polaridade na membrana pós-sináptica.

Ele tem um papel essencial na determinação do funcionamento, comportamento e do raciocínio do ser humano.

Ao contrário das redes neurais artificiais, redes neurais naturais não transmitem sinais negativos, sua ativação é medida pela frequência com que os pulsos são emitidos. As redes naturais não são uniformes como as redes artificiais, e apresentam certa uniformidade apenas em alguns pontos do organismo.

A Figura 3.1 ilustra o desenho de uma célula nervosa ou neurônio. As suas principais componentes são:



- Os dendritos, que tem por função, receber os estímulos transmitidos pelos outros neurônios.
- O corpo do neurônio, também chamado de soma, que é responsável por coletar e combinar informações vindas de outros neurônios.
- O axônio, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos para outras células.




Figura 3.1. Principais componentes do neurônio.

As primeiras informações mencionadas sobre a neuro computação datam de 1943, em artigo publicado por McCulloch e Pitts (McCulloch, 1943), em que sugeriam a construção de uma máquina baseada ou inspirada no cérebro humano. Muitos outros artigos e livros surgiram desde então, porém, pouco resultado foi obtido. Em 1949, Donald Hebb (apud Haykin, 2000). escreveu o livro intitulado "The Organization of Behavior" (A Organização do Comportamento) que perseguia a idéia de que o condicionamento psicológico clássico está presente em qualquer parte dos animais pelo fato de que esta é uma propriedade de neurônios individuais Suas idéias não eram completamente novas, mas Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios. Este

primeiro passo serviu de inspiração para que muitos outros pesquisadores perseguissem a mesma idéia.

O primeiro neuro computador a obter sucesso (Mark I Perceptron) surgiu em 1957-1958 e foi criado por Frank Rosenblatt, Charles Wightman e outros. Em razão da profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muito o vêem como o fundador da neuro computação na forma em que a temos hoje. Seu interesse inicial para a criação do Perceptron era o reconhecimento de padrões (Rosenblatt, 1959).

Após Rosenblatt, Bernard Widrow (Widrow, 1960), desenvolveu um novo tipo de elemento de processamento de redes neurais chamado de Adaline (abreviação de ADaptive LINear Element), e mais tarde propôs a sua generalização multidimensional, o MADALINE (múltipla ADALINE). Esta rede era equipada com uma nova lei de aprendizado, conhecida como a "Regra Delta", que mais tarde foi generalizada para redes com modelos neurais mais elaborados (Rumelhart, 1986).

Infelizmente, os anos seguintes foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar vários materiais de divulgação que fazia uma previsão pouco confiável para a época, sobre máquinas tão poderosas como o cérebro humano e que surgiriam em um curto espaço de tempo. Em 1969, Minsky e Papert (Minsky, 1969) publicaram o livro 'Perceptrons - An Introduction to Computational Geometry', onde os autores argumentaram enfaticamente quanto às limitações básicas dos perceptrons isoladas, a começar pela impossibilidade de se implementar regras lógicas tão simples como o ou-exclusivo. Historicamente, a publicação deste livro paralisou, a partir de 1970, as pesquisas na área de redes neurais.

Um período de pesquisa silenciosa seguiu-se durante a época de 1969 a 1982, quando poucas pesquisas foram publicadas devido aos fatos ocorridos anteriormente. Entretanto, aqueles que pesquisavam nesta época, e todos os que se seguiram no decorrer de treze anos conseguiram novamente estabelecer um campo concreto para o renascimento da área.



Nos anos 80, muitos pesquisadores passaram a publicar diversas propostas para a exploração de desenvolvimento de redes neurais bem como suas aplicações. Esta retomada do interesse em redes neurais artificiais foi devido a vários fatores, entre os quais ressalta-se, melhores conhecimentos da estrutura real do cérebro, disponibilidade de computadores com maior capacidade de cálculo, sobretudo, o desenvolvimento de novos algoritmos de aprendizado. Neste período John Hopfield, renomado físico de reputação mundial, se interessou pela neuro computação, e escreveu artigo (Hopfield, 1982) que percorreu o mundo todo persuadindo centenas de cientistas, matemáticos, e tecnólogos altamente qualificados a se unirem a esta nova área emergente. Outros pesquisadores também continuaram as pesquisas sobre o assunto, entre eles destacaram-se Teuvo Kohonen (Finlândia), Edoardo Caianiello (Itália), Stephen Grossberg e James Anderson (EUA) e Kunuhito Fukushima (Japão).

Apesar de um grande número de pesquisadores da área terem aderido à área de RNA pela influência de Hopfield, foi em 1986 que este campo de pesquisa se expandiu com a publicação do livro "Parallel Distributed Processing" (Processamento Distribuído Paralelo), de Rumelhart, Hinton e Williams (Rumelhart, 1986), onde os autores desenvolveram o algoritmo de aprendizado '*backpropagation*' para as redes do tipo perceptron com estruturas multicamadas. Paralelamente, os fundamentos teóricos foram melhorados, especialmente por Grossberg (1976a, 1976b), Hopfield (1982), que também contribuíram para o ressurgimento da área.

Desde então, várias aplicações têm sido mapeadas através de redes neurais artificiais, tais como: reconhecimento de padrões (Widrow, 1988), processamento de imagens (Lin, 1991), sistemas de controle, Robótica (Smagt, 1991) e identificação de sistemas.



3.2.1. Topologia de Redes Neurais Artificiais.

As redes neurais artificiais (RNA) consistem em um método de solucionar problemas relacionados à engenharia e ciências por intermédio de circuitos simples que simulam o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. Além disso, RNA são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (Braga, 2001). Uma rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios.

De uma forma geral, a operação de uma célula da rede se resume em:

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível excede um limite (threshold) a unidade produz uma saída.

Assim como o sistema nervoso é composto por bilhões de células nervosas, a rede neural artificial também seria formada por unidades que nada mais são que pequenos módulos que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

O modelo de neurônio mais simples, o qual engloba as principais características de uma rede neural biológica, paralelismo e alta conectividade, foi



proposto por McCulloch e Pitts (apud Haykin, 2000). Conforme mostra a Figura 3.2, o modelo geral do neurônio artificial pode ser ilustrado por:




Figura 3.2. Modelo geral do neurônio artificial.

Onde:

$x_1, x_2, \dots, x_p$ são os sinais de entrada.

$w_{k1}, w_{k2}, \dots, w_{kp}$ são os pesos ou conexões sinápticas.

θ_k é o limiar de ativação do neurônio.

u_k é a saída do combinador linear.

$g(u_k)$ é a função de ativação (limita a saída do neurônio).

y_k é o sinal de saída do neurônio.

As equações que descrevem o comportamento do neurônio artificial são dadas por:

$$u = \sum_{i=1}^N w_i \cdot x_i + \theta_k \quad (3.1)$$

$$y = g(u)$$

A função de ativação $g(u)$ processa o conjunto de entradas recebidas e o transforma em estado de ativação. Normalmente, o estado de ativação do neurônio pode assumir os seguintes valores:

- 1) Binários (0 e 1);
- 2) Bipolares (-1 e 1);
- 3) Reais.

As funções de ativação mais típicas são:

a) Função degrau

Nesse tipo de ativação, mostrado na Figura 3.3, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (3.2)$$




Figura 3.3. Função degrau.

Então, a saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não-negativo, caso contrário a saída do neurônio assumirá o valor 0.

b) Função degrau (bipolar)

Nesse tipo de ativação, mostrado na Figura 3.4, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases} \quad (3.3)$$




Figura 3.4. Função degrau bipolar.

Então, a saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não-negativo, caso contrário a saída do neurônio assumirá o valor -1.

c) Função rampa

Nesse tipo de ativação, mostrado na Figura 3.5, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases} \quad (3.4)$$




Figura 3.5. Função rampa.

Para esta função de ativação, a saída do neurônio pode assumir valores positivos e negativos no domínio de -1 a 1, e no intervalo definido no intervalo $\{-a, a\}$, a saída assume o valor da função $g(u)=u$.

d) Função sigmóide

Para a função sigmóide, ilustrada na Figura 3.6, tem-se:

$$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (3.5)$$




Figura 3.6. Função sigmóide.

Para a função acima, β é o parâmetro que define a inclinação (ganho) da função sigmóide. Nesse tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1.

e) Função tangente hiperbólica

Na função de ativação do tipo tangente hiperbólica (Figura 3.7), tem-se:

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (3.7)$$




Figura 3.7. Função tangente sigmóide.

Para esta função de ativação, a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 a 1.

As funções de ativação são escolhidas em função da necessidade do problema que a rede esteja trabalhando.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas com dados reais, diferindo da computação convencional, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

Conforme apresentado na Figura 3.8., as camadas de uma rede neural são usualmente classificadas em três grupos:




Figura 3.8. Organização em camadas.

Camada de Entrada: onde os padrões são apresentados à rede.

Camadas Intermediárias ou Ocultas: onde é feita a maior parte do processamento. Através das conexões ponderadas. Estas camadas podem ser consideradas como extratoras de características.

Camada de Saída: onde o resultado final é apresentado.

Redes neurais são também classificadas de acordo com a arquitetura em que foram implementadas, topologias, características de seus nós, regras de treinamento, e tipos de modelos de neurônio empregado.

Com relação à arquitetura das redes neurais artificiais, têm-se:

a) Redes Feedforward (Camada Única)

São redes neurais com uma camada de entrada e uma única camada de neurônios que é a própria camada de saída (Figura 3.9). Suas principais aplicações são em memória associativas e no reconhecimento de padrões (Widrow, 1988). Neste tipo de redes, tem-se o modelo Perceptron e o Adaline.




Figura 3.9. Exemplo de Redes Feedforward (Camada Única)

b) Redes Feedforward (Multicamadas)

Este tipo de rede distingue da anterior pela presença de uma ou mais camadas escondidas de neurônios (Figura 3.10). Assim, os neurônios que recebem sinais de excitação do meio externo estão na camada de entrada; os neurônios que estão na saída representam a camada de saída e os neurônios intermediários estão nas camadas escondidas. Suas principais aplicações são em reconhecimento de padrões, por exemplo, no trabalho de Jorge (apud Imamura, 2000); aproximador universal de funções e em controle, por exemplo, os trabalhos de Neto, Narendra e Antsaklis (apud, Imamura, 2000). Neste tipo de redes, tem-se o Madaline, o Perceptron Multicamadas e o de Função Base Radial (RBF).




Figura 3.10. Exemplo de Redes Feedforward (Multicamadas)

c) Redes Recorrentes

São redes que contém realimentação entre neurônios de camadas diferentes (Figura 3.11). Suas principais aplicações são em sistemas dinâmicos, memórias associativas, previsão e estimação, otimização e no controle. Neste tipo de redes, tem-se o modelo do Hopfield e o Perceptron com realimentação.




Figura 3.11. Exemplo de Redes Recorrentes

3.2.2. Treinamento de Redes Neurais Artificiais.

Um dos objetivos de pesquisas sobre redes neurais na computação é desenvolver morfologias neurais, baseadas em modelos matemáticos, que podem realizar funções diversas (Haykin, 2000). Na maior parte dos casos, modelos neurais são compostos de muitos elementos não lineares que operam em paralelo e que são classificados de acordo com padrões ligados à biologia.

Do ponto de vista estrutural, a arquitetura de redes neurais pode ser classificada como estática, dinâmica ou fuzzy, constituída ainda de uma única camada ou múltiplas camadas. Além disso, algumas diferenças computacionais surgem também quando se trata da maneira com que são feitas as conexões existentes entres os neurônios. Estas conexões podem ser estritamente no sentido de ida, no sentido de ida e volta, lateralmente conectadas, topologicamente ordenadas ou híbridas.

A propriedade mais importante das redes neurais é a capacidade de aprender o seu ambiente e com isso melhorar seu desempenho. Isso é feito através

de um processo iterativo de ajustes (treinamento) aplicado a seus pesos. O processo de aprendizado encerra, quando a rede neural consegue generalizar soluções para uma classe de problemas.

Um algoritmo de aprendizado é composto por um conjunto de regras bem definidas destinadas à solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si notadamente pelo modo como os pesos são modificados.

Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. A porcentagem de 50 a 90% do total de dados deve ser separada para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras associadas ao processo. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

As principais formas de aprendizado que estão associados ao processo de ajuste de pesos da rede podem ser divididos em (Haykin, 2000) :

Aprendizado Supervisionado: utiliza um agente externo que indica à rede um comportamento bom ou ruim de acordo com o padrão de entrada. A rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico. Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada com o respectivo padrão de saída, a diferença (erro) é então propagada em sentido inverso ao fluxo de informações da rede (das saídas para as entradas) e os pesos são alterados de acordo com algum algoritmo que tende a minimizar o erro. Os vetores de entrada e saída do conjunto de treinamento são aplicados sequencialmente, os erros são calculados e os pesos ajustados para cada vetor, até que o erro para o conjunto de treinamento seja aceitável.

Aprendizado Não Supervisionado: não utiliza um agente externo indicando a resposta desejada para os padrões de entrada, utiliza-se, entretanto, exemplos de



situações semelhantes para que a rede responda de maneira semelhante. A rede se auto-organiza em relação a alguns subconjuntos de entrada cujos elementos possuem características similares. Os vetores do conjunto de treinamento consistem unicamente de vetores de entrada. O algoritmo de treinamento modifica os pesos da rede para produzir vetores de saída que são consistentes, isto é, vetores do conjunto de treinamento que são similares entre si produzirão o mesmo padrão de saída. Nesse tipo de aprendizagem espera-se que o sistema deva estatisticamente descobrir características e particularidades marcantes da população de entrada. Ao contrário do aprendizado supervisionado, onde não existe um conjunto à priori de categorias dentro do qual os padrões irão ser classificados, o sistema é quem deve desenvolver sua própria representação do estímulo de entrada.

Denomina-se ainda ciclo de aprendizado como uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executado de dois modos: pelo modo padrão, a qual a correção acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções. Um outro método para apresentação de dados de treinamento é no modo Batch, onde apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e valendo-se deste erro fazem-se as correções dos pesos (apud Haynin, 2000).

Para se efetuar o mapeamento do processo através de redes neurais artificiais, alguns passos devem ser seguidos para a adequada aplicação da abordagem neural. Os principais passos são especificados a seguir:

Passo 1 - Coleta de dados

O primeiro passo do processo de desenvolvimento de redes neurais artificiais é a coleta de dados relativos ao problema. Esta tarefa requer uma análise cuidadosa sobre o problema para minimizar ambigüidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o



domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema.

Passo 2 - Separação em conjuntos

Normalmente, os dados coletados devem ser separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede; e dados de teste, que serão utilizados para verificar seu comportamento sob condições reais de utilização.

Depois de determinados estes conjuntos, eles são geralmente colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, pode ser necessário pré-processar estes dados, através de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

Passo 3 -Configuração da rede

O terceiro passo é a especificação da configuração da rede, que pode ser dividido em três etapas:

1. Seleção do paradigma neural apropriado à aplicação.
2. Determinação da topologia da rede a ser utilizada - o número de camadas, o número de unidades em cada camada, etc.
3. Determinação de parâmetros do algoritmo de treinamento e funções de ativação. Este passo tem um grande impacto na performance do sistema resultante.

Existem metodologias na condução destas tarefas. Normalmente partes dessas escolhas são feitas de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte, que requer grande experiência dos projetistas.



Passo 4 - Treinamento

O quarto passo é o treinamento da rede. Nesta fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios pequenos uniformemente distribuídos, em um intervalo definido.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. Os principais critérios de parada do algoritmo de aprendizagem são o número máximo de ciclos e o erro quadrático médio por ciclo. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de over-treinamento, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização.

O treinamento deve ser encerrado quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível.

Passo 5 - Teste

O quinto passo é o teste da rede. Durante esta fase o conjunto de teste é utilizado para determinar a performance da rede com dados que não foram previamente utilizados.

Na próxima seção, descreve-se o algoritmo de treinamento referente ao processo de aprendizagem supervisionado das Redes Perceptron Multicamadas utilizadas nas simulações referidas neste trabalho.



3.2.3. Redes Perceptrons Multicamadas.

Quando Redes Neurais Artificiais de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, ou seja, não é possível a formação de uma representação interna (Haykin, 2000). Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento.

Tal restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva o sistema à incapacidade de aprender importantes mapeamentos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias. Um exemplo clássico deste caso é a função ou-exclusivo (XOR).

Minsky e Papert (Minsky, 1969) analisaram matematicamente o Perceptron demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre suscetíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento *backpropagation* (Rumelhart, 1986), por Rumelhart, Hinton e Williams em 1986, precedido por propostas semelhantes ocorridas nos anos 70 e 80, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizados atualmente, as redes Perceptron Multi-Camadas (MLP), treinadas com o algoritmo *backpropagation*.

Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos



padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema.

Como provou Cybenko (Cybenko, 1989), com base em extensões do Teorema de Kolmogorov são necessárias no máximo duas camadas intermediárias, com um número suficiente de unidades por camada, para se produzir quaisquer mapeamentos. Também foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua.

3.3. Processos de Aprendizagem de Redes Perceptrons.

3.3.1. A Regra Delta Generalizada (*Backpropagation*).

O algoritmo da regra delta generalizada (*backpropagation*), pode ser descrito da seguinte forma. Durante o treinamento com o algoritmo *backpropagation*, a rede opera em uma seqüência de dois passos. Primeiro, um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta, o erro é calculado. O erro é então propagado a partir da camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado (Haykin, 2000). Esse processo é repetido para todos os vetores de entrada da rede até que o erro quadrático médio das saídas da rede esteja num valor aceitável.



3.3.2. Derivação do algoritmo (*Backpropagation*)

A derivação do algoritmo “*backpropagation*”, para redes Perceptron com uma única camada escondida (Haykin, 2000) é realizada conforme a notação apresentada na Figura 3.12.




Figura 3.12. Diagrama esquemático da rede Perceptron

A partir da Figura 3.12, adota-se a seguinte convenção:

- i-) O parâmetro N especifica o número de variáveis que constitui cada vetor de entrada.
- ii-) O parâmetro N_1 especifica a quantidade de neurônios utilizados na camada neural escondida.
- iii-) O parâmetro N_2 especifica o número de variáveis que constitui cada vetor de saída, e também indica a quantidade de neurônios utilizados na camada neural de saída.

- iv-) O vetor $x = [x_1, x_2, \dots, x_N]^T$ denota o vetor de entrada da rede.
- v-) O vetor $y = [y_1, y_2, \dots, y_N]^T$ denota o vetor de saída da rede.
- vi-) O símbolo w_{ji} fornece o valor do peso sináptico conectando o j-ésimo neurônio da camada (1) ao i-ésimo neurônio da camada (1-1).
- vii-) O símbolo I_j fornece o valor correspondente à entrada ponderada do j-ésimo neurônio da camada (1), ou seja:

$$I1_j = \sum_{i=1}^N w_{ji} x_i; j = 1, \dots, N1 \quad (3.2)$$

$$I2_j = \sum_{i=1}^N w_{ji} y1_i; j = 1, \dots, N2 \quad (3.3)$$

- viii-) O símbolo y_j fornece o valor correspondente à saída do j-ésimo neurônio da camada (1), ou seja:

$$y1_j = g(I1_j) \quad ; j = 1, \dots, N1 \quad (3.4)$$

$$y2_j = g(I2_j) \quad ; j = 1, \dots, N2 \quad (3.5)$$

As funções erro quadrático $\{E(k)\}$ e erro quadrático médio $\{E_M\}$, as quais são utilizadas como critérios de desempenho e parada do processo de treinamento, são definidas por:

- i-) Erro quadrático

Esta função fornece o valor instantâneo da soma dos erros quadráticos (em relação ao k-ésimo padrão de treinamento) de todos os neurônios da camada de saída da rede, ou seja:

$$E(k) = \frac{1}{2} \sum_{j=1}^{N_2} (d_j(k) - y_{2j}(k))^2 \quad (3.6)$$

Onde $d_j(k)$ é o valor da saída desejada no neurônio j em relação ao k -ésimo padrão de entrada.

ii-) Erro quadrático médio

O erro quadrático médio é obtido a partir da soma dos erros quadráticos relativos a todos os padrões de entrada utilizados no conjunto de treinamento da rede, ou seja:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (3.7)$$

Onde o parâmetro p especifica o número de padrões de treinamento ou a quantidade de vetores de entrada.

Assim, o objetivo do processo de aprendizagem, utilizando o algoritmo “*backpropagation*”, consiste em ajustar as matrizes de pesos W_1 e W_2 da rede a fim de minimizar a função E_M .

O processo de ajuste dos pesos pode ser dividido em duas fases como descrito a seguir:

Fase 1: Ajuste dos pesos dos neurônios da camada de saída

O ajuste dos pesos dos neurônios da camada de saída (2ª camada neural) são feitos a partir da minimização da função erro quadrático em relação aos pesos w_{2j} . Utilizando a regra de diferenciação em cadeia, tem-se:



$$\nabla E_{(w_{2j})} = \frac{\partial E}{\partial w_{2j}} = \frac{\partial E}{\partial y_{2j}} \cdot \frac{\partial y_{2j}}{\partial I_{2j}} \cdot \frac{\partial I_{2j}}{\partial w_{2j}} \quad (3.8)$$

Onde:

$$\frac{\partial I_{2j}}{\partial w_{2j}} = y_{1i} \quad (3.9)$$

$$\frac{\partial y_{2j}}{\partial I_{2j}} = g'(I_{2j}) \quad (3.10)$$

$$\frac{\partial E}{\partial y_{2j}} = - (d_j - y_{2j}) \quad (3.11)$$

Substituindo (3.9), (3.10) e (3.11) em (3.8), obtém-se:

$$\frac{\partial E}{\partial w_{2j}} = - (d_j - y_{2j}) \cdot g'(I_{2j}) \cdot y_{1i} \quad (3.12)$$

Logo, o ajuste deverá ser feito na direção oposta ao gradiente a fim de minimizar a função erro quadrático, ou seja:

$$\Delta w_{2j} = -\eta \cdot \frac{\partial E}{\partial w_{2j}} \quad (3.13)$$

$$\Delta w_{2j} = -\eta \cdot \delta_{2j} \cdot y_{1i}$$

Ou ainda:

$$w_{2j}(t+1) = w_{2j}(t) + \eta \cdot \delta_{2j} \cdot y_{1i} \quad (3.14)$$

Onde η é uma constante que determina a taxa de aprendizagem (tamanho do passo em direção a ponto de mínimo da função erro mínimo quadrático) do

algoritmo “*backpropagation*”, e δ_{2j} denota o gradiente local sendo autodefinido por:

$$\delta_{2j} = (d_j - y_{2j}) \cdot g'(I_{2j}) \quad (3.15)$$

Fase 2 : Ajuste dos pesos dos neurônios da camada intermediária

O ajuste dos pesos dos neurônios da camada intermediária (1ª camada neural) é feito normalmente a partir da função erro quadrático em relação aos pesos w_{1ji} . Utilizando a regra de diferenciação em cadeia, tem-se:

$$\nabla E_{(w_{1ji})} = \frac{\partial E}{\partial w_{1ji}} = \frac{\partial E}{\partial y_{1j}} \cdot \frac{\partial y_{1j}}{\partial I_{1j}} \cdot \frac{\partial I_{1j}}{\partial w_{1ji}} \quad (3.16)$$

Onde:

$$\frac{\partial I_{1j}}{\partial w_{1ji}} = x_i \quad (3.17)$$

$$\frac{\partial y_{1j}}{\partial I_{1j}} = g'(I_{1j}) \quad (3.18)$$

$$\frac{\partial E}{\partial y_{1j}} = \sum_{k=1}^{N_2} \frac{\partial E}{\partial I_{2k}} \cdot \frac{\partial I_{2k}}{\partial y_{1j}} = \sum_{k=1}^{N_2} \frac{\partial E}{\partial I_{2k}} \cdot \frac{\partial (\sum_{k=1}^{N_2} w_{2kj} \cdot y_{1j})}{\partial y_{1j}} \quad (3.19)$$

$$= \sum_{k=1}^{N_2} \frac{\partial E}{\partial I_{2k}} \cdot \frac{\partial (\sum_{k=1}^{N_2} w_{2kj} \cdot y_{1j})}{\partial y_{1j}} \quad (3.20)$$

Inserindo o resultado da multiplicação de (3.10) por (3.11) em (3.19), tem-se:

$$\frac{\partial E}{\partial y_{1j}} = - \sum_{k=1}^{N_2} \delta 2_k \cdot w_{2kj} \quad (3.21)$$

Substituindo (3.17), (3.18) e (3.19) em (3.16), tem-se:

$$\frac{\partial E}{\partial w_{1j}} = \left(- \sum_{k=1}^{N_2} \delta 2_k \cdot w_{2kj} \right) \cdot g'(I_{1j}) \cdot x_i \quad (3.22)$$

O ajuste deve ser feito na direção oposta ao gradiente. Então, a equação (3.21) torna-se:

$$\Delta w_{1ji} = -\eta \cdot \frac{\partial E}{\partial w_{1ji}} \quad (3.23)$$

$$\Delta w_{1ji} = -\eta \cdot \delta 1_j \cdot x_i$$

Ou ainda:

$$w_{1ji}(t+1) = w_{1ji}(t) + \eta \cdot \delta 1_j \cdot x_i \quad (3.24)$$

Onde $\delta 1_j$ denota o gradiente local e é autodefinido por:

$$\delta 1_j = g'(I_{1j}) \cdot \left(\sum_{k=1}^{N_2} \delta 2_k \cdot w_{2kj} \right) \quad (3.25)$$

Assim, aplicam-se as Fases 1 e 2 seqüencialmente até que o erro quadrático médio da rede atinja um valor aceitável que é estipulado em função de cada aplicação específica.

CAPÍTULO 4

APLICAÇÃO DE R.N.A. NA CALIBRAÇÃO DE CÂMERAS

Neste capítulo, é feita a apresentação do método proposto, utilizando redes neurais para a calibração de câmeras e recuperação da informação tridimensional. Também, é apresentado o modelo de câmera e detalhado um procedimento de calibração de câmeras aplicado a um sistema de visão estéreo. Esse sistema é usado então para a simulação de um sistema de câmeras estéreo, com o propósito de gerar dados sintéticos de referência para treinamento e teste da técnica de calibração com redes neurais. A aplicação das duas técnicas em dados reais permite uma comparação dos métodos e uma avaliação do desempenho da técnica proposta para a calibração de câmeras com redes neurais, cujos resultados são apresentados no Capítulo 5.

4.1. A técnica proposta.



Para o desenvolvimento do trabalho, foi necessário que primeiramente se definisse o modelo matemático a ser empregado para os procedimentos de testes e treinamento da rede. Este modelo foi utilizado para a simulação de uma câmera e a geração de dados utilizados nos experimentos. Na sequência, é apresentado o modelo matemático de câmeras para simulação sem nenhuma modelagem de distorção óptica ou geométrica. A utilização de modelos matemáticos sem distorção é encontrada na literatura e apresenta boa aproximação para um grande número de aplicações nas quais é necessária a aquisição de coordenadas de imagens reais (Moumem, 2002). Este modelo pode ser estendido e aplicado a duas câmeras de um sistema de estéreo visão para permitir a recuperação de informação tridimensional.

4.1.1. Modelo Matemático da Câmera.

O modelo matemático permite simular as transformações matriciais, rotação, translação e perspectiva de um ponto no espaço para a sua projeção na imagem. As coordenadas das câmeras são expressas de forma homogênea, facilitando operações matriciais, e obtidas através do produto das referidas transformações. Pode-se também considerar um modelo com seis graus de liberdade, como por exemplo, no trabalho Ganapathy em (Ganapathy, 1984), porém isto não é necessário para os propósitos deste trabalho, porque dois graus de liberdade são suficientes para um sistema de aquisição estéreo.

$$C_h = P_1 \times C_1 \times R_1 \times G_1 \times W_h \quad (4.1)$$

Onde:

C_h - Coordenadas homogêneas, na câmera, da projeção de um ponto no espaço.

W_h -Coordenadas globais de um ponto no espaço.

P_1 – Matriz de transformação perspectiva.



C_I - Matriz de deslocamento do sistema de fixação da câmera.

G_I - Matriz de translação em relação às origens do sistema global de coordenadas.

R_I - Matriz de rotação.

A matriz transformação perspectiva, projeção dos pontos no plano de imagem, é dada por:

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & \frac{-1}{\lambda} & 1 \end{bmatrix} \quad (4.2)$$

Onde:

λ - Foco ou distância focal das câmeras.

A matriz translação da câmera em relação à origem das coordenadas globais é dada por:

$$G = \begin{bmatrix} 1 & 0 & 0 & -X_0 \\ 0 & 1 & 0 & -Y_0 \\ 0 & 0 & 1 & -Z_0 \\ 0 & 0 & 1 & 1 \end{bmatrix} \quad (4.3)$$

Onde:

X_0 - Coordenada X , do sistema de fixação da câmera.

Y_0 - Coordenada Y , do sistema de fixação da câmera.

Z_0 - Coordenada Z , do sistema de fixação da câmera.



A matriz de rotação da câmera no espaço, com dois graus de liberdade, é descrita por:

$$R = \begin{bmatrix} \cos \theta & \sin \theta & 0 & 0 \\ -\sin \theta \cos \alpha & \cos \theta \cos \alpha & \sin \alpha & 0 \\ \sin \theta \sin \alpha & -\cos \theta \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.4)$$

Onde:

α e θ são os ângulos de orientação (rotação) da câmera.

A matriz de deslocamento do sistema de fixação da câmera, em relação à origem é dada por:

$$C = \begin{bmatrix} 1 & 0 & 0 & -r_1 \\ 0 & 1 & 0 & -r_2 \\ 0 & 0 & 1 & -r_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.5)$$

Onde:

r_1 - deslocamento em x .

r_2 - deslocamento em y .

r_3 - deslocamento em z .

As coordenadas W_h são de mundo, expressas em coordenadas homogêneas; C_h são as coordenadas homogêneas da câmera depois das transformações do modelo matemático. Considerando um sistema estéreo pode-se escrever as equações para ambas as câmeras, C_h^1 e C_h^2 , como dado a seguir:

$$\begin{bmatrix} C_{h1} \\ C_{h2} \\ C_{h3} \\ C_{h4} \end{bmatrix} = [A] \times \begin{bmatrix} W_{h1} \\ W_{h2} \\ W_{h3} \\ W_{h4} \end{bmatrix} \quad (4.7)$$

$$C_h^1 = P_1 \times C_1 \times R_1 \times G_1 \times W_h \quad (4.8)$$

$$C_h^2 = P_2 \times C_2 \times R_2 \times G_2 \times W_h \quad (4.9)$$

Das quais pode-se obter as coordenadas de projeção dos pontos nas imagens com:

$$x_1 = \frac{C_{h1}^1}{C_{h4}^1} \quad (4.10)$$

$$y_1 = \frac{C_{h2}^1}{C_{h4}^1} \quad (4.11)$$

$$x_2 = \frac{C_{h1}^2}{C_{h4}^2} \quad (4.12)$$

$$y_2 = \frac{C_{h2}^2}{C_{h4}^2} \quad (4.13)$$

Observa-se que o modelo matemático obtido através das matrizes de rotação, translação, não considera a distorção das lentes das câmeras, presentes

nas câmeras nas experiências com imagens. Nos testes e experimentos, a simulação de distorções é realizada pela adição de ruído aos valores de coordenadas.

Ao se considerar um sistema estéreo, com duas câmeras, pode-se aplicar diretamente o modelo descrito acima a ambas as câmeras. As coordenadas dos pontos projetados no plano de imagem podem ser obtidas pela aplicação direta das equações (4.8) e (4.9). A diferença entre as duas câmeras para a simulação de um sistema estéreo é basicamente a mudança apenas na matriz G , a qual determina a posição do sistema de fixação de cada câmera no espaço. Assim, obtém-se (x_1, y_1) e (x_2, y_2) das duas câmeras, C^1 e C^2 , pelas equações (4.10) a (4.13), observando que a divisão pelo quarto elemento C_{44} é devido às equações (4.10) a (4.13) estarem na forma homogênea.

4.1.2. Método de Hall Aplicado à Visão Estéreo.

Para validar a metodologia empregada neste trabalho, a qual utiliza redes neurais artificiais, foi elaborado um procedimento de simulação que emprega o método de Hall (apud Salvi, 2002) para a calibração de câmeras, adaptado para o problema de estéreo visão, para determinar os pontos no espaço a partir dos pontos de câmera, isto é, recuperar a informação tridimensional a partir das imagens.

Observa-se que, no método de Hall tradicional, a matriz de calibração A , da equação 2.8, determina a relação das coordenadas globais para coordenada das projeções em cada câmera. Assim, no desenvolvimento desta seção, um método similar de calibração é utilizado para determinar as coordenadas globais de um ponto no espaço, utilizando-se as suas coordenadas bidimensionais projetadas em duas câmeras de um sistema estéreo.

De acordo com (Gonzalez, 2000), a transformação perspectiva inversa mapeia um ponto na imagem de volta ao espaço. Então, a matriz de transformação perspectiva (equação 4.2) torna-se:



$$W_h = P^{-1} \times C_h \quad (4.14)$$

em que P^{-1} é:

$$P^{-1} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & \frac{1}{\lambda} & 1 \end{bmatrix} \quad (4.15)$$

Assim como a transformação perspectiva tem uma matriz inversa (4.15), as outras transformações empregadas para modelo matemático da câmera apresentada no início do capítulo também possuem transformações inversas (R^{-1} , C^{-1} e G^{-1}). Desse modo, de acordo com a equação (4.14), pode-se aplicar uma matriz de transformação inversa da matriz de calibração A , utilizada para calibração de uma câmera, para determinar às coordenadas globais a partir das coordenadas da imagem. Assim:

$$W_h = A^{-1} \times C_h \quad (4.16)$$

Então:

$$\begin{bmatrix} W_{Xmundo} \\ W_{Ymundo} \\ W_{Zmundo} \\ W \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \\ a_{41} & a_{42} & a_{43} \end{bmatrix} \times \begin{bmatrix} X_i \\ Y_i \\ 1 \end{bmatrix} \quad (4.17)$$

De acordo com a equação (4.17), realiza-se uma transformação inversa através de uma matriz de calibração A , para determinar as coordenadas de mundo através das coordenadas da câmera. Entretanto, esse sistema é sub-dimensionado e o seu resultado não é único.

Para a obtenção das coordenadas de um ponto no espaço a partir das suas projeções em uma imagem, é necessário o emprego de um sistema estéreo. A



derivação de um modelo para duas câmeras, em um sistema de visão estéreo, é apresentada a seguir.




Figura 4.1. Modelo de sistema estéreo mostrando a projeção de um ponto w nas duas câmeras.

A Figura 4.1 apresenta um sistema estéreo, no qual o ponto $P'_2 (x'_2, y'_2)$, corresponde ao ponto P_2 da imagem 2, transformado para a posição que faz com que as duas câmeras coincidam. P_2 é o ponto P_w projetado na câmera 2, e $P'_2 (x'_2, y'_2)$ é a representação do mesmo ponto tomado em relação a um sistema de coordenadas (coordenadas de tela) que tem a mesma referência em qualquer imagem. Isso decorre do fato de que as coordenadas dos pontos na imagem são obtidas em relação ao sistema local (em cada imagem-câmera). Assim, é necessário realizar uma transformação da representação de coordenadas no sistema de tela local para o sistema global.

$$P'_2 = T \times P_2 \Rightarrow T^{-1} \times P'_2 = P_2 \quad (4.18)$$

Da equação do modelo da câmera temos que:

$$P_w = A_1 \times P_1 \quad (4.19)$$

e

$$P_w = A_2 \times P_2 \quad (4.20)$$

Considerando (4.18), pode-se escrever:

$$P_w = A_2 \times T^{-1} \times P'_2 \quad (4.21)$$

Ou,

$$P_w = A'_2 \times P'_2 \quad (4.22)$$

As duas relações (4.19) e (4.22) podem ser combinadas em:

$$P_w = \begin{bmatrix} A_1 & 0 \\ A_2 & 1 \end{bmatrix} \times \begin{bmatrix} P_1 \\ P_2 \end{bmatrix} \quad (4.23)$$

$$P_w = A \times P_{1,2} \quad (4.24)$$

De acordo com o desenvolvimento apresentado, pode-se escrever:

$$\begin{bmatrix} X_{\text{mundo}} \\ Y_{\text{mundo}} \\ Z_{\text{mundo}} \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} \\ a_{21} & a_{22} & a_{23} & a_{24} \\ a_{31} & a_{32} & a_{33} & a_{34} \end{bmatrix} \times \begin{bmatrix} x_{i1} \\ y_{i1} \\ x_{i2} \\ y_{i2} \end{bmatrix} \quad (4.25)$$

Estendendo-se a equação (4.25) para expressar as coordenadas de mundo na forma homogênea, tem-se:



$$\begin{bmatrix} WX_{\text{mundo}} \\ WY_{\text{mundo}} \\ WZ_{\text{mundo}} \\ W \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} \end{bmatrix} \times \begin{bmatrix} x_{i1} \\ y_{i1} \\ x_{i2} \\ y_{i2} \\ 1 \end{bmatrix} \quad (4.26)$$

A matriz A , da equação (4.26), representa as transformações necessárias para determinar as coordenadas globais a partir das coordenadas das duas câmeras, tornando-se um modelo análogo à calibração de uma câmera. Entretanto, a matriz A também representa as transformações necessárias mais distorções de câmeras, presentes nos experimentos com imagens reais.

Como as matrizes estão dispostas em sua forma homogênea, a coordenada X_{mundo} , por exemplo, será o primeiro elemento da matriz (4.26) dividido pelo último elemento dessa matriz, obtendo-se a coordenada X_{mundo} na forma cartesiana, tal transformação é necessária para recuperação de coordenadas expressas em coordenadas homogêneas para a forma cartesiana, assim:

$$X_{\text{mundo}} = \frac{WX_{\text{mundo}}}{W} \quad (4.27)$$

De acordo com as matrizes acima, pode-se escrever:

$$X_{\text{mundo}} = \frac{a_{11}x_{i1} + a_{12}y_{i1} + a_{13}x_{i2} + a_{14}y_{i2} + a_{15}}{a_{41}x_{i1} + a_{42}y_{i1} + a_{43}x_{i2} + a_{44}y_{i2} + a_{45}} \quad (4.28)$$

Fazendo-se arbitrariamente $a_{45}=1$ pode-se reescrever da seguinte maneira.

$$X_m = a_{11}x_{i1} + a_{12}y_{i1} + a_{13}x_{i2} + a_{14}y_{i2} + a_{15} - X_m a_{41}x_{i1} - X_m a_{42}y_{i1} - X_m a_{43}x_{i2} - X_m a_{44}y_{i2} \quad (4.29)$$

Assim pode-se demonstrar para as coordenadas Y_{mundo} e Z_{mundo}

Reescrevendo as equações como:

Aplicando-se o método dos mínimos quadrados, pode-se encontrar a matriz A que relaciona as coordenadas dos pontos de imagem das duas câmeras com as coordenadas globais dos pontos correspondentes. Depois de determinada a matriz A de calibração, aplica-se a solução (4.26) e com as coordenadas das projeções das duas câmeras pode-se determinar as coordenadas globais dessas projeções.

Esse método foi implementado no Matlab, como uma ferramenta para confrontar os resultados obtidos com aqueles obtidos nos experimentos utilizando R.N.A.

4.2. Neurocalibração

Nesta seção são apresentadas as motivações, quanto ao emprego das R.N.A. para o desenvolvimento dos experimentos realizados neste trabalho, e as justificativas quanto à topologia da rede neural empregada (como número de pontos de treinamento e teste, número de neurônios e camadas, tipos de funções de ativação, algoritmo de treinamento, erro de treinamento da rede). É importante observar que, alguns trabalhos encontrados na literatura denominam como *neurocalibração* o emprego de R.N.A em calibração de câmeras (Moumem, 1999).

4.2.1. Vantagens para o emprego de Redes Neurais

Em uma rede neural, a informação pode parecer ter representação redundante, porém, o fato de que ela se encontre distribuída por todos os elementos da rede significa que mesmo que parte da rede seja destruída, a informação contida nesta parte ainda estará presente na rede, e poderá ser recuperada. Portanto, a redundância, na representação de informações em uma rede neural, diferente de outros sistemas, transforma-se em uma vantagem, que torna o sistema tolerante à falhas. Generalizações redundantes e tolerância a falhas



proporcionam fortes incentivos para a escolha de redes neurais como uma escolha apropriada para aproximação para a modelagem de sistemas biológicos. Outras importantes considerações, as quais também demonstram o potencial de uma rede neural, assim podem ser enumeradas a seguir:

- Uma importante característica de redes neurais reside em sua capacidade de adaptação e aprendizagem. Essa capacidade de adaptação e aprendizagem pelo ambiente significa que modelos de redes neurais podem lidar com dados imprecisos e situações não totalmente definidas, robustez. Isso significa que ela é imune a pequenas falhas a rede poderá reconhecer um determinado padrão embora existam distorções em suas entradas (Loesch, 1996).
- Uma característica significativa de redes neurais está em sua capacidade de aproximar qualquer função contínua não linear de um grau de correção desejado. Esta capacidade das redes neurais as tem tornado útil para modelar sistemas não lineares na combinação de controladores não lineares como calibração de câmeras em razão de transformações perspectiva e distorções radiais.

Com o avanço em tecnologias de recursos computacionais, existem componentes com funções voltadas a sistemas com implementações para redes neurais, o que traz uma velocidade adicional à computação neural. Na próxima seção, apresenta-se o desenvolvimento da aplicação das R.N.A. como um método de calibração de câmeras.

4.2.2. Aplicação de Redes Neurais Artificiais em Calibração

No processo de calibração em estéreo visão convencional, utilizam-se soluções matemáticas não lineares (considerando-se as distorções das câmeras) para a determinação dos parâmetros de um modelo de câmera.

A aplicação de Redes Neurais em calibração de câmera e recuperação de informação tridimensional, como a principal proposta deste trabalho, tem por objetivo possibilitar a calibração de câmeras sem conhecimento prévio da



geometria do sistema de calibração e das características intrínsecas (modelo) de câmeras utilizadas na obtenção das imagens. Assim, a vertente da pesquisa foi o emprego de redes neurais artificiais, para calibração de um sistema de visão estéreo e, após o processo de calibração, a aplicação da rede na recuperação de informação 3-D, ou seja, reconhecimento de formas tridimensionais de um objeto de teste (scanner 3-D).

Então, para a solução do problema de calibração do sistema de visão estéreo, utilizou-se uma rede Perceptron Multicamadas com algoritmo Levenberg Marquadt para o processo de treinamento. Como objeto de calibração, geraram-se aproximadamente 200 a 300 pontos de treinamento para dados sintéticos, devido à simplicidade de geração desses pontos de teste. Entretanto para dados reais, a aquisição dos pontos de teste é realizada usando um *grid* de 130 pontos, empregados no treinamento da rede neural e para solução analítica do método dos mínimos quadrados. O número de pontos usado foi definido empiricamente e se baseou na maioria dos trabalhos encontrados na literatura que apresentam conjunto de pontos com a mesma ordem de grandeza. Os pontos de teste (do *grid*), diferem dos pontos de treinamento, por serem coloridos (vermelhos e verdes) e também pela posição diferente dos pontos de teste. O erro de treinamento da rede para experimentos com dados sintéticos foram de 10^{-6} , 10^{-7} e 10^{-8} . Entretanto, o erro de treinamento para dados reais foi de 10^{-6} e 10^{-5} , em razão de um tempo muito alto de treinamento da rede neural para dados reais. No treinamento da rede, os dados de entradas são as coordenadas das projeções das duas câmeras (x_1, y_1) e (x_2, y_2) e na camada de saída, as coordenadas de mundo ou globais (X_{mundo} , Y_{mundo} e Z_{mundo}), como mostra a Figura 4.2.

Somente nas experiências com reconhecimento de posição ou foco, a rede neural sofreu alterações em sua topologia, com o acréscimo de mais um neurônio na camada de saída, referentes à posição ou a distancia focal objetivada após o treinamento da R.N.A., entretanto, tais mudanças são apresentadas no Capítulo 5.






Figura 4.2 Modelo da Rede Neural

4.2.3. Características da rede neural empregada no trabalho.

Neste trabalho, foram realizados testes com redes neurais com duas camadas ocultas, e também com uma camada oculta somente, com as seguintes funções de ativação.

1. Para duas camadas ocultas

Tangente sigmóide nas camadas ocultas e rampa na camada de saída. No trabalho (Wells, 1996), por exemplo, utilizou-se uma combinação de funções de ativação sigmóide, tangente hiperbólica e na camada de saída, função rampa. É importante notar que: uma rede com mais de uma camada oculta, cujos neurônios utilizam funções de ativação lineares é equivalente a uma rede de uma só camada (Braga, 2001). Braga demonstra tal observação utilizando propriedades da álgebra linear (Lay, 1999). O emprego dessas funções deve-se também ao fato de serem diferenciáveis em todos os seus pontos (Haykin, 2000).

2. Para uma camada oculta

Tangente sigmóide na camada oculta e rampa na última camada.

O emprego da função rampa e tangente sigmóide deve-se ao fato destas funções assumirem valores negativos, prováveis de acordo com a natureza do

problema, ou seja, os valores das coordenadas de imagem e das coordenadas globais podem ser negativos.

Quanto ao número de neurônios das camadas de entrada e saída, são definidos de acordo o número de variáveis empregadas na entrada e saída da rede neural, por exemplo, nos experimentos em que se empregou reconhecimento do relacionamento 3-D para 2-D, empregados na maioria dos experimentos, foram utilizados quatro neurônios na camada de entrada (coordenadas x , y das câmeras) e três neurônios na camada de saída (coordenadas X , Y e Z do espaço).

Porém, na literatura abordada, alguns autores utilizaram critérios diferentes, por exemplo, no trabalho (Lynch, 1999), fixou-se o número de neurônios em 15 na camada oculta. No trabalho (Wells, 1996) foram feitos testes inicialmente com 10 neurônios somando de 10 em 10, até o máximo de 60 neurônios na camada oculta, com números próximos ao utilizado no desenvolvimento deste trabalho. Assim, nesse trabalho utilizou-se o número de neurônios intermediários próximos a 50, diminuindo o número de épocas de treinamento da rede neural nos experimentos e também por restrições dos recursos computacionais (hardware e software), empregados que não permitiram número de neurônios intermediários superiores a 55, assim para não se trabalhar no limite do processamento, ou seja, com mais que 55 neurônios o MatLab não processava, assim optou-se por 50 neurônios na maioria dos experimentos.

Existem algumas técnicas de otimização do número de neurônios na camada intermediária, por exemplo, o emprego dos métodos de *pruning*, os quais objetivam a retirada de neurônios ociosos da camada intermediária que não contribuem para correta classificação dos dados (Silvestre, 2002). A filosofia de um dos métodos de *pruning* é a retirada de elementos da rede e a subsequente verificação da variação de erro de saída. Caso a retirada deste elemento não cause grande variação do erro de saída, conclui-se que a rede é pouco sensível a este e que ele pode ser retirado sem perda de capacidade da rede de modelar dados (Braga, 2001).



A Figura 4.3 apresenta a curva de treinamento da rede neural empregado em um dos experimentos realizados, no desenvolvimento do presente trabalho.




Figura 4.3. Exemplo de treinamento de uma Rede Neural Artificial.

O gráfico da Figura 4.3 mostra o erro da rede neural em cada época, objetivando o erro de 10^{-8} , pré-definido para o treinamento da rede. A Figura 4.3 também mostra o número de 1359 épocas, necessárias para atingir o erro estimado e a performance final da rede. O número de épocas significa quantas vezes foi necessário apresentar o conjunto de dados de entrada e saída, para atingir o erro estimado no treinamento da rede neural.

4.3. Materiais e Metodologia

Através da aplicação do modelo matemático mencionado no início deste capítulo, são gerados dados sintéticos, simulando projeções dos pontos de um *grid* virtual nas duas câmeras.

Geometricamente cada ponto do espaço só pode ter um correspondente com as coordenadas das imagens (x_1, y_1) , e (x_2, y_2) nas duas câmeras. Neste trabalho, geraram-se pontos no espaço, em alguns experimentos aleatoriamente (somente na geração de dados sintéticos), e por um *grid*, com dimensões conhecidas, dentro de uma região definida, para experimentos com superfície, os dados sintéticos foram gerados mais precisamente em um quadrado com a coordenada Z_g fixa em 0.2m e X_g e Y_g de 0.65 a 1.35m. Através de modelos matemáticos das duas câmeras, determinou-se às coordenadas dos pontos x e y nas duas imagens.

As simulações, realizadas através de modelos matemáticos, servem como primeiro passo no desenvolvimento, presente na maioria dos trabalhos prévios da literatura, servindo para ajustes e conclusões iniciais importantes antes da implementação com dados reais.

Para aquisição dos dados reais (imagens), foram utilizados três tipos de câmeras. Nas experiências com a aquisição de imagens feita pela câmera digital Sony, os resultados foram melhores, devido a melhor qualidade da imagem gerada por este tipo de câmera quanto às distorções. Os erros dos experimentos realizados com a câmera digital resultam das imprecisões de aquisição das coordenadas das medidas dos pontos de treinamento através das imagens das duas câmeras.

Os experimentos objetivaram comparações entre os resultados empregando dados sintéticos e imagens reais. Os quais empregam os dois métodos M.M.Q. e R.N.A. A seqüência dos passos de execução para a realização dos experimentos é exibida na Figura 4.4.






Figura 4.4. Fluxograma para realização das experiências.

As experiências incluíram várias configurações diferentes, avaliando a influência de número de neurônios e camadas nos resultados, como também a precisão de treinamento. São organizadas experiências em oito grupos, relativos ao tipo de treinamento, nos quais as redes neurais generalizaram em todos os casos:

- Treinamento no qual a rede reconhece parâmetros intrínsecos como o foco, em experimentos realizados com dados sintéticos.
- Treinamento de reconhecimento de pontos em uma superfície usando dados sintéticos.
- Treinamento de reconhecimento de pontos em um volume, usando dados sintéticos.

- Treinamento de reconhecimento de pontos em uma superfície plana, com a aquisição de pontos de imagens reais de um *grid* com dimensões conhecidas.
- Treinamento com reconhecimento de pontos em um volume definido no espaço com imagens reais, utilizando quatro *grids* superpostos.
- Treinamento no qual a rede reconhece posição de uma câmera no espaço, utilizando imagens reais.
- Treinamento em que a rede recupera pontos para geração uma superfície 3-D, gerada através de dados sintéticos de uma função seno. Uma simulação para recuperação de informação 3-D (scanner 3-D).
- Treinamento em que a rede recupera a superfície de um objeto (mouse) como princípio de construção de um scanner 3-D.

Nos primeiros experimentos a topologia utilizada foi com duas camadas intermediárias (4-20-30-3), a qual tinha 4 neurônios na primeira camada (coordenadas x, y das câmeras), 20 neurônios na primeira camada intermediária, 30 neurônios na segunda camada intermediária e 3 neurônios na camada de saída (coordenadas globais X, Y e Z). Mas teoricamente, a solução de um problema não linear com domínio contínuo (Haykin, 2000) necessita de somente uma camada intermediária. Assim, posteriormente foram realizados experimentos, nos quais a topologia empregada no treinamento da rede com imagens reais foi de (4-50-3), com apenas uma camada oculta com 50 neurônios, com 4 e 3 neurônios nas camadas de entrada e saída respectivamente, conseguiu-se assim um menor tempo de processamento para o treinamento da rede neural, devido à utilização de apenas uma camada oculta. Observou-se a necessidade de utilizar uma camada oculta, nas experiências com imagens reais, em razão de erros de aquisição dos pontos e distorções radiais, necessitando de um tempo muito maior no treinamento da rede comparado ao tempo de processamento com dados sintéticos. Os experimentos com dados reais são a aplicação prática dos métodos apresentados neste trabalho.

O método empregado (R.N.A.) apresenta a vantagem sobre métodos tradicionais, pois não é necessário se conhecer a geometria das câmeras, seus parâmetros intrínsecos, e a calibração é feita simultaneamente para as duas



câmeras. Desta forma, o processo de calibração torna-se mais prático, pois impõe menos restrições na configuração do aparato de calibração e é desnecessária a determinação intermediária de alguns parâmetros da câmera, como o foco. Mesmo em situação de simulação de erros e distorção de foco, semelhantes à aquisição de imagens reais, a rede foi capaz de calibrar as câmeras com excelente precisão (menor que 1%) para os padrões de calibração apresentados na literatura.

4.4. Equipamento utilizado

Para o desenvolvimento do experimento, utilizou-se para soluções matemáticas o Matlab versão 5.2., e o Toolbox Neural Network com o método Levenberg Marquardt para a otimização, aprendizado e teste da rede neural, também utilizado nos trabalhos de Moumem em (Moumem, 1999, 2002).

O recurso de hardware utilizado foi um K6-2 AMD 500 MHz 128 MBRAM. Foram utilizados três tipos de câmera diferentes para validar os resultados: uma Webcam 3.0 Creative; uma câmera digital Sony; e também uma Webcam Dexta 1.0. Ambas as Webcams apresentam como característica um alto grau de distorção ótica.

Os recursos computacionais utilizados para o desenvolvimento dos experimentos apresentaram um tempo de processamento da ordem de minutos para o ajuste do método dos mínimos quadrados, mesmo nos experimentos realizados com imagens reais. Entretanto, quanto ao treinamento das Redes Neurais, o tempo de processamento foi da ordem de minutos em experimentos com dados sintéticos, de horas com experimento com dados sintéticos com a adição simulada de erros de aquisição (erro gaussiano) e dias em experimentos feitos com aquisição de imagens (dados reais). É importante observar que: a Rede Neural depois da etapa de treinamento, o qual é feito apenas uma vez se não houver alteração no aparato (*setup*), tem uma resposta de tempo da ordem de segundos para testes de calibração do sistema estéreo proposto neste trabalho.

Para a geração e aquisição das imagens de teste e treinamento da rede, foi criado um *grid* de 130 pontos e aparatos para fixação da câmera. O número de



pontos para o *grid*, teoricamente, tem que ser bem maior do que 6 para soluções matemáticas analíticas. Entretanto, o número utilizado, 130 pontos, é da mesma ordem de grandeza daqueles apresentados em outros trabalhos, por exemplo, 140 pontos em (Zhengyou, 1998). A localização dos pontos de teste foi feita manualmente com imprecisões nas medidas de coordenadas globais, considerando que cada ponto apresentava um diâmetro médio de aproximadamente 1cm e distância aproximada entre os pontos de 2cm.

CAPÍTULO 5

RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados os resultados dos experimentos realizados para a validação do método proposto. Estes resultados foram obtidos a partir dos testes e da metodologia apresentada no Capítulo 4. O desempenho da técnica é avaliado através do erro médio absoluto e o erro médio relativo, os quais foram calculados a partir dos resultados obtidos com a aplicação do método proposto e das coordenadas reais dos pontos de teste. Estes erros foram obtidos após o treinamento da rede ou ajuste do método dos mínimos quadrados com o número de pontos relatados em cada experimento. Em média, foram utilizados seis pontos de teste fora do conjunto de treinamento da R.N.A. e do conjunto utilizado para a solução pelo M.M.Q. O número de pontos de teste foi de aproximadamente 5% do número de pontos de treinamento para aquisição de dados reais.

Inicialmente, são apresentadas as tabelas com os dados dos experimentos e a descrição de cada um. Na sequência, são feitas uma apresentação e análise dos resultados.



5.1. Resultados

Os resultados da aplicação do método de redes neurais para a calibração de câmera são apresentados na tabela 5.1a. Na tabela 5.1b, são apresentados os resultados da aplicação do método dos mínimos quadrados com a finalidade de comparar os resultados obtidos pelos métodos. Cada linha dessas tabelas representa um experimento com uma configuração diferente. A tabela 5.2 apresenta a topologia da rede neural usada, com número de camadas, neurônios e erro de treinamento. A tabela 5.3 confronta os dois métodos em uma comparação direta entre os principais experimentos, os quais foram realizados com a mesma base de dados, para que se tenha resultado parcial no emprego dos dois métodos.

Tabela 5.1a. Resultado dos experimentos R.N.A.

Num.Exp.	Pontos	E.M.A.	E.M.R.
01	300	0,0000	0,00%
02	300	0,00001	0,00%
03	250 ^E	0,00213	0,20%
04	250 ^E	0,00091	0,10%
06	200	-0,00011	0,00%
07	250	-0,3333	0,00%
08	250	0,0001	0,00%
09	250	0,00025	0,00%
13	300 ^A	0,00117	0,10%
14	100	-0,00024	0,00%
15	300	0,0000	0,00%
18 ^R	130	0,2056	5,00%
20 ^R	130	-0,2872	2,00%
21 ^R	130	-0,0150	4,00%
22 ^R	130	0,01895	1,00%
23 ^R	130	0,02560	1,50%
24 ^R	130	-0,23856	1,15%

^A Pontos aleatórios.

^R Experimentos com pontos reais.

^E Simulações com erros gaussianos

^F Simulações com identificação de focos

E.M.A. – Erro médio absoluto.

E.M.R. – Erro médio relativo.



A tabela 5.4. sumariza os resultados, confrontando as experiências com dados sintéticos e imagens reais dos dois métodos aplicados.

Como o número de experimentos realizados foi muito grande, os resultados individuais de cada ponto de teste são apresentados nas tabelas do Apêndice II, as quais mostram os erros absolutos e relativos de cada ponto confrontando as soluções obtidas com o emprego de redes neurais ou com o método dos mínimos quadrados.

Tabela 5.1b. Resultado dos experimentos M.M.Q.

Num.	Pontos	E.M.A.	E.M.R.
00	300	$3,3300 \times 10^{-5}$	0,00%
05	150 ^E	-0,00678	0,80%
10	100 ^A	0,01169	1,20%
11	200	-0,00267	0,30%
12	300	0,00076	0,10%
16	300	0,00200	0,00%
17 ^R	130	0,23590	4,00%
19 ^R	130	-0,03695	1,00%

^A Pontos aleatórios.

^R Experimentos com pontos reais.

^E Simulações com erros gaussianos

^F Simulações com identificação de focos

E.M.A. – Erro médio absoluto.

E.M.R. – Erro médio relativo.

Tabela 5.2. Características da Rede Neural

Num.	Erro rede	Num. Épocas	Topologia rede	Pontos
01	10^{-7}	7	[20-30-3]	300
02	10^{-7}	9	[20-30-3]	300
03	10^{-6}	252	[20-30-3]	250 ^E
04	10^{-7}	989	[20-30-3]	250 ^E
06	10^{-8}	43	[20-30-5] ^F	200
07	10^{-6}	7	[20-30-3]	250
08	10^{-7}	9	[20-30-3]	250
09	10^{-8}	12	[20-30-3]	250
13	10^{-7}	10	[20-30-3]	300 ^A
14	10^{-8}	8	[20-30-3]	100
15	10^{-8}	13	[20-30-3]	300
18 ^R	10^{-8}	130	[20-30-3]	130
20 ^R	10^{-6}	358	[50-3]	130
21 ^R	10^{-8}	1359	[50-3]	130
22 ^R	10^{-5}	5000	[55-3]	560
23 ^R	10^{-6}	1256	[55-3]	130
24 ^R	10^{-5}	2500	[55-3]	320
25 ^R	10^{-6}	467	[50-3]	130
26 ^S	10^{-6}	258	[50-3]	450
27 ^S	10^{-6}	364	[50-3]	364
28 ^S	10^{-5}	5000	[50-3]	320
29 ^S	10^{-5}	3000	[45-3]	520

^A Pontos aleatórios.

^R Experimentos com pontos reais.

^E Simulações com erros gaussianos

^F Simulações com identificação de focos

^S Experimentos para recuperação 3-D (Scanner 3-D)

A organização e seqüência lógica dos experimentos foram definidas visando comprovar inicialmente, com dados sintéticos, a viabilidade da técnica proposta para, em seguida, coletar e analisar dados para imagens reais, com distorções e erros de aquisição. Além disso, os experimentos com dados sintéticos foram divididos em quatro grupos de experimentos, o primeiro somente com a aplicação do modelo de câmera simples, o segundo grupo com inclusão de erros gaussianos nos dados, simulando aquisição de imagens reais, e o terceiro grupo acrescentando o reconhecimento de foco das câmeras, além da recuperação de posição. O quarto grupo de testes para dados sintéticos foi realizado considerando a recuperação 3-D de uma superfície conhecida, para análise de resultados



antecedendo experimentos com aquisição real de imagens. Os experimentos com aquisição de imagens reais foram divididos em dois grupos: reconhecimento de pontos em superfícies ou volumes.

O experimento inicial (experimento zero) foi realizado com dados sintéticos em uma superfície plana para verificar a aplicação do modelo matemático usado para a simulação de um sistema estéreo e também para validar o próprio método de calibração estéreo empregando minimização quadrática, desenvolvida no Capítulo 4.

Os dois primeiros experimentos implementados com R.N.A., 1 e 2, com simulação dos dados, apresentaram erros muito pequenos, permitindo validar a proposta e serviram de indicação para que novos experimentos fossem realizados.

Nos experimentos 3, 4 e 5 foi feito o acréscimo de um erro gaussiano da ordem de 5%, na entrada dos dados da R.N.A., para uma simulação dos erros de aquisição das coordenadas, tanto a posição dos pontos no espaço como dos pontos na imagem. Nesse caso, foi necessário usar um maior número de épocas para generalizar.

O experimento 5 foi realizado utilizando o mesmo método empregado no experimento zero (método de Hall), para permitir uma referência de comparação. A simulação realizada neste caso foi à mesma daquela empregada para o uso de redes neurais nos experimentos 3 e 4.

O experimento 6 demonstrou a aplicação de redes neurais com o treinamento utilizando dois focos diferentes, isto é, uma das duas câmeras utiliza dois focos. Os resultados mostraram que a rede foi capaz de reconhecer os focos, previamente utilizados no treinamento da rede. Este experimento é importante, pois abre a perspectiva de aplicação do método para câmeras diferentes, demonstrando assim o potencial das redes neurais como um método de calibração inteligente para a recuperação de parâmetros extrínsecos e intrínsecos. Pode-se ainda vislumbrar a aplicação deste método para a calibração de câmeras com lentes ativas (Moumem, 2002). Observa-se que, para o desenvolvimento deste experimento, foram necessários 5 neurônios na última camada da rede neural,



devido as três coordenadas de mundo (X , Y e Z) e as duas distancias focais de cada uma das câmeras.

Os experimentos 7,8 e 9 foram realizados com pontos sintéticos gerados em uma superfície plana no espaço utilizando as redes neurais apenas para confirmar os resultados obtidos anteriormente, através de testes exaustivos.

Os experimentos 10, 11, 12, 13, 14 e 15 utilizaram pontos sintéticos em um paralelepípedo, confrontando as técnicas de R.N.A. e M.M.Q. Os resultados obtidos apresentaram precisão bastante similar aos anteriores.

O experimento 16 foi feito com uma simulação com dois focos diferentes, utilizando o método de Hall estendido para se confirmar à eficácia desta solução, e compara com os resultados obtidos no experimento 6, o qual empregou redes neurais na mesma condição (simulação). É importante observar que, neste caso especificamente, a rede reconhece o foco utilizado e o método de Hall não, sendo necessário especificar no procedimento.

Os experimentos 17 e 18 foram realizados com a aquisição de dados de imagens reais de um plano com uma câmera WebCam3. Nestes casos, a distorção radial, não tratada nos experimentos simulados, é bastante evidente e tem origem devido à baixa qualidade ótica deste tipo de câmera (Figura 5.1). Ressalta-se, entretanto, que o emprego destas câmeras deve ser considerado pelo baixo custo das mesmas e a grande disponibilidade para aplicação.




Figura 5.1. Imagens do Grid, obtidos com uma Webcam Creative em um sistema estéreo.




Figura 5.2. Imagens do grid obtidas através de uma câmera Sony.

Os experimentos 19, 20 e 21 são semelhantes aos experimentos 17 e 18 com a diferença de se utilizar uma câmera digital da Sony, com melhor qualidade ótica (Figura 5.2). As duas ferramentas foram confrontadas, trazendo compatibilidade nos resultados obtidos.

Tabela 5.3. R.N.A. x M.M.Q. (Resultados Parciais)

Redes Neurais Artificiais			Método dos mínimos quadrados			Tipo
Experimentos	Erro Relativo	Erro Absoluto	Experimentos	Erro Relativo	Erro Absoluto	
1 e 2	0,00%	$5,00 \times 10^{-5}$	0	0,00%	$3,33 \times 10^{-5}$	Modelo puro
3e4	0,15%	0,00152	5.	0,80%	-0,00678	Erro Gaussiano
6	0,00%	-0,00011	16	0,00%	0,0020	Focos diferentes
13	0,10%	0,00117	10	1,20%	0,01169	Pts aleatórios
14e15	0,00%	-0,00012	11e12	0,10%	-0,00096	Paralelepípedo
18	5,00%	0,2056	17	4,00%	0,2359	WebCam
20 e 21	3,00%	-0,1511	19	1,00%	-0,03695	SONY

Na tabela 5.3, é apresentada uma comparação entre o método dos mínimos quadrados e a rede neural, nos experimentos realizados com as mesmas condições de aquisição de dados, ou seja, mesmo aparato para imagens reais e mesmo modelo para os dados sintéticos.

Na tabela 5.4, é apresentada uma comparação geral entre os resultados obtidos com cada uma das classes de experimentos. Comparam-se os erros obtidos com dados sintéticos e dados reais e entre as soluções com método dos mínimos quadrados e RNA.

Tabela 5.4. R.N.A. x M.M.Q. (Resultados Finais)

Dados Sintéticos	Média E.A.	Média E.R.
R.N.A.	0,0300	0,036%
M.M.Q.	0,0480	0,480%
Dados Reais	Média E.A.	Média E.R.
R.N.A.	0,1317	3,000%
M.M.Q.	0,1364	2,500%

É importante observar que os resultados apresentados na tabela 5.4 levam em conta apenas as médias de erro obtido com a rede neural até a experiência 21. Isso se deve ao fato de que as últimas experiências utilizaram aparatos diferentes para recuperação 3-D, com o reconhecimento de posição e aquisição de imagens com câmeras diferentes, e não ter sido aplicado o método de mínimos quadrados. Dessa maneira, não teria significado incluir tais resultados na Tabela 5.4, na qual é feito um confronto de resultados dos dois métodos. Nesta tabela, são computados os erros em módulo para as médias dos erros absolutos e relativos.

5.1.1. Obtenção de pontos no espaço 3-D.

O experimento 22 objetivou calibrar o sistema em um espaço 3-D com imagens reais, provando que a rede generalizou tanto em testes de simulação

como imagens reais, Figura 5.3 com quatro *grids* paralelos superpostos dispostos na vertical. Outros trabalhos encontrados na literatura empregam aparatos semelhantes, como por exemplo, Viana em (Viana, 1999). Observa-se que tal experiência foi feita aplicando-se o conceito de *self-calibration* (autocalibração), na qual a calibração é feita com a movimentação da câmera ou do plano sem rigor na montagem do aparato.




Figura 5.3. Grids verticais deslocados paralelamente.

Neste caso, ressalta-se que se pôde demonstrar através do experimento que as redes neurais são capazes de obter os resultados corretos em um volume 3-D e não apenas em um plano.

No experimento 23 a rede neural sofreu uma mudança em sua topologia com o acréscimo de uma quarta saída (um quarto neurônio na última camada), o quarto neurônio é necessário para as três coordenadas globais e para uma coordenada de posição da câmera. Assim, a rede neural fornece também a posição da câmera no espaço 3-D (Wells, 1996).

O experimento 24 é um importante teste, confirmando a robustez e a facilidade de aplicação das redes neurais, utilizando duas imagens de duas câmeras diferentes (Qing, 1999), ou seja, com focos e distorções (parâmetros

intrínsecos), posições e orientações diferentes (parâmetros extrínsecos). As imagens utilizadas são exibidas na Figura 5.4.




Figura 5.4. Sistema estéreo com câmeras diferentes.

5.1.2. Aplicação do método para recuperação de informação 3-D.

O experimento 25 foi idealizado para demonstrar a aplicação do método para a implementação de um scanner 3-D, utilizando dados sintéticos, gerados pelo mesmo modelo matemático de câmera, utilizada nas experiências anteriores. Uma superfície sintética é gerada a partir da função $\frac{\sin(x)}{10}$ em 15 pontos diferentes gerando uma superfície no espaço 3-D como mostra a Figura 5.5. O treinamento da rede neural para a calibração foi realizado com 10 *grids* de 90 pontos (15x6) para cada *grid*.




Figura 5.5. Duas vistas da superfície recuperada com 10 *grids* horizontais.

O experimento 26 é semelhante ao experimento anterior, porém utiliza 5 *grids* de treinamento de 90 pontos, totalizando 450 pontos. O resultado do experimento é apresentado na Figura 5.6.




Figura 5.6. Duas vistas da superfície recuperada com 5 *grids* horizontais.

O experimento 27 também é semelhante aos anteriores, com a diferença de se utilizar 20 *grids* paralelos, destinados a nortear um número empírico de pontos e número de *grids* para o treinamento da rede neural. Ressalta-se que a superfície gerada, também utilizada nos experimentos 25 e 26, foi gerada utilizando-se apenas dez pontos, sendo exibida na Figura 5.7.




Figura 5.7. Duas vistas da superfície recuperada com 20 *grids* horizontais.

O experimento 28 demonstra a aplicação prática das R.N.A., para implementar um scanner 3-D. Neste experimento a rede neural foi treinada em uma região espacial definida, com quatro *grids* superpostos horizontais, com um total de 320 pontos em cada câmera. As imagens do *grid* de calibração são exibidas na Figura 5.8.




Figura 5.8. Grids paralelos deslocados horizontalmente.

Após o treinamento, a rede neural determina com base na imagem e através de pontos definidos no objeto (Figura 5.9), as coordenadas em 3-D da superfície do mesmo. Tal experiência demonstra o princípio de um scanner.




Figura 5.9 - Mouse captado pela câmera esquerda e direita respectivamente.



Figura 5.10. Superfície 3-D recuperada pela RNA.




Figura 5.11. Recuperação dos pontos medidos na superfície do mouse.

As Figuras 5.10 e 5.11, demonstram a diferença da superfície recuperada pela rede através dos pontos, e a superfície gerada somente com as medidas das coordenadas 3-D dos mesmos diretamente no objeto de teste.

O experimento 29 é semelhante ao 28, porém a rede neural é treinada em uma região espacial definida, com quatro *grids* superpostos horizontais e um total de 520 pontos em cada câmera. As imagens do *grid* de calibração são exibidas na Figura 5.12.




Figura 5.12. Grids Paralelos deslocados horizontalmente.

O experimento 29 empregou dois objetos em um mesmo ensaio. A Figura 5.14 exibe as imagens de um mouse, denominado mouse2 para diferenciar do mouse do experimento 28. O outro objeto, uma Rampa, é exibido na Figura 5.13.




Figura 5.13. Imagens da Rampa.




Figura 5.14. Imagens do Mouse 2

A Figura 5.15 exibe a digitalização dos dados da Rampa. Vale ressaltar que: na construção do aparato para disposição dos *grids*, uma imperfeição não permitiu digitalizar pontos com dimensões inferiores a 1 cm de altura (coordenada *Z*), deste modo alguns pontos não puderam ser recuperados pela rede. Porém, uma importante observação se fez presente no ensaio, para os pontos que estavam fora

do conjunto de treinamento (iguais ou menores que 1 cm), a rede encontrou resultados absurdos como valores da coordenada Z negativos, totalmente errôneos.




Figura 5.15. Recuperação dos pontos medidos na superfície da rampa.

Os resultados encontrados pela rede neural para a rampa são exibidos na Figura 5.16




Figura 5.16. Resultados R.N.A. da rampa.

Os resultados para o segundo objeto do experimento (mouse2) são exibidos nas Figuras 5.17 (digitalização) e 5.18 (recuperação R.N.A.).




Figura 5.17. Recuperação dos pontos medidos na superfície do mouse2.

Observa-se a aplicação de um algoritmo de recuperação de superfície com a média dos pontos encontrados em uma linha pela rede. O treinamento da rede para este experimento foi limitado a 3000 épocas, resultando em um erro final da rede inferior a 10^{-4} .




Figura 5.18. Recuperação 3-D mouse2 pela R.N.A.

5.2. Análise dos Resultados:

Os resultados obtidos usando 1 ou 2 camadas ocultas foram similares, mostrando que a rede, com pelo menos uma camada oculta, pode resolver sistemas não lineares, e portanto podem ser empregados para a solução de problemas de calibração de câmera, apesar de não podermos afirmar que o

algoritmo de retropropagação forneça uma solução ótima para todos os problemas resolúveis (Haykin, 2000).

A necessidade do uso de mais uma camada oculta deve-se ao problema da descontinuidade em seu domínio (Immamura, 2000). Nesse trabalho, a rede generalizou com uma e duas camadas, concluindo a existência de uma função de calibração contínua em seu domínio, devido às regiões de treinamento da rede serem superfícies ou regiões volumétricas definidas e contínuas no espaço 3-D.

Os resultados de simulações com dados sintéticos, acrescidos de um erro gaussiano nas entradas da rede, como no trabalho de Zhengyou em (Zhengyou, 1998), da ordem de 5%, simulando erros de aquisição, demonstraram a eficiência de generalização da rede neural em situações com erros de aquisição, problema certamente existentes na aquisição de coordenadas das projeções dos pontos, nos experimentos com imagens reais, bem como originados da própria geometria de uma câmera real devido às imprecisões das lentes. Esses dados são apresentados na tabela 5.1a.

Os experimentos realizados com erro 10^{-6} apresentaram bons resultados, porém os experimentos direcionados para erro de treinamento 10^{-7} apresentaram resultados ainda melhores, mas com um tempo de processamento muito alto para experiências com dados reais. Isto se deve ao fato de que dados reais apresentam imprecisões e erros, dificultando o aprendizado das redes neurais, e por isso, torna inviável o uso de erro de treinamento igual ou maior que 10^{-7} . Assim, na maior partes dos casos, para experimentos com imagens reais, foram utilizadas erros de treinamento de até 10^{-6} em razão dos recursos computacionais utilizados no desenvolvimento, apesar da pequena deterioração dos resultados. Entretanto, em experimentos utilizando dados sintéticos, o treinamento da rede com erro de 10^{-7} , demonstrou ser ideal, por apresentar diferenças mínimas de resultados, quando comparado aos experimentos feitos, com erro de treinamento de 10^{-8} . É interessante notar que a utilização de dados sintéticos pode ser útil para um pré-treinamento da rede neural se conhecermos, aproximadamente, a geometria e características da câmera, simplificando o processo de treinamento com dados reais.



A seguir são apresentadas algumas considerações relevantes quanto ao uso das redes neurais para calibração de câmeras e recuperação de informação 3-D.

- A rede neural depois de treinada, é capaz de reconhecer parâmetros intrínsecos, como o foco e parâmetros extrínsecos, como posição, sendo assim uma solução inteligente.
- Os testes realizados com imagens reais geradas pelas câmeras Webcam Creative e Dexta, por exemplo, (Figura 5.5), apresentam maior distorção radial do que a câmera digital Sony (Figura 5.2). Consistentemente, os resultados obtidos com a câmera Sony foram mais precisos que aqueles com as outras câmeras.
- As R.N.A. generalizaram em nos experimentos com dados sintéticos, com melhor precisão que o M.M.Q. do método Hall. Porém, nos experimentos com imagens reais, os dois métodos são equivalentes (tabela 5.2). Entretanto, no trabalho de Moumem em (Moumem, 2002) a rede neural obteve resultados mais precisos comparada a um método de solução analítica, encontrada na literatura, como o de Wilson (apud Moumem, 2002), referência em calibração de câmeras com lentes ativas.
- A generalização das R.N.A. é influenciada por três fatores: (1) o tamanho do conjunto de treinamento, e o quão representativo do ambiente de interesse ele é, (2) a arquitetura da rede neural e (3) a complexidade física do problema em questão. Evidentemente, não temos controle sobre o último fator (Haykin, 2000). Entretanto, os resultados demonstraram que a escolha da rede perceptron multicamadas e o tipo de treinamento através de um *grid* de pontos com dimensões conhecidas vislumbrando o emprego de redes neurais como um método para a calibração de câmeras, no contexto de recuperação de imagens 3-D.



CAPÍTULO 6

CONCLUSÕES

Neste trabalho, foi apresentada a aplicação das redes neurais como um método para calibração de câmeras, comparado com a solução mais usual, a qual emprega solução analítica e um modelo de câmera explícito. Através de diversos experimentos com dados reais e sintéticos foi possível demonstrar a viabilidade e as vantagens do emprego das Redes Neurais Artificiais para a calibração de câmeras. Também foi demonstrado o emprego da técnica para a recuperação de informações tridimensionais de objetos, como passo inicial da construção de um scanner 3-D.

A característica mais significativa das redes neurais está em sua capacidade de aproximar funções contínuas não lineares, demonstrada neste trabalho pela aquisição de imagens reais com distorções. Esta capacidade típica das redes neurais permite determinar o relacionamento entre as variáveis de um processo não-linear, usualmente difícil de ser obtido por técnicas convencionais. Esta capacidade torna as redes neurais adequadas para a calibração de câmeras. A maioria das técnicas de calibração de câmeras parte da suposição de um modelo de câmera conhecido cujos parâmetros devem ser determinados. Porém, em muitos casos o modelo de câmera pode não ser adequadamente definido



viabilizando o uso de redes neurais para calibração de câmeras. Em alguns casos, a aplicação de redes neurais torna-se ainda mais vantajosa, como por exemplos nas câmeras com foco variável e lentes do tipo zoom, para as quais a definição de um modelo matemático torna-se praticamente impossível.

Algumas conclusões e vantagens da utilização de redes neurais, já apresentadas anteriormente, são sumarizadas a seguir:

- Parâmetros iniciais de calibração são desnecessários para aplicação de Rede Neural.
- O método pode ser aplicado com qualquer aparato (*setup*) que permita a aquisição de pontos 3-D.
- Não são necessários cálculos matemáticos para solução do problema de calibração de câmeras.
- A rede neural depois de treinada é um sistema inteligente capaz de reconhecer parâmetros intrínsecos, como o foco utilizado nas câmeras.
- A validação do método foi obtida através da generalização tanto com dados reais como com dados sintéticos.
- A precisão apresentada pelo método foi melhor que aquela apresentada pelo M.M.Q. quando usando dados sintéticos, porém, em simulações com imagens reais, os dois métodos são equivalentes.
- De acordo com os resultados apresentados, a proposta deste trabalho foi validada sendo possível a sua utilização como ferramenta para calibração em estéreo visão.
- A R.N.A demonstrou, robustez em experimentos com parâmetros intrínsecos e extrínsecos diferentes (focos e distorções), gerados por câmeras diferentes
- A R.N.A. permite localizar a posição da câmera no espaço, útil em inúmeras aplicações, com robótica móvel.
- A aplicação da R.N.A em estéreo visão pode ser estendida a construção de um scanner 3-D.



Embora o tempo de treinamento da rede seja bastante grande, tornando a sua aplicação inicial difícil, a técnica pode ser empregada por qualquer pessoa, mesmo sem grandes conhecimentos técnicos, bastando que seja descrito o procedimento de aquisição dos dados. Entretanto, duas considerações são importantes: esse procedimento pode ser melhorado e automatizado através do emprego de algoritmos de reconhecimento de pontos, e depois de treinada, a rede neural realiza os testes em tempo real.

Considerando que a disponibilidade de câmeras de vídeo torna-se cada vez maior, o emprego de Redes Neurais Artificiais, pela facilidade de emprego, permite vislumbrar uma ampla gama de possibilidades de aplicações de visão computacional para o usuário final não técnico. Exemplos de possíveis aplicações são: biometria, sistemas de segurança, aquisição de modelos tridimensionais de partes do corpo com a finalidade de confecção de roupas sob encomenda, etc. Por outro lado, a robustez e adaptabilidade da técnica a tornam extremamente atrativa para uma potencial aplicação na automação de sistemas industriais, sistemas de controle de qualidade por inspeção visual, e em especial em sistemas robóticos autônomos.

6.1. Trabalhos Futuros

A partir da demonstração da viabilidade de emprego de redes neurais e do método dos mínimos quadrados para a calibração de câmeras no contexto de recuperação de informação 3-D, pode-se vislumbrar uma série de aplicações para esta técnica:

- Aplicar R.N.A. para calibração de um sistema de veículo autônomo. Nesse tipo de problema há a necessidade de se efetuar o processo de calibração de câmeras constantemente, em função do deslocamento. Por não ser necessário uma configuração rígida para a calibração, o emprego do método apresentado é altamente propício.



- Explorar a capacidade de inteligência da rede, por exemplo, a capacidade de reconhecimento de foco das câmeras, vislumbrando aplicação em sistemas de visão computacional com lentes ativas.
- Aplicar R.N.A para aquisição e recuperação de dados 3-D (scanner 3-D).
- Aplicar R.N.A. para recuperação de medidas de objetos 3-D para sistemas de automação industrial, por exemplo, sistemas de controle de qualidade através de inspeção visual.



BIBLIOGRAFIA

- (Aguilar, 1996) - J. J. Aguilar, F. Torres e M.A Lope. , **Stereo Vision for 3-D measurement: accuaracy analisys, calibration and industrial applications**. Centro politecnico Superior de Ingenieros, Universidad de Zaragoza, Maria de Luna, 3 E-50015 Zaragoza, Spain.1996 Esevier Sciense. Vol 18. n. 4, pp. 193-200.
- (Andreff, 2000) Andreff Nicolas, Radu Horaud, Bernerd Espiau. **On-Line Hand-Eye Calibration**. INTRIA Rhone-Alpes/ GRAVIR-IMAG. Saint Martin, France. 2000.
- (Batlle, 1998) Batlle, J., E. Moudadib and J.Salvat. **Recent Progress in Coded Strutured Light as a Technique to solve the correspondence problem: A Survey**. Pattern Recognition, vol. 31, no.7, pp. 963-982, 1998.
- (Bellon, 1990) – Bellon, Olga R. Pereira. Visão Computacional. **Um sistema para localização de objetos poliédricos no espaço 3-D**. Dissertação de mestrado. Universidade Estadual de Campinas. Dezembro 1990.
- (Braga, 2001) Braga Antônio de Pádua, Tereza Bernarda Ludemir, André Carlos Ponce de Leon Ferreira Carvalho. **REDES NEURAIIS ARTIFICIAIS Teoria e Aplicações**.LTC Livros Técnicos e Científicos. 2001.
- (Bouguet, 1998) Bouguet, Jean-Yves and Pietro Perona. **3D photography on your desk**. ICCV'98, Bombay, India.
- (Chen, 1999) - Chen, Willian and Bernard Jiang C., **3-D Câmera Calibration Using Vanish Point Concept**, , Whashington University, St Louis, U.S.A.
- (Dorf, 1998) – Dorf, Richard C. e Robert H. Bishop. **Sistemas de Controle Modernos**. LTC Livros Técnicos e Científicos. 1998.



- (Echico, 1990) Echigo Tomio. **A Camera Calibration Technique using Three Sets of Parallel Lines.** Machine Vision and Applications. (1990) 3:159-167.
- (Ganapathy, 1984) – Ganapathy, Sundaram. **Decomposition of matrizes for robot vision.** Pattern Recognition Letters 2 (1984) 401-412.
- (Gonzaga, 1996) – Gonzaga, Adilson e Valentin Orac Boda. **Reconhecimento de Objetos Sólidos Poliédricos Utilizando Feixe de Laser.** TR-LAVI-002/96.
- (Gonzalez, 2000) - Gonzalez, Rafael C., Richard E Woods. **Processamento Digital de Imagens.** Edgard Blücher Ltda, São Paulo, 2000.
- (Groover, 2000) Groover, P. Mikell. **Automation, Production Systems, and Computer-Integrated Manufacturing.** Second Edition, Prentice Hall, Inc. Upper Saddle River, New Jersey U.S.A. 2000.
- (Grossberg, 1976a) Grossberg S. **Adaptative pattern classification and universal recording: I. Parallel development and coding of neural detectors.** Biological Cybernetics, vol.23, pp 121-134, 1976.
- (Grossberg, 1976b) Grossberg S. **Adaptative pattern classification and universal recording: II. Feedback, expectation, olfaction, illusions.** Biological Cybernetics, vol.23, pp 187-202, 1976.
- (Guisser, 2000) Guisser L., R. Payrissat , S. Castan. **An accurate 3-D vision system using a projected *grid* for surface descriptions.** Image and Vision computing 18 (2000) 463-491.
- (Hagan, 1994) – M. T. Hagan, M. B. Menhaj. **Training feedforward networks with the Marquadt algoritm.** IEEE Transactions on Neural Networks, vol. 5, no.6, pp 989-993, 1994.
- (Haykin, 2000) – Haykin, Simon. **Redes Neurais, Princípios e prática.** Bookman C. Editora. 2 edição. São Paulo, 2000.



- (Heikkila, 2000) Heikkilä Janne. **Geometric Camera Calibration Using Circular Control Points**. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 22 N°10 October 2000.
- (Hopfield, 1982) Hopfield, J.J. **Neural network and phisycal systems with emergent colletive computational abilities**. National Academy of Sciences of the U.S.A., vol.79.pp 2254-2558,1982.
- (Imamura, 2000) Imamura Marcos M. **Uma abordagem neural para analise dos gases dissolvidos em óleo isolante em função das grandezas físico-químicas**. Dissertação de Mestrado. UNESP, Bauru, SP, Brasil. 2000.
- (Kim, 1998) – Kim, C. **3-D Structured Light Based Depth Extraction**. Laboratory Research Areas: 3-D Scanner.1998
- (Kozankiewicz, 2002) Kozankiewicz Przemyslaw. **Fast Algorithm For Creating Image Base D Stereo Images**. WSCG 2002, pg. 59-61.
- (Lay, 1999)- Lay, David C. **Álgebra Linear e suas aplicações**, 2º edição, 1999, Livros Técnicos e Científicos Editora.
- (Lin, 1991) Lin, W. C., F.Y. Liao, C. K. Tsao, T. Lingutla. A hierarchical multiple view approach to three-dimensional object recognition. IEEE Trans. On Neural Networks, vol.2, p. 84-92, 1991.
- (Loesch, 1996) Loesch Cláudio e Solange T. Sari. **Redes Neurais Artificiais Fundamentos e Modelos**. Editora Furb. Blumenau 1996.
- (Lynch, 1999) Lynch Mark B., Cihan H. Dagli, Mahesh Vallenki. **The use of fedforward neural networks for machine vision calibration**. Int. Journal Production Economics 60-61 (1999) 479-489.
- (McCulloch, 1943) W. S. McCulloch, W. Pitts. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol. 5, pp 115-133, 1943.
- (Minsky, 1969) M.L. Minsky e S. A Papert. **Perceptrons: Na Introduction to Computacional Geometry**. The MIT Press, Cambridge, Massachusetts, 1969.



- (Moumem, 1999) Moumem T. Ahmed, Elsayed E. Hemayed and Aly A. Farag. **Neurocalibration: A Neural Network That Can Tel Camera Calibration Parameters.** CVIP Lab. University of Lousville.U.S.A.1999.
- (Moumem, 2002) Moumem T. Ahmed, Aly A. Farag. **A Neural Approach to Zoom-lens Camera Calibration from Data With Outliers.** CVIP Lab. University of Lousville.U.S.A. 2002.
- (Nayar, 2000) Nayar Shree K., Rahul Swaminathan. **Nommetric Calibration of Wide Angle Lenses and Polycameras.** IEEE Transactions on Pattern Analyses and Machine Intelligence, vol 22, N. 10, pg 1772-1778. October 2000.
- (Qing, 1999) - Qing ,Guo Wei and G Hirzinger. **Multisensory Visual Servoing by a Neural Network,** IEEE.Transactions on Systems. Man and Cybernetics-Part B Vol 29 n.2, april 1999.
- (Rosenblat, 1959) F. Roseblatt. Principles of Neurodinamics and the Theory of Brain Mechanisms. Spartan Books , Whashington, DC, 1959.
- (Rumelhart, 1986) D.E. (Rumelhart, 1986) D.E.Rumelhart, G. E. Hinton, R. J. Wiliams. **Learning internal representations by error propagation.** In: Parallel Distributed Processing, vol. 1, chap. 8, MIT Press: Cambridge, Massachusetts, 1986.
- (Salvi, 2002) Salvi, Joaquim, Xavier Almangué e Joan Batlle. **A comparative review of camera calibrating methods with accuracy evalution.** Computer Vision and Robotics Group. Institute of Informatics and Applications. University of Girona. Pattern Recognition vol. 35, pg 1617-1635, 2002.
- (Silvestre, 2002) Silvestre, Miriam R.,Sérgio Minoru Oikawa e Lee Luan Ling. **Eficiência de métodos de Pruning para classificação em MLP.** 47ª Reunião Anual da Região Brasileira da Sociedade Internacional de Biometria. Rio Claro, Brasil, pg. 83, 2002.



- (Smagt, 1991) Smagt P.P. van der, B. J.A. Krose. **A real-time learning neural robot controller. Proc. Of the 1991 International Conference on Artificial Neural Networks**, Espoo, Finland, pp. 351-356, 1991.
- (Su, 1995) Su Chao-Ton, C. Alec Cahng, Fana-Chih Tien. **Neural Networks for precise measurement in computer vision systems**. Computers and Industry vol.27, pg. 225-236.1995.
- (Tien, 1999) Tien, F.-C.; Chang, C.A. **Using neural networks for 3-D measurement in stereo vision inspection system**. Chaoyang Univ. of Technology, Taichung County, Taiwan. International Journal of Production Research, 1999, vol.37, issue 9, p1935-1948.
- (Tsai, 1986) Tsai Roger Y. **An Efficient and Accurate Camera Calibration Technique for 3D Machine Vision**. IEEE Computer Vision and Pattern Recognition Conference. Miami Beach, Florida. pp. 364-374, 1986.
- (Tommaselli, 1998) Tommaselli Antonio Maria Garcia. **Accuracy assessment of a photogrammetric close-range reconstruction system**. IEEE Transactions on Pattern Analyses and Machine Intelligence, pg 46-53. October 1998.
- (Trucco, 1998) – Trucco, E., R. B. Fischer , A. W. Fitzgibbon and D. K. Naidu . **Calibration, data consistency and model acquisition with laser stripers**. Computer Intregated Manufaturing, 1998, vol.11, no. 4, 293-310.
- (Viana, 1999) Viana S. Antonio A., Jacques Waldmann e Fábio de Freitas Caetano. **Non-Linear Optimization Batch Calibration with Accuracy Evaluation**. SBA Controle e Automação vol.10 no. 02, pg. 89-99,1999.
- (Wang, 1990) - Wang, Ling-Ling, Wen-Hsiang Tsai. **Computing Camera Parameters using Vanishning-Line Information from a Rectangular Parallepiped**. Machine Vision and Applications, 1990, no. 3, pág.. 129-141.



- (Wang, 1997) Wang, C, C. Sun, R. Liao. Monitoring transformer chromatography with BPNN fault diagnosis method. Proceedings of the Chinese Society of Electrical Engineering, Vol.17, n.05, pp.322-325,1997.
- (Wells, 1996) Wells Gordon , Christophe Venaille, Carme Torras. **Promising research, Vision-based robot positioning using neural networks.** Image and Vision Computing 14(1996) 715-732.
- (Weng, 1992) – Weng Juyang Member, IEEE, Paul Cohen, and Marc Herniou . **Camera Calibration with Distortion Models and Accuracy Evaluation.** IEEE transactions on pattern analysis and machine intelligence, Vol. 14, N 10, October 1992.
- (Widrow, 1960) Widrow, B., M. E. Hoff. **Adaptive switching circuits.** Proceedings of IRE WESCON Convention Record, pp. 96-104, 1960.
- (Widrow, 1988) Widrow, B., R. G. Winter, R.A. Baxter. **Layered neural nets for pattern recognition.** IEEE Trans. On Acoustics, Speech, and Signal Processing, vol. 36, pp. 1109-1117, 1988.
- (Yuncai, 1990) Yuncai Liu , Thomas S. Huang and Olivier D Faugeras, **Determination of Camera Location from 2-D to 3-D Line and Point Correspondence .**IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol 12 N°1 January 1990.
- (Zhengyou, 1998) Zhengyou Zhang. **A Flexible New Technique for Camera Calibration.** Technical Report MSR-TR-98-71 Microsoft Research. One Microsoft Way Redmond, WA 98052. December 2, 1998.



ANEXO I

SIMULAÇÃO PARA AQUISIÇÃO 3-D.

O objetivo deste anexo é de demonstrar, através de simulação, a aplicação do modelo apresentado na Seção 2.1, para recuperação de informação 3-D, com um sistema de imageamento estéreo. Este modelo apresenta restrições para a aplicação prática, como por exemplo, a necessidade de um perfeito alinhamento entre as duas câmeras e a superposição dos eixos de coordenadas das câmeras. Outra considerável dificuldade para a aplicação do método apresentado é a necessidade de se conhecer parâmetros intrínsecos (foco e centro da lente) e parâmetros extrínsecos (posição das câmeras). Entretanto, a simulação desse método para a recuperação de informação 3-D, demonstra uma das maiores vantagens da aplicação de redes neurais. Pelo fato das redes neurais não necessitarem nenhum conhecimento prévio do aparato e das câmeras utilizadas, é possível, somente com as coordenadas dos pontos do espaço e com as coordenadas das projeções das duas câmeras, calibrar um sistema estéreo de aquisição de imagens.

A geração dos pontos sintéticos (x_i, y_i) , aplicando somente a matriz perspectiva P (Equação 4.2), do modelo de câmera, considerando-se as restrições impostas pelo método.

Assim:

$$Ch_i = P \times Wh \quad (AI.1)$$

Onde:



$$P = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & \frac{-1}{0.035} & 1 \end{bmatrix} \quad (\text{AI.2})$$

A geração dos pontos sintéticos (x_2, y_2) , aplicando a matriz perspectiva P e a matriz de deslocamento C .

Assim:

$$Ch_2 = P \times C \times W_h \quad (\text{AI.3})$$

Onde:

$$C = \begin{bmatrix} 1 & 0 & 0 & -0.1 \\ 0 & 1 & 0 & -0 \\ 0 & 0 & 1 & -0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (\text{AI.4})$$

Como as equações (AI.1) e (AI.3) estão na forma homogênea, as coordenadas das projeções das câmeras no sistema cartesiano são obtidas pelas equações (4.9 a 4.12):

Deste modo com as coordenadas das projeções dos pontos geradas (dados sintéticos), podemos aplicar um exemplo para ilustrar o método apresentado, assim: Dado um ponto P_1 qualquer no espaço com coordenadas ($X_G=1.14$, $Y_G=1.08$ e $Z_G=0.2$). Podemos escrever o vetor W_h [1,14, 1,08, 0,2, 1], deste ponto, e conseqüentemente aplicando (AI.1) e (AI.2), obtemos os vetores Ch_1 e Ch_2 :



$$Ch_1=[1,08, 1,14, 0,2, -4,7143] \quad (A1.5)$$

$$Ch_2=[1,04, 1,14, 0,2, -4,7143] \quad (A1.6)$$

Assim:

$$X_1 = \frac{1,08}{-4,7143} \quad (A1.7)$$

$$Y_1 = \frac{1,14}{-4,7173} \quad (A1.8)$$

$$X_2 = \frac{1,04}{-4,7143} \quad (A1.9)$$

$$Y_2 = \frac{1,14}{-4,7143} \quad (A1.10)$$

Assim aplicando as equações (A1.5 a A1.8), teremos as coordenadas cartesianas:

$(x_1 = -0,2418, y_1 = -0,2291)$ e $(x_2 = -0,2206, y_2 = -0,2291)$.

Observamos que: as coordenadas y_1 e y_2 tem o mesmo valor indicando um alinhamento entre as câmeras. Então, com as coordenadas das projeções das câmeras, o foco ($\lambda=0,35$), utilizada na matriz P e a distância entre os eixos focais $(0,1)$ devido ao parâmetro ($R_f=0,1$) da matriz C , podemos recuperar as coordenadas 3-D, de acordo com a equação (2.24)

$$Z = 0.035 - \frac{0,035 \times -0,1}{0,2206 - 0,2418} \quad (A1.9)$$

$$Z=0,2001$$



Aplicando a equação (2.18), podemos calcular as coordenadas X e Y do ponto w .

$$X = \frac{-0,2418}{0,035} \times (0,035 - 0,2) \quad (\text{AI.10})$$

e

$$Y = \frac{-0,2291}{0,035} \times (0,035 - 0,2) \quad (\text{AI.11})$$

Donde obtém-se $X=1,1399$ e $Y= 1,08$

Outra dificuldade de aplicação deste método, para recuperação de informação 3-D, é a correspondência dos pontos em uma mesma cena. Porém esta dificuldade é referente à aplicação de qualquer método que utilize a aquisição de imagens em um sistema estéreo.



ANEXO II

RESULTADOS DOS EXPERIMENTOS

Neste anexo, tabelas dos principais experimentos são apresentadas, para ilustrar os resultados encontrados. Assim tais resultados são avaliados pela diferença entre os valores das coordenadas globais reais (*Xreal*, *Yreal* e *Zreal*) e as coordenadas encontradas pelos métodos aplicados, Redes Neurais Artificiais (*XRN*, *YRN* e *ZRN*) e o Método dos Mínimos Quadrados (*XMQ*, *YMQ* e *ZMQ*). Na primeira linha das tabelas, a topologia, o número de épocas, a precisão de treinamento, são apresentados, e também o número de padrões (pontos) de treinamento, para os experimentos que empregaram R.N.A., entretanto, para os experimentos que empregaram M.M.Q. são apresentados somente o número de pontos utilizados. Dois tipos de erros são calculados, o erro absoluto (diferença absoluta entre o valor de cada uma das coordenadas) e o erro relativo (em porcentagem, também em cada uma das coordenadas). Um erro médio absoluto e relativo é calculado em cada teste. Para finalizar a avaliação do experimento, o final de cada tabela apresenta um erro médio absoluto e relativo de todos os testes realizados no mesmo.



ANEXO II Tabelas experimentos

Tabela AII.0a. Experimento ZERO (6 pontos teste).

O Método dos Mínimos Quadrados em superfície plana.					
Xreal	0,85	X MMQ	0,8500	0,0000	0,00%
Yreal	0,85	Y MMQ	0,8499	-0,0001	-0,01%
Zreal	0,20	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,85	X MMQ	0,8500	0,0000	0,00%
Yreal	0,88	Y MMQ	0,8800	0,0000	0,00%
Zreal	0,20	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,90	X MMQ	0,9000	0,0000	0,00%
Yreal	0,88	Y MMQ	0,8800	0,0000	0,00%
Zreal	0,20	Z MMQ	0,2001	0,0001	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,90	X MMQ	0,90	0,0000	0,00%
Yreal	0,90	Y MMQ	0,90	0,0000	0,00%
Zreal	0,20	Z MMQ	0,20	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Xreal	0,88	X MMQ	0,88	0,0000	0,00%
Yreal	0,88	Y MMQ	0,88	0,0000	0,00%
Zreal	0,20	Z MMQ	0,20	0,0000	0,00%
Erro médio abs e relativo coord			0,0001	0,00%	
Xreal	1,0000	X MMQ	0,9999	-0,0001	0,00%
Yreal	0,8000	Y MMQ	0,8799	0,0001	-0,01%
Zreal	0,2000	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Erro médio abs e relativo coord			0,0000	0,0%	
Erro médio da amostra			0,0000	0,0%	

Tabela AII.0b. Experimento ZERO (9 pontos teste).

O Método dos Mínimos Quadrados em superfície plana.					
Xreal	0,85	X MMQ	0,8500	0,0000	0,00%
Yreal	0,85	Y MMQ	0,8499	-0,0001	-0,01%
Zreal	0,20	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,85	X MMQ	0,8500	0,0000	0,00%
Yreal	0,88	Y MMQ	0,8800	0,0000	0,00%
Zreal	0,20	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,90	X MMQ	0,9000	0,0000	0,00%
Yreal	0,88	Y MMQ	0,8800	0,0000	0,00%
Zreal	0,20	Z MMQ	0,2001	0,0001	0,00%
Erro médio abs e relativo coord.			0,0000	0,00%	
Xreal	0,90	X MMQ	0,90	0,0000	0,00%
Yreal	0,90	Y MMQ	0,90	0,0000	0,00%
Zreal	0,20	Z MMQ	0,20	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Xreal	0,88	X MMQ	0,88	0,0000	0,00%
Yreal	0,88	Y MMQ	0,88	0,0000	0,00%
Zreal	0,20	Z MMQ	0,20	0,0000	0,00%
Erro médio abs e relativo coord			0,0001	0,00%	
Xreal	1,0000	X MMQ	0,9999	-0,0001	0,00%
Yreal	0,8000	Y MMQ	0,8799	0,0001	-0,01%
Zreal	0,2000	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Xreal	0,8/500	X MMQ	0,8500	0,0000	0,00%
Yreal	0,85000	Y MMQ	0,8499	-0,0001	-0,01%
Zreal	0,2000	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Xreal	1,0000	X MMQ	0,9999	-0,0001	-0,01%
Yreal	0,8800	Y MMQ	0,8799	0,0001	-0,01%
Zreal	0,2000	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	-0,01%	
Xreal	0,8700	X MMQ	0,8700	0,0000	0,00%
Yreal	0,8700	Y MMQ	0,8700	0,0000	0,00%
Zreal	0,2000	Z MMQ	0,2000	0,0000	0,00%
Erro médio abs e relativo coord			0,0000	0,00%	
Erro médio abs e relativo coord			0,0000	0,00%	
Erro médio da amostra			0,0000	0,00%	



Tabela AII.1. Experimento 1.

Com grid, focos diferentes, erro 10-7, 7 épocas. 300 pontos					
Xreal	1,00	X RN	1,0002	-0,0002	-0,02%
Yreal	1,05	Y RN	1,0502	-0,0002	-0,02%
Zreal	0,20	Z RN	0,2	0	0,00%
Erro médio abs e relativo coord.				-0,013%	-0,013%
Xreal	1,189	X RN	1,188	0,001	0,10%
Yreal	1,230	Y RN	1,2302	-0,0002	-0,02%
Zreal	0,200	Z RN	0,1997	0,0003	0,03%
Erro médio abs e relativo coord.				0,00037	0,00%
Xreal	0,88	X RN	0,8758	0,0042	0,42%
Yreal	0,88	Y RN	0,8838	-0,0038	-0,38%
Zreal	0,20	Z RN	0,1998	0,0002	0,020%
Erro médio abs e relativo coord.				0,0002	0,00%
Xreal	1,05	X RN	1,0502	-0,0002	-0,02%
Yreal	0,95	Y RN	0,9504	-0,0004	-0,04%
Zreal	0,20	Z RN	0,1999	0,0001	0,01%
Erro médio abs e relativo coord.				0,0001	0,00%
Xreal	1,06	X RN	1,0604	-0,0004	-0,040%
Yreal	0,95	Y RN	0,9504	-0,0004	-0,040%
Zreal	0,20	Z RN	0,1999	0,0001	0,010%
Erro médio abs e relativo coord.				0,0002	0,00%
Xreal	1,05	X RN	1,0502	-0,0002	-0,020%
Yreal	1,00	Y RN	1,0004	-0,0004	-0,040%
Zreal	0,20	Z RN	0,1999	0,0001	0,010%
Erro médio abs e relativo coord				-0,000166667	0,00%
Erro médio da amostra				6,66667E-05	0,0%

Tabela AII.2 Experimento-2.

R.N. dois focos altura diferentes. 300 pontos 10-7 9 épocas					
Xreal	1,00	XRN	0,9998	0,0002	0,02%
Yreal	1,05	YRN	1,0502	-0,0002	-0,02%
Zreal	0,20	ZRN	0,1998	0,0002	0,02%
Erro médio abs e relativo				6,67E-05	0,0%
Xreal	1,00	XRN	0,9999	1E-04	0,01%
Yreal	1,00	YRN	1,0002	-0,0002	-0,02%
Zreal	0,20	ZRN	0,1999	0,0001	0,01%
Erro médio abs e relativo				9,25E-18	0,0%
Xreal	0,90	XRN	0,8988	0,0020	0,12%
Yreal	0,90	YRN	0,9006	-0,0006	-0,06%
Zreal	0,20	ZRN	0,1998	0,0002	0,02%
Erro médio abs e relativo				0,0003	0,00%
Xreal	0,98	XRN	0,9798	0,0002	0,02%
Yreal	1,08	YRN	1,0800	0,0000	0,00%
Zreal	0,20	ZRN	0,1998	0,0002	0,02%
Erro médio abs e relativo				0,0001	0,00%
Xreal	0,955	XRN	0,9547	0,0003	0,03%
Yreal	0,955	YRN	0,9551	-1E-04	-0,01%
Zreal	0,200	ZRN	0,1999	0,0001	0,01%
Erro médio abs e relativo				1,00E-04	0,00%
Xreal	0,95	XRN	0,9548	-0,0048	-0,48%
Yreal	1,10	YRN	1,1	0	0,00%
Zreal	0,20	ZRN	0,1998	0,0002	0,02%
Erro médio abs e relativo				-0,0015	-0,20%
Xreal	1,00	XRN	0,9999	1E-04	0,01%
Yreal	1,10	YRN	1,1001	-1E-04	-0,01%
Zreal	0,20	ZRN	0,1999	0,0001	0,01%
Erro médio abs e relativo				3,33E-05	0,0%
Xreal	0,90	XRN	0,8988	0,0012	0,12%
Yreal	0,90	YRN	0,9006	-0,0006	-0,06%
Zreal	0,20	ZRN	0,1998	0,0002	0,02%
Erro médio abs e relativo				0,0008	0,0%
Erro médio abs e relativo da amostra				-1,7E-05	0,0%



Tabela AII.3 Experimento 3.

R.N.A. com 250 padrões, erro aquisição 5%, 252 épocas. 10-6					
Xreal	1,025	XRN	1,0247	0,0003	0,03%
Yreal	0,955	YRN	0,9575	-0,0025	-0,25%
Zreal	0,200	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,00073	-0,1%
Xreal	1,025	XRN	1,0268	-0,0018	-0,18%
Yreal	1,052	YRN	1,0552	-0,0032	-0,32%
Zreal	0,200	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,00167	-0,20%
Xreal	0,8880	XRN	0,8897	-0,0017	-0,17%
Yreal	0,8880	YRN	0,8867	0,0013	0,13%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,00013	0,00%
Xreal	0,980	XRN	0,9755	0,0045	0,45%
Yreal	1,022	YRN	1,0166	0,0054	0,54%
Zreal	0,200	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				0,0033	0,3%
Xreal	0,98	XRN	0,9787	0,0013	0,13%
Yreal	0,78	YRN	0,7828	-0,0028	-0,28%
Zreal	0,20	ZRN	0,2000	0	0,00%
Erro médio abs e relativo				-0,0005	-0,1%
Xreal	1,00	XRN	1,0015	-0,0015	-0,15%
Yreal	0,95	YRN	0,9095	0,0405	4,05%
Zreal	0,20	ZRN	0,2	0,0000	0,00%
Erro médio abs e relativo				0,0130	1,3%
Xreal	1,00	XRN	1,0008	-0,0008	-0,08%
Yreal	0,9	YRN	0,9041	-0,0041	-0,41%
Zreal	0,2	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,00163	-0,2%
Xreal	1,00	XRN	0,9970	0,0030	0,30%
Yreal	1,00	YRN	0,9976	0,0024	0,24%
Zreal	0,20	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				0,0054	0,2%
Erro médio abs e relativo da amostra				0,0021	0,2%



Tabela AII.4 Experimento-4.

Rede Neural treinada com 250 padrões, erro aquisição 5 %;					
Erro da rede 10-7, 989 épocas.					
Xreal	1,13	XRN	1,1281	0,0019	0,17%
Yreal	1,08	YRN	1,0728	0,0072	0,67%
Zreal	0,2	ZRN	0,2	0,0000	0,00%
Erro médio abs e relativo				0,003033	0,3%
Xreal	1,0000	XRN	0,9983	-0,0018	-0,18%
Yreal	1,0000	YRN	1,0050	-0,0032	-0,30%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,00167	-0,2%
Xreal	0,8880	XRN	0,8821	0,0059	0,66%
Yreal	0,8880	YRN	0,879	0,009	1,01%
Zreal	0,2000	ZRN	0,2	0	0,00%
Erro médio abs e relativo				0,004967	0,6%
Xreal	1,0250	XRN	1,0176	0,0074	0,72%
Yreal	0,8850	YRN	0,8846	0,0004	0,05%
Zreal	0,2000	ZRN	0,2	0	0,00%
Erro médio abs e relativo				0,0026	0,3%
Xreal	1,0500	XRN	1,0481	0,0019	0,18%
Yreal	0,9500	YRN	0,9502	-0,0002	-0,02%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				0,000567	0,1%
Xreal	0,9555	XRN	0,9561	-0,0006	-0,06%
Yreal	1,0222	YRN	1,027	-0,0048	-0,47%
Zreal	0,2000	ZRN	0,2	0,0000	0,00%
Erro médio abs e relativo				-0,0018	-0,2%
Xreal	0,7550	XRN	0,756	-0,0010	-0,13%
Yreal	0,7550	YRN	0,754	0,0010	0,13%
Zreal	0,2000	ZRN	0,2	0,0000	0,00%
Erro médio abs e relativo				0,0000	0,0%
Xreal	0,7550	XRN	0,7555	-0,0005	-0,07%
Yreal	0,6550	YRN	0,6549	0,0001	0,02%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				-0,0004	0,0%
Erro médio abs e relativo da amostra				0,000913	0,1%



Tabela AII.5 Experimento-5.

Método mínimo quadrado 150 padrões erro 5%					
Xreal	1,05	MQX	1,0534	-0,0034	-0,32%
Yreal	1,05	MQY	1,0556	-0,0056	-0,53%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,003	-0,3%
Xreal	0,8888	MQX	0,9053	-0,0165	-1,86%
Yreal	1,05	MQY	1,0594	-0,0094	-0,90%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,00863	-0,9%
Xreal	0,9555	MQX	0,9706	-0,0151	-1,58%
Yreal	0,8555	MQY	0,881	-0,0255	-2,98%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,01353	-1,5%
Xreal	0,95	MQX	0,9573	-0,0073	-0,77%
Yreal	1,2	MQY	1,1997	0,0003	0,02%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,00233	-0,3%
Xreal	1,05	MQX	1,0574	-0,0074	-0,70%
Yreal	0,78	MQY	0,8094	-0,0294	-3,77%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,01227	-1,5%
Xreal	1,05	MQX	1,052	-0,002	-0,19%
Yreal	1,15	MQY	1,1508	-0,0008	-0,07%
Zreal	0,2	MQZ	0,2	0	0,00%
Erro médio abs e relativo				-0,00093	-0,1%
Erro médio abs e relativo da amostra				-0,01	-0,8%

Tabela AII.6 Experimento-6.

R N 200 pontos erro 10-8 43 épocas calculo do foco					
Xreal	0,900	XRN	0,9002	-0,0002	-0,020%
Yreal	0,900	YRN	0,9003	-0,0003	-0,030%
Zreal	0,250	ZRN	0,2498	0,0002	0,020%
F1real	0,035	F1RN	0,0349	0,0001	0,010%
F2real	0,035	F2RN	0,035	0,0000	0,000%
Erro médio abs e relativo coord.				-1E-04	-0,010%
Xreal	1,000	XRN	1,0013	-0,0013	-0,130%
Yreal	1,000	YRN	1,0011	-0,0011	-0,110%
Zreal	0,290	ZRN	0,2892	0,0008	0,080%
F1real	0,035	F1RN	0,0351	-1E-04	-0,010%
F2real	0,035	F2RN	0,0350	0,0000	0,000%
Erro médio abs e relativo coord.				-0,0005	-0,1%
Xreal	0,950	XRN	0,95	0,0000	0,000%
Yreal	0,950	YRN	0,9499	1E-04	0,010%
Zreal	0,280	ZRN	0,2803	-0,0003	-0,030%
F1real	0,033	F1RN	0,033	0,0000	0,000%
F2real	0,035	F2RN	0,035	0,0000	0,000%
Erro médio abs e relativo coord.				-6,67E-05	0,000%
Xreal	1,000	XRN	0,9995	0,0005	0,050%
Yreal	1,000	YRN	0,9995	0,0005	0,050%
Zreal	0,210	ZRN	0,2105	-0,0005	-0,050%
F1real	0,033	F1RN	0,033	0,0000	0,000%
F2real	0,035	F2RN	0,035	0,0000	0,000%
Erro médio abs e relativo coord				0,0002	0,000%
Xreal	0,950	XRN	0,9501	-1E-04	-0,010%
Yreal	0,950	YRN	0,9501	-1E-04	-0,010%
Zreal	0,230	ZRN	0,2301	-1E-04	-0,010%
F1real	0,033	F1RN	0,033	0,0000	0,000%
F2real	0,035	F2RN	0,035	0,0000	0,000%
Erro médio abs e relativo coord				-1E-04	0,0%
Xreal	0,900	XRN	0,8998	0,0002	0,020%
Yreal	0,900	YRN	0,9001	-1E-04	-0,010%
Zreal	0,270	ZRN	0,2701	-1E-04	-0,010%
F1real	0,035	F1RN	0,0349	0,0001	0,010%
F2real	0,035	F2RN	0,035	0,0000	0,000%
Erro médio abs e relativo coord				0,0000	0,0%
Erro médio abs e relativo da amostra				-0,000106	0,0%



Tabela AII.7 Experimento-7.

R.N.A. Grid retangular 250 pontos erro 10-6. 7 épocas.					
Xreal	1,1400	X RN	1,1395	0,0005	0,050%
Yreal	1,0800	Y RN	1,0799	1E-04	0,010%
Zreal	0,2000	Z RN	0,2001	-1E-04	-0,010%
Erro médio abs e relativo coord.				0,0000	0,017%
Xreal	1,0250	X RN	1,0246	0,0000	0,040%
Yreal	1,0250	Y RN	1,0250	0,0000	0,000%
Zreal	0,2000	Z RN	0,2000	0,0000	0,000%
Erro médio abs e relativo coord.				0,0000	0,000%
Xreal	0,8800	X RN	0,8799	1E-04	0,010%
Yreal	0,8800	Y RN	0,8804	-0,0004	-0,040%
Zreal	0,2000	Z RN	0,1999	0,0001	0,010%
Err o médio abs e relativo coord.				-6,67E-05	0,000%
Xreal	1,0500	X RN	1,0498	0,0002	0,020%
Yreal	0,9500	Y RN	0,9503	-0,0003	-0,030%
Zreal	0,2000	Z RN	0,2000	0,0000	0,000%
Err o médio abs e relativo coord.				-3,33E-05	0,000%
Xreal	1,0800	X RN	1,0798	0,0002	0,020%
Yreal	0,9500	Y RN	0,9503	-0,0003	-0,030%
Zreal	0,2000	Z RN	0,2000	0,0000	0,000%
Err o médio abs e relativo coord.				-3,33E-05	0,000%
Xreal	0,8600	X RN	0,8599	1E-04	0,010%
Yreal	0,8800	Y RN	0,8804	-0,0004	-0,040%
Zreal	0,2000	Z RN	0,1999	0,0001	0,010%
Err o médio abs e relativo coord.				-6,67E-05	0,000%
Erro médio abs e relativo da amostra				-0,3333	0,00%

Tabela AII.8 Experimento-8.

Grid retangular 250 pontos erro 10-7, 9 épocas					
Xreal	0,7700	XRN	0,7695	0,0005	0,050%
Yreal	1,1600	YRN	1,1597	0,0003	0,030%
Zreal	0,2000	ZRN	0,2003	-0,0003	-0,030%
Erro médio abs e relativo coord.				0,017%	0,017%
Xreal	1,0250	XRN	1,0248	0,0002	0,020%
Yreal	1,0250	YRN	1,0249	1E-04	0,010%
Zreal	0,2000	ZRN	0,2000	0,0000	0,000%
Erro médio abs e relativo coord.				1E-04	0,00%
Xreal	0,8800	XRN	0,8799	1E-04	0,010%
Yreal	0,8800	YRN	0,8800	0,0000	0,000%
Zreal	0,2000	ZRN	0,2000	0,0000	0,000%
Erro médio abs e relativo coord.				3,33E-05	0,00%
Xreal	0,8400	XRN	0,8400	0,0000	0,000%
Yreal	0,7700	YRN	0,7700	0,0000	0,000%
Zreal	0,2000	ZRN	0,2000	0,0000	0,000%
Erro médio abs e relativo coord				0,0000	0,00%
Xreal	1,0200	XRN	1,0199	1E-04	0,010%
Yreal	0,9600	YRN	0,9600	0,0000	0,000%
Zreal	0,2000	ZRN	0,2000	0,0000	0,000%
Erro médio abs e relativo				3,33E-05	0,00%
Xreal	1,0600	XRN	1,0601	-1E-04	-0,010%
Yreal	0,7700	YRN	0,7700	0,0000	0,000%
Zreal	0,2000	ZRN	0,2000	0,0000	0,000%
Erro médio abs e relativo				-3,3E-05	0,00%
Xreal	1,1400	XRN	1,1398	0,0002	0,020%
Yreal	1,0800	YRN	1,0799	1E-04	0,010%
Zreal	0,2000	ZRN	0,2	0,0000	0,000%
Erro médio abs e relativo				1E-04	0,00%
Xreal	0,9200	XRN	0,9197	0,0003	0,030%
Yreal	1,0900	YRN	1,0898	0,0001	0,020%
Zreal	0,2000	ZRN	0,2001	0,0000	-0,010%
Erro médio abs e relativo				0,0004	0,00%
Erro médio abs e relativo da amostra				0,0001	0,00%



Tabela AII.9 Experimento-9.

Grid retangular 250 pontos com erro 10-8,12 épocas					
Xreal	1,0000	XRN	1,0000	0,0000	0,00%
Yreal	1,0000	YRN	0,9999	0,0001	0,01%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				3,33E-05	0,00%
Xreal	1,1400	XRN	1,1399	0,0001	0,01%
Yreal	1,0800	YRN	1,0799	0,0001	0,01%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				6,67E-05	0,00%
Xreal	1,0250	XRN	1,0250	0,0000	0,00%
Yreal	1,0250	YRN	1,0249	0,0001	0,01%
Zreal	0,2000	ZRN	0,2000	0,0	0,00%
Erro médio abs e relativo				3,33E-05	0,0%
Xreal	0,9652	XRN	0,9651	0,0001	0,01%
Yreal	1,1256	YRN	1,1255	0,0001	0,01%
Zreal	0,2000	ZRN	0,2000	0,0000	0,00%
Erro médio abs e relativo				6,67E-05	0,00%
Xreal	0,6676	X RN	0,6675	0,0001	0,02%
Yreal	0,8888	Y RN	0,8888	0,0000	0,00%
Zreal	0,2000	Z RN	0,2001	-0,0001	-0,05%
Erro médio abs e relativo				0,0000	0,00%
Xreal	1,0000	X RN	1,1682	0,0001	0,01%
Yreal	0,9999	Y RN	1,1681	0,0001	0,01%
Zreal	0,2000	Z RN	0,2001	-0,0001	-0,05%
Erro médio abs e relativo				3,33E-05	0,00%
Xreal	0,8600	X RN	0,8599	0,0001	0,01%
Yreal	1,1600	Y RN	1,1599	0,0001	0,01%
Zreal	0,2000	Z RN	0,2001	-0,0001	-0,05%
Erro médio abs e relativo				0,0000	0,00%
Xreal	0,7555	X RN	0,7555	0,0	0,00%
Yreal	0,7555	Y RN	0,7555	0,0	0,00%
Zreal	0,2000	Z RN	0,2000	0,0	0,00%
Erro médio abs e relativo				0,0	0,00%
Erro médio abs e relativo da amostra				-0,00025	0,00%



Tabela AII.10 Experimento-10.

Mínimos quadrados 100 pontos aleatórios					
Xreal	0,91	MQX	0,918	-0,008	-0,80%
Yreal	0,92	MQY	0,9267	-0,0067	-0,67%
Zreal	0,255	MQZ	0,2573	-0,0023	-0,23%
Erro médio abs e relativo				-0,005667	-0,6%
Xreal	0,9	MQX	0,8205	0,0795	0,0795
Yreal	0,85	MQY	0,7905	0,0595	0,0595
Zreal	0,21	MQZ	0,2161	-0,0061	-0,0061
Erro médio abs e relativo				0,0443	4,4%
Xreal	1	MQX	0,9394	0,0606	6,06%
Yreal	1	MQY	0,9763	0,0237	2,37%
Zreal	0,2	MQZ	0,239	-0,039	-3,90%
Erro médio abs e relativo				0,0151	1,5%
Xreal	0,8888	MQX	0,8683	0,0205	2,05%
Yreal	0,8888	MQY	0,8547	0,0341	3,41%
Zreal	0,2555	MQZ	0,2589	-0,0034	-0,34%
Erro médio abs e relativo				0,017067	1,7%
Xreal	0,9	MQX	0,8874	0,0126	1,26%
Yreal	0,9	MQY	0,8831	0,0169	1,69%
Zreal	0,25	MQZ	0,2534	-0,0034	-0,34%
Erro médio abs e relativo				0,0087	0,9%
Xreal	0,9555	MQX	0,9651	-0,0096	-0,96%
Yreal	0,8888	MQY	0,8924	-0,0036	-0,36%
Zreal	0,2666	MQZ	0,2815	-0,0149	-1,49%
Erro médio abs e relativo				-0,009367	-0,9%
Erro médio abs e relativo da amostra				0,01169	1,2%

Tabela AII.11 Experimento-11.

Mínimos quadrados com 200 pontos					
Xreal	0,91	MQX	0,9068	0,0032	0,32%
Yreal	0,92	MQY	0,9181	0,0019	0,19%
Zreal	0,255	MQZ	0,2557	-0,0007	-0,07%
Erro médio abs e relativo				0,00147	0,1%
Xreal	0,9	MQX	0,8961	0,0039	0,0039
Yreal	0,85	MQY	0,8482	0,0018	0,0018
Zreal	0,21	MQZ	0,2589	-0,0489	-0,0489
Erro médio abs e relativo				-0,0144	-1,4%
Xreal	1	MQX	1,0067	-0,0067	-0,67%
Yreal	1	MQY	1,0238	-0,0238	-2,38%
Zreal	0,21	MQZ	0,2099	1E-04	0,01%
Erro médio abs e relativo				-0,0101	-1,0%
Xreal	0,8888	MQX	0,8849	0,0039	0,39%
Yreal	0,8888	MQY	0,8829	0,0059	0,59%
Zreal	0,2555	MQZ	0,2553	0,0002	0,02%
Erro médio abs e relativo				0,00333	0,3%
Xreal	0,9	MQX	0,8949	0,0051	0,51%
Yreal	0,9	MQY	0,8953	0,0047	0,47%
Zreal	0,25	MQZ	0,2503	-0,0003	-0,03%
Erro médio abs e relativo				0,00317	0,3%
Xreal	0,9555	MQX	0,9531	0,0024	0,24%
Yreal	0,8888	MQY	0,8873	0,0015	0,15%
Zreal	0,2666	MQZ	0,2688	-0,0022	-0,22%
Erro médio abs e relativo				0,00057	0,1%
Erro médio abs e relativo da amostra				-0	-0,3%



Tabela AII.12 Experimento-12.

Mínimos Quadrados com 300 pontos.					
Xreal	0,91	MQX	0,9069	0,0031	0,31%
Yreal	0,92	MQY	0,9174	0,0026	0,26%
Zreal	0,255	MQZ	0,2554	-0,0004	-0,04%
Erro médio abs e relativo				0,00177	0,2%
Xreal	0,9	MQX	0,8944	0,0056	0,56%
Yreal	0,85	MQY	0,8473	0,0027	0,27%
Zreal	0,26	MQZ	0,26	0	0,00%
Erro médio abs e relativo				0,00277	0,3%
Xreal	1	MQX	1,0055	-0,0055	-0,55%
Yreal	1	MQY	1,0194	-0,0194	-1,94%
Zreal	0,21	MQZ	0,2101	-0,0001	-0,01%
Erro médio abs e relativo				-0,0083	-0,8%
Xreal	0,8888	MQX	0,884	0,0048	0,48%
Yreal	0,8888	MQY	0,8819	0,0069	0,69%
Zreal	0,2555	MQZ	0,2557	-0,0002	-0,02%
Erro médio abs e relativo				0,00383	0,4%
Xreal	0,9	MQX	0,8947	0,0053	0,53%
Yreal	0,9	MQY	0,8945	0,0055	0,55%
Zreal	0,25	MQZ	0,2504	-0,0004	-0,04%
Erro médio abs e relativo				0,00347	0,3%
Xreal	0,9555	MQX	0,953	0,0025	0,25%
Yreal	0,8888	MQY	0,8864	0,0024	0,24%
Zreal	0,2666	MQZ	0,2684	-0,0018	-0,18%
Erro médio abs e relativo				0,00103	0,1%
Erro médio abs e relativo da amostra				8E-04	0,1%



Tabela AII.13 Experimento-13.

R.N.A. Erro 10-7 300 pontos aleatórios 10 épocas					
Xreal	0,9	XRN	0,8997	0,0003	0,03%
Yreal	0,92	YRN	0,9002	0,0198	1,98%
Zreal	0,255	ZRN	0,255	0	0,00%
Erro médio abs e relativo				0,0067	0,7%
Xreal	0,9	XRN	0,9001	-1E-04	-1E-04
Yreal	0,85	YRN	0,8497	0,0003	0,0003
Zreal	0,26	ZRN	0,26	0	0
Erro médio abs e relativo				7E-05	0,0%
Xreal	1	XRN	1,0002	-0,0002	-0,02%
Yreal	1	YRN	0,9997	0,0003	0,03%
Zreal	0,21	ZRN	0,2099	1E-04	0,01%
Erro médio abs e relativo				7E-05	0,0%
Xreal	0,8888	XRN	0,8885	0,0003	0,03%
Yreal	0,8888	YRN	0,889	-0,0002	-0,02%
Zreal	0,2555	ZRN	0,2554	1E-04	0,01%
Erro médio abs e relativo				7E-05	0,0%
Xreal	0,9	XRN	0,8997	0,0003	0,03%
Yreal	0,9	YRN	0,9002	-0,0002	-0,02%
Zreal	0,25	ZRN	0,25	0	0,00%
Erro médio abs e relativo				3E-05	0,0%
Xreal	0,9555	XRN	0,9552	0,0003	0,03%
Yreal	0,8888	YRN	0,8888	0	0,00%
Zreal	0,2666	ZRN	0,2666	0	0,00%
Erro médio abs e relativo				1E-04	0,0%
Erro médio abs e relativo da amostra				0,001	0,1%

Tabela AII.14 Experimento-14.

R.N.A. Erro 10-8 100 padrões 8 épocas					
Xreal	0,91	XRN	0,9098	0,0002	0,02%
Yreal	0,92	YRN	0,9196	0,0004	0,04%
Zreal	0,255	ZRN	0,2552	-0,0002	-0,02%
Erro médio abs e relativo				0,000133	0,0%
Xreal	0,9	XRN	0,9002	-0,0002	-0,0002
Yreal	0,85	YRN	0,8501	-1E-04	-1E-04
Zreal	0,26	ZRN	0,2669	-0,0069	-0,0069
Erro médio abs e relativo				-0,0024	-0,2%
Xreal	1	XRN	0,999	0,001	0,10%
Yreal	1	YRN	0,9986	0,0014	0,14%
Zreal	0,21	ZRN	0,2109	-0,0009	-0,09%
Erro médio abs e relativo				0,0005	0,0%
Xreal	0,8888	XRN	0,8884	0,0004	0,04%
Yreal	0,8888	YRN	0,8884	0,0004	0,04%
Zreal	0,2555	ZRN	0,2558	-0,0003	-0,03%
Erro médio abs e relativo				0,000167	0,0%
Xreal	0,9	XRN	0,8995	0,0005	0,05%
Yreal	0,9	YRN	0,8995	0,0005	0,05%
Zreal	0,25	ZRN	0,2503	-0,0003	-0,03%
Erro médio abs e relativo				0,000233	0,0%
Xreal	0,9555	XRN	0,9557	-0,0002	-0,02%
Yreal	0,8888	YRN	0,889	-0,0002	-0,02%
Zreal	0,2666	ZRN	0,2665	1E-04	0,01%
Erro médio abs e relativo				-1E-04	0,0%
Erro médio abs e relativo da amostra				-2E-04	0,0%



Tabela AII.15 Experimento-15.

R.N.A. Erro 10-8 300 padrões 13 épocas					
Xreal	0,91	XRN	0,9099	1E-04	0,01%
Yreal	0,92	YRN	0,92	0,0	0,00%
Zreal	0,255	ZRN	0,2551	-1E-04	-0,01%
Erro médio abs e relativo				0,0	0,0%
Xreal	0,9	XRN	0,8998	0,0002	0,0002
Yreal	0,85	YRN	0,85	0,0	0,0
Zreal	0,26	ZRN	0,2603	-0,0003	-0,0003
Erro médio abs e relativo				-3,3E-05	0,0%
Xreal	1,0	XRN	1,0	0,0	0,00%
Yreal	1,0	YRN	1,0	0,0	0,00%
Zreal	0,21	ZRN	0,21	0,0	0,00%
Erro médio abs e relativo				0,0	0,0%
Xreal	0,8888	XRN	0,8887	1E-04	0,01%
Yreal	0,8888	YRN	0,8887	1E-04	0,01%
Zreal	0,2555	ZRN	0,2556	-1E-04	-0,01%
Erro médio abs e relativo				3,33E-05	0,0%
Xreal	0,9	XRN	0,8999	1E-04	0,01%
Yreal	0,9	YRN	0,8999	1E-04	0,01%
Zreal	0,25	ZRN	0,2501	-1E-04	-0,01%
Erro médio abs e relativo				3,33E-05	0,0%
Xreal	0,9555	XRN	0,9554	1E-04	0,01%
Yreal	0,8888	YRN	0,8888	0,0	0,00%
Zreal	0,2666	ZRN	0,2667	-1E-04	-0,01%
Erro médio abs e relativo				0,0	0,0%
Erro médio abs e relativo da amostra				5,56E-06	0,0%

Tabela AII.16 Experimento-16.

Mínimos Quadrados com focos diferentes					
Xreal	0,9	XRN	0,9	0,0	0,00%
Yreal	0,9	YRN	0,9	0,0	0,00%
Zreal	0,2	ZRN	0,2	0,0	0,00%
Erro médio abs e relativo				0,0	0,0%
Xreal	0,88	XRN	0,88	0,0	0,0
Yreal	0,9	YRN	0,9	0,0	0,0
Zreal	0,2	ZRN	0,2	0,0	0,0
Erro médio abs e relativo				0,0	0,0%
Xreal	1	XRN	0,9999	1E-04	0,01%
Yreal	1	YRN	1	0	0,00%
Zreal	0,2	ZRN	0,2	0	0,00%
Erro médio abs e relativo				3,33E-05	0,0%
Xreal	1	XRN	0,9999	1E-04	0,01%
Yreal	0,89	YRN	0,8899	1E-04	0,01%
Zreal	0,2	ZRN	0,2	0	0,00%
Erro médio abs e relativo				6,67E-05	0,0%
Xreal	1	XRN	0,9999	1E-04	0,01%
Yreal	0,95	YRN	0,9499	1E-04	0,01%
Zreal	0,2	ZRN	0,2	0	0,00%
Erro médio abs e relativo				6,67E-05	0,0%
Xreal	0,95	XRN	0,9499	1E-04	0,01%
Yreal	1,05	YRN	1,0499	1E-04	0,01%
Zreal	0,2	ZRN	0,2	0	0,00%
Erro médio abs e relativo				6,67E-05	0,0%
Erro médio abs e relativo da amostra				3,89E-05	0,0%



Tabela AII.17 Experimento-17.

Mínimos Quadrados, aquisição com câmera Sony.					
Xgrid	9	XRN	8,32	0,678	8%
Ygrid	8,5	YRN	9,03	-0,5251	-6%
Zgrid	2	ZRN	2	0	0%
Erro médio abs e relativo coord.				5,097%	0,452%
Xgrid	22	XRN	22,21	-0,206	-1%
Ygrid	8,5	YRN	8,13	0,3706	4%
Zgrid	2	ZRN	2,00	-0,0001	0%
Erro médio abs e relativo coord.				0,0548	1,1%
Xgrid	175	XRN	176,21	0,0042	-1%
Ygrid	8,5	YRN	8,00	-0,0038	6%
Zgrid	2	ZRN	2,00	0,0002	0%
Erro médio abs e relativo coord.				0,0002	1,7%
Xgrid	98	XRN	98,488	-0,4883	0%
Ygrid	27	YRN	26,68	0,3196	1%
Zgrid	2	ZRN	2,0001	-0,0001	0%
Erro médio abs e relativo coord				-0,0563	0,2%
Xgrid	158,5	XRN	159	-0,6093	0%
Ygrid	27	YRN	26,68	0,3196	1%
Zgrid	2	ZRN	2,0001	-0,0001	0%
Erro médio abs e relativo coord				-0,0966	0,3%
Xgrid	67,5	XRN	67,588	-0,0878	0%
Ygrid	43	YRN	43,437	-0,4367	-1%
Zgrid	2	ZRN	2	0	0%
Erro médio abs e relativo coord				-0,1748	-0,4%
Erro médio abs e relativo da amostra				-0,0369	1%



Tabela AII.20 Experimento-20.

RESULTADOS Rede Neural ERRO 10-6 [50 3] 358 EPOCAS					
Xgrid	9	XRN	8,71	0,29	3%
Ygrid	8,5	YRN	10,18	-1,68	-20%
Zgrid	2	ZRN	2	0	0%
Erro médio abs e relativo coord.				-46,333%	-5,514%
Xgrid	22	XRN	23,2	-1,2	-5%
Ygrid	8,5	YRN	9,04	-0,54	-6%
Zgrid	2	ZRN	2	0	0%
Erro médio abs e relativo coord.				-0,58	-3,9%
Xgrid	175	XRN	176,39	0,0042	-1%
Ygrid	8,5	YRN	8,66	-0,0038	-2%
Zgrid	2,0	ZRN	2	0,0002	0%
Erro médio abs e relativo coord.				0,0002	-0,9%
Xgrid	98	XRN	98,59	-0,59	-1%
Ygrid	27	YRN	27,32	-0,32	-1%
Zgrid	2,0	ZRN	2	0	0%
Erro médio abs e relativo coord				-0,303333	-0,6%
Xgrid	158,5	XRN	159	-0,97	-1%
Ygrid	27	YRN	26,98	0,02	0%
Zgrid	2,0	ZRN	2	0	0%
Erro médio abs e relativo coord				-0,316667	-0,2%
Xgrid	67,5	XRN	67,44	0,06	0%
Ygrid	43	YRN	43,24	-0,24	-1%
Zgrid	2,0	ZRN	2	0	0%
Erro médio abs e relativo coord				-0,06	-0,2%
Erro médio abs e relativo da amostra				-0,287189	-2%



Tabela AII.21 Experimento-21.

RESULTADOS Rede Neural ERRO 10-8 [50 3] 1359 ÉPOCAS					
Xgrid	9,0	XRN	9,53	-0,53	-6%
Ygrid	8,5	YRN	9,24	-0,74	-9%
Zgrid	2,0	ZRN	2,0	0,0	0%
Erro médio abs e relativo coord.				-0,4233	-4,865%
Xgrid	22,0	XRN	24,11	-2,11	-10%
Ygrid	8,5	YRN	8,06	0,44	5%
Zgrid	2,0	ZRN	2,0	0,0	0%
Erro médio abs e relativo coord.				-0,5567	-1,5%
Xgrid	175	XRN	172,08	0,0042	2%
Ygrid	8,5	YRN	13,27	-0,0038	-56%
Zgrid	2	ZRN	2,0	0,0002	0%
Erro médio abs e relativo coord.				0,0002	-18,1%
Xgrid	98	XRN	98,02	-0,02	0%
Ygrid	27	YRN	28	-1	-4%
Zgrid	2,0	ZRN	2,0	0	0%
Erro médio abs e relativo coord				-0,34	-1,2%
Xgrid	158,5	XRN	157	1,18	1%
Ygrid	27	YRN	24,21	2,79	10%
Zgrid	2,0	ZRN	2,0	0,0	0%
Erro médio abs e relativo coord				1,3233	3,7%
Xgrid	67,5	XRN	67,77	-0,27	0%
Ygrid	43	YRN	43,01	-0,01	0%
Zgrid	2,0	ZRN	2,0	0,0	0%
Erro médio abs e relativo coord				-0,0933	-0,1%
Erro médio abs e relativo da amostra				-0,015	-4%

Tabela AII.23 Experimento-23.

Grid 130 pontos erro 10-6 1256 épocas imagens reais					
XRN	0,1376	Xreal	0,1365	-0,0011	-1%
YRN	0,1579	Yreal	0,16	0,0021	1%
ZRN	0,004	Zreal	0,002	-0,002	-100%
Posição RN	0,0976	Posição real	0,1		
Erro médio abs e relativo coord.				-0,033%	-33,164%
XRN	0,0614	Xreal	0,0607	0,0007	1%
YRN	0,1596	Yreal	0,16	-0,0004	0%
ZRN	0,0034	Zreal	0,002	0,0014	41%
Posição RN	0,0971	Posição real	0,1		
Erro médio abs e relativo coord.				0,000567	14,0%
XRN	0,0154	Xreal	0,0152	0,0042	1%
YRN	0,1622	Yreal	0,16	-0,0038	1%
ZRN	0,002	Zreal	0,002	0,0002	0%
Posição RN	0,1142	Posição real	0,115		
Erro médio abs e relativo coord.				0,0002	0,9%
X RN	0,0903	Xreal	0,091	-0,0007	-1%
Y RN	0,1624	Yreal	0,16	0,0024	1%
Z RN	0,002	Zreal	0,002	0	0%
Posição RN	0,1143	Posição real	0,115		
Erro médio abs e relativo coord				0,000567	0,2%
X RN	-0,001	Xreal	0	-0,001	100%
Y RN	0,067	Yreal	0,0711	-0,0041	-6%
Z RN	0,0021	Zreal	0,002	1E-04	5%
Posição RN	0,1	Posição real	0,1		
Erro médio abs e relativo coord				-0,001667	32,9%
X RN	0,167	Xreal	0,1668	0,0002	0%
Y RN	0,1621	Yreal	0,16	0,0021	1%
Z RN	0,0034	Zreal	0,002	0,0014	41%
Posição RN	0,1139	Posição real	0,115		
Erro médio abs e relativo coord				0,001233	14,2%
Erro médio abs e relativo da amostra				9,44E-05	5%

Tabela AII.25 Experimento-25.

RESULTADOS Rede Neural ERRO 10-6 [50 3] 467 ÉPOCAS					
Xgrid	13,65	XRN	13,63	0,02	0,18%
Ygrid	16	YRN	16,00	0,00	0,01%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord.				0,00867	0,063%
Xgrid	10	XRN	10	0,00	0,00%
Ygrid	10	YRN	10,85	-0,85	-8,50%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord.				-0,2833	-2,833%
Xgrid	24	XRN	24,98	-0,98	-4,08%
Ygrid	10	YRN	10,59	-0,59	-5,90%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord.				-0,5233	-3,328%
Xgrid	98	XRN	98,02	-0,02	-0,02%
Ygrid	27	YRN	27,49	-0,49	-1,81%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord				-0,17	-0,612%
Xgrid	158,5	XRN	159	0,00	0,00%
Ygrid	27	YRN	25,5	1,50	5,56%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord				0,5	1,852%
Xgrid	68	XRN	68,51	-0,51	-0,75%
Ygrid	44	YRN	46,38	-2,38	-5,41%
Zgrid	2	ZRN	2	0,00	0,00%
Erro médio abs e relativo coord				-0,9633	-2,053%
Erro médio abs e relativo da amostra				-0,2386	-1,152%



0810001121

