

CALIBRAÇÃO DE CÂMERAS USANDO REDES NEURAIS

*Márcio Mendonça*¹
*Ivan Nunes da Silva*²
*José Eduardo C. Castanho*³

RESUMO:

Este trabalho apresenta uma nova proposta para calibração de câmeras, dentro do contexto de aquisição de imagens 3-D, utilizando redes neurais do tipo “perceptron back propagation” com camadas ocultas. A principal vantagem do emprego de redes é não ser necessário conhecer os parâmetros intrínsecos das câmeras, tais como foco, distorções além da geometria do sistema. Vários testes foram realizados para se validar a proposta com a utilização de diferentes conjuntos de pontos de teste, números de neurônios e diferentes simulações de câmeras. Por se fazer uso de simulações de câmera, ou seja modelos matemáticos capazes de reproduzir a utilização de câmeras na obtenção das coordenadas dos pontos, e considerando que nos testes simulados não existem erros de aquisição dos pontos, a imprecisão obtida pela rede neural é consequência apenas do resíduo numérico. Nos testes com simulação de erro na aquisição, a rede convergiu e apresentou boa precisão, demonstrando a robustez da técnica empregada.

Palavras Chave: Redes Neurais , Calibração de Camera , Visão Estereo

ABSTRACT:

This work presents a new proposal for calibration of cameras, inside the context of acquisition of images 3-D, using neural network of the perceptron type back propagation with occult layers. The main advantage of the employment of nets is that it is not necessary to know the intrinsic parameters of the cameras, such as focus, besides the geometry of the system. Several tests are proposed to validate the Work.

¹ Graduado em Engenharia, mestrando na Universidade do Norte do Paraná - UNOPAR, professor do CEFET-PR / Unidade de Cornélio Procópio.

^{2 e 3} Professores da Universidade Estadual Paulista - UNESP / Campus de Bauru.

The use of different groups of test points, numbers of neurons and different simulations of cameras. For doing use of camera simulations, that is to say mathematical models capable to reproduce the use of cameras in the obtaining of the coordinates of the points. It is finally the use of the system in real situations with acquisition of real images. The tests with error simulations in its acquisition, the net converged and presented good precision showing the robustness of the employed technique.

Key Words: Neural networks , Camera calibration, stereovision.

INTRODUÇÃO:

A proposta de um sistema de calibração de câmera é estabelecer a relação das coordenadas 3D globais para as coordenadas de imagem da câmera em 2D[5].

O processo de calibração de câmera é um pré-requisito para a maioria das aplicações em visão computacional. Consiste em se obter os parâmetros que definem o modelo do sistema de aquisição, permitindo estabelecer uma relação entre as coordenadas do ambiente, chamadas de coordenadas globais, em três dimensões para as coordenadas bidimensionais das imagens.

O modelo de câmera é necessário para se definir uma relação entre os pontos no espaço tridimensional e o espaço bidimensional da imagem [8]. A calibração permite, portanto, estabelecer a posição da câmera (ou do sistema de visão) em relação ao sistema de coordenadas globais.

Neste modelo, as coordenadas globais, em três dimensões – (x,y,z) , são mapeadas para apenas duas coordenadas da imagem (x',y') . Assim, teremos uma transformação de muitos para um conforme mostra figura 1.

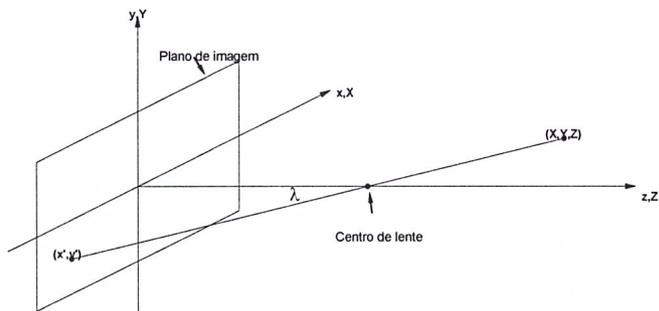


FIGURA 1. Modelo de transformação perspectiva de uma câmera.

Os pontos com diferentes coordenadas espaciais terão a mesma projeção ou as mesmas coordenadas na imagem. Dessa forma, é impossível se obter as coordenadas de um ponto no espaço (coordenadas de mundo) diretamente das coordenadas projetadas do mesmo na imagem.

Para a recuperação da informação 3-D em visão computacional existem várias alternativas [17],[10],[21],[7]. Entre as mais comuns, está a estéreo visão [15],[19],[4]; a utilização da projeção de luz estruturada [12],[21],[7]; ou também um sistema de calibração móvel com uma câmera presa a um braço de um robô[1]. Na estéreo visão, tratada neste trabalho, 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. Deste 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. Dessa forma, através de triangulação é possível se recuperar a posição do ponto no espaço a partir das coordenadas do ponto projetado em ambas as câmeras. Entretanto, a solução desse sistema implica na solução de um sistema de equações não lineares e portanto é necessário o emprego de técnicas de otimização. Além disso, é necessária a recuperação prévia dos parâmetros intrínsecos das câmeras com a finalidade de se determinar o modelo de projeção. Algumas técnicas permitem a obtenção simultânea tanto dos parâmetros intrínsecos (distância focal, centro da câmera), como dos parâmetros extrínsecos (orientação da câmera e posição)

Uma outra abordagem, sugerida neste trabalho, é utilizar uma rede neural capaz de aprender a relação entre as coordenadas globais e as coordenadas das câmeras. E adicionando a possibilidade deste método de calibração o reconhecimento de foco das câmeras utilizadas. Este aprendizado é realizado utilizando coordenadas de pontos no espaço e suas respectivas projeções em um conjunto de câmeras (sistema estéreo), fornecendo a Rede Neural os pontos de imagem das duas câmeras na entrada e pontos de coordenadas espaciais correspondentes na saída.

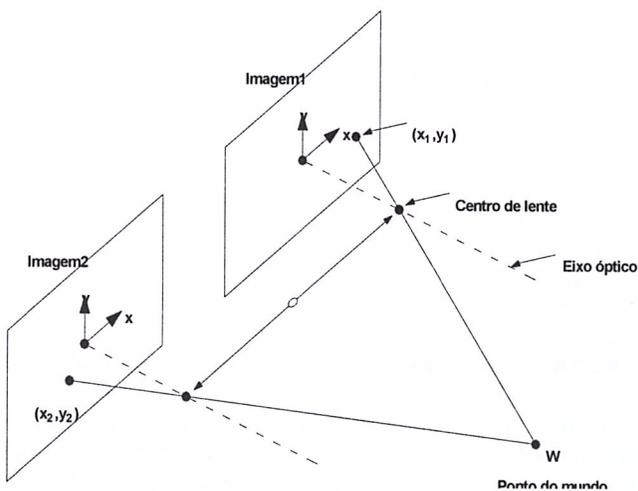


Figura 2. – Modelo de um sistema de estéreo visão.

MOTIVAÇÃO:

No processo de calibração em estereovisão convencional utiliza-se uma matriz de calibração A , discutida na introdução do trabalho. Feito para cada uma das câmeras, através de soluções matemáticas ou também soluções matriciais com aplicação dos mínimos quadrados.

E conhecer parâmetros intrínsecos da câmera, foco e a disposição geométrica das mesmas para se resgatar a terceira dimensão. A motivação do trabalho é desenvolver uma nova ferramenta para calibrar as câmeras utilizando redes neurais em que se opera somente com as coordenadas cartesianas das duas câmeras e das coordenadas globais aplicadas como padrões de entrada e saída da rede. Determina-se a calibração. E para se demonstrar a robustez do processo, os últimos testes são realizados com erros de aquisição dos pontos, criando uma simulação ainda mais real.

Deve-se, pois, calibrar um sistema de estereovisão através de uma rede “perceptron back propagation” com pelo menos uma camada oculta, em que a rede calibra as duas câmeras simultaneamente e dispensa parâmetros intrínsecos e geométricos necessários a um sistema matemático tradicional de calibração em estereovisão.

Convém criar situações com focos diferentes para as duas câmeras para se demonstrar a eficiência do método que dispensa os parâmetros intrínsecos; e pode-se comparar o erros de teste de redes treinadas com dados aleatórios ou grid de pontos geometricamente espaçados utilizados em processos convencionais.

DESENVOLVIMENTO:

Geometricamente, cada ponto do espaço só pode ter um correspondente com as coordenadas das imagens x , y , e x_2 y_2 nas duas câmeras, no nosso trabalho geramos pontos no espaço aleatoriamente e por um grid dentro de uma região definida, mais precisamente um quadrado com a coordenada Z_g fixa em 0.2m e XG e YG de 0,65 a 1,35m. E através de modelos matemáticos de duas câmeras determinamos os pontos x e y das duas imagens. O modelo matemático simula as transformações matriciais rotação, translação e perspectiva de um ponto no espaço para a sua imagem. Desta maneira as coordenadas das câmeras são expressas de forma homogênea para facilitar operações matriciais, e são obtidas a partir das coordenadas globais e produto das referidas transformações. Em outras abordagens são utilizados modelos com mais graus de liberdade [6].

$$Ch = P * C * R * G * Wh;$$

Matriz transformação perspectiva:

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & \frac{-1}{\lambda} & 1 \end{bmatrix}$$

Matriz translação da câmera em relação a origem das coordenadas globais:

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

Matriz Rotação com dois graus de liberdade:

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

Deslocamento do sistema de fixação da câmera:

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

As coordenadas wh são as globais expressas em coordenadas homogêneas, chi são as coordenadas homogêneas da câmera depois das transformações do modelo matemático.

As coordenadas das duas câmeras são obtidas a partir de dois modelos, basicamente com mudança apenas na matriz G que determina a posição do sistema de fixação da câmera no espaço. Podemos calcular x_1 e y_1 e x_2 e y_2 das duas câmeras pelas formulas [8].

$Ch_1 = P * C * R * G * Wh$; câmera 1

$Ch_2 = P * C * R * G_2 * Wh$; câmera 2

em que:

$$X_1 = \frac{Ch_1(1)}{Ch_1(4)}$$

$$Y_1 = \frac{ch_1(2)}{ch_1(4)}$$

$$X_2 = \frac{ch_2(1)}{ch_2(4)}$$

$$Y_2 = \frac{ch_2(2)}{ch_2(4)}$$

Para a calibração do sistema utilizou-se uma rede perceptron com varrições de 60, até 300 pontos de treinamento. O erro da rede foi de 10^{-6} a 10^{-8} sendo os melhores resultados para testes com erros menores. Aumentando a precisão de 10^{-7} para 10^{-8} , o tempo de processamento aumenta significativamente mas sem aumentar significativamente a eficiência, principalmente quando erros de distorções de foco são grandes devido a qualidade da câmera.

REDES NEURAIS ARTIFICIAIS

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 a partir de dados reais, diferindo da computação convencional, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

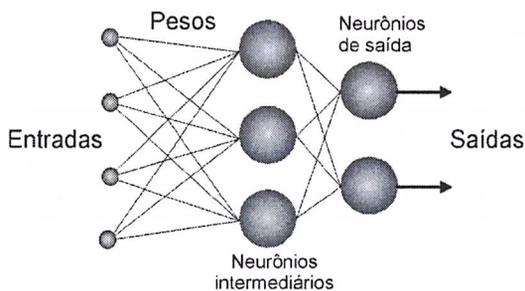


Figura 3

Conforme apresentado na Figura 3., as camadas de uma rede neural são usualmente classificadas em três grupos:

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

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 concluído e apresentadas as coordenadas globais.

Para o desenvolvimento do software utilizou-se o mat lab , tool box neural network, método levenberg para o aprendizado da rede .O hardware utilizado foi um K6-2 AMD 500 Mhz 128 Mbram . Overlock 550 Mhz e NoBreak 600 VA.

Avaliação crítica

O sistema tem grande vantagem sobre métodos tradicionais por não precisar conhecer a geometria das câmeras, seus parâmetros intrínsecos e feito simultaneamente para as duas câmeras . Deixando o processo de calibração muito mais

prático, principalmente por não necessitar de disposição geométrica do sistema e do foco, dados que podem contribuir para imprecisão no processo. E mesmo em situação de simulação de erros e distorção de foco, a rede foi capaz de obter calibração das câmeras com excelente precisão, para os padrões de calibração.

Vantagens do método

Métodos complicados e modelos matemáticos do espaço de trabalho e sistema de imagem são desnecessários. Parâmetros iniciais de calibração são desnecessários.

O método pode ser aplicado para outros trabalhos com qualquer *setup*.

Metodologia

Os testes mencionados são comparações entre os resultados do modelo matemático e o uso de imagens reais, fornecendo coordenadas sem erro de aquisição e distorção para a rede neural.

As tabelas demonstram os erros absolutos e relativos das coordenadas denominadas reais do modelo matemático e da rede neural. No início das tabelas, a topologia, o número de épocas e a precisão de treinamento são mencionados. Todas as tabelas de teste trazem informações do número de padrões, épocas. Observando que todas as medidas das coordenadas estão em metros.

Solução por mínimos quadrados também é utilizada no texto, para se comparar a precisão obtida pelos M.Q.[4] e a rede neural, pontos de testes com um grid (tabuleiro) ou pontos aleatórios .

As simulações estão dispostas em quatro grupos, nos quais a rede generalizou em todos:

- (A) *Situações com focos, alturas diferentes.*
- (B) *Erro de aquisição, simulado por um erro gaussiano.*
- (C) *Testes de inteligência onde a rede reconhece parâmetros intrínsecos como o foco das câmeras no sistema.*
- (D) *Treinamento em uma superfície no espaço (coordenada z fixa)*
- (E) *Treinamento em um volume no espaço.*
- (F) *Treinamento com uma superfície no espaço com imagens reais.*

A topologia utilizada é 20 30 3, só em (C) que 20 30 5 com os dois focos e as três coordenadas espaciais. A topologia usada em (F) é de 50 3, com melhoria em tempo de processamento, mais pesado com o uso de imagens reais devido as distorções radiais .

Não consideradas em tempo de simulação, os modelos matemáticos não consideraram distorções radiais. Os testes (F) são a aplicação prática dos métodos apresentados neste trabalho. Para tanto, foram aplicadas duas câmeras. Na segunda experiência, os resultados foram muito bons, ficando a cargo de imprecisões de medidas das coordenadas dos pontos do grid e aquisição das coordenadas e imagem.

TABELA DOS EXPERIMENTOS

Num.	Ferramenta	Erro rede	Num. Epocas	Topologia rede	Pontos	E.M.A.	E.M.R.
01	R.N.A.	10^{-7}	7	[20-30-3]	300	0,0	0%
02	R.N.A.	10^{-7}	9	[20-30-3]	300	0,00001	0%
03	R.N.A.	10^{-6}	252	[20-30-3]	250 ^E	0,00213	0,2%
04	R.N.A.	10^{-7}	989	[20-30-3]	250 ^E	0,00091	0,1%
05	M.Q.	*	*	*	150 ^E	-0,00678	-0,8%
06	R.N.A.	10^{-8}	43	[20-30-5] ^F	200	-0,00011	0%
07	R.N.A.	10^{-6}	7	[20-30-3]	250	-0,3333	0%
08	R.N.A.	10^{-7}	9	[20-30-3]	250	0,0001	0%
09	R.N.A.	10^{-8}	12	[20-30-3]	250	0,00025	0%
10	M.Q.	*	*	*	100 ^A	0,01169	1,2%
11	M.Q.	*	*	*	200	-0,00267	-0,3%
12	M.Q.	*	*	*	300	0,00076	0,1%
13	R.N.A.	10^{-7}	10	[20-30-3]	300 ^A	0,00117	0,1%
14	R.N.A.	10^{-8}	8	[20-30-3]	100	-0,00024	0%
15	R.N.A.	10^{-8}	13	[20-30-3]	300	0	0%
16	M.Q.	*	*	*	300	0,002	0%
17 ^R	M.Q.	*	*	*	130	0,2359	4%
18 ^R	R.N.A.	10^{-8}	130	[20-30-3]	130	0,2056	5%
19 ^R	M.Q.	*	*	*	130	-0,03695	1%
20 ^R	R.N.A.	10^{-6}	358	[50-3]	130	-0,2872	-2%
21 ^R	R.N.A.	10^{-8}	1359	[50-3]	130	-0,015	-4%
22 ^R	R.N.A.	10^{-5}	5000	[55-3]	130	0,01895	0%

* Não é utilizado.

^R Experimentos com pontos reais.

^F Simulações com identificação de focos.

^A Pontos aleatórios.

^E Simulações com erros gaussianos.

RESULTADOS E DISCUSSÃO:

Os experimentos 1 e 2 feitos por simulação foram as primeiras validações com erros muito pequenos, porém validando a proposta do uso das redes neurais.

Aos experimentos 3, 4 e 5, foi acrescido um erro gaussiano da ordem de 5% para uma simulação mais próxima da realidade devido a erros de aquisição das coordenadas tanto as globais como as da imagem.

Sendo importante que a rede generalizou, com maior numero de épocas, o experimento 5 trouxe a aplicação de uma outra ferramenta para confronto com as redes neurais, fazendo simulação semelhante com o mesmo erro de aquisição e com erros compatíveis.

O experimento 6 trouxe uma perspectiva para abertura de novos trabalhos em que a rede foi treinada com dois focos diferentes e capaz de identificar qual dos focos estava sendo utilizado em determinado instante. Demonstrando o potencial das redes neurais como sistemas inteligentes.

Os experimentos 7,8 e 9 foram realizados com pontos virtuais em uma superfície plana no espaço utilizando as redes neurais.

Os experimentos 10 a 15 foram pontos virtuais em um paralelogramo espacial confrontando R.N. com M.Q., com resultados bastante próximos para redes neurais.

O experimento 16 foi uma simulação com dois focos, para se confirmar a eficácia desta solução em situações diversas.

Os experimentos 17 e 18 foram realizadas a partir da aquisição de dados reais de imagens planas uma câmera WebCam3, trazendo a distorção radial não tratada em tempo de simulação e bastante evidente devido a baixa qualidade da imagem deste tipo de câmera .

Os experimentos 19, 20 e 21 foram semelhantes ao 16 e 17 com a diferença de se utilizar outro tipo de câmera Sony. As duas ferramentas foram confrontadas , trazendo compatibilidade nos resultados obtidos.

O experimento 22 teve objetivo especial de se calibrar o sistema em um espaço 3d com imagem real, provando que a rede generalizou tanto em testes de simulação como imagens reais.

CONCLUSÕES FINAIS:

Os resultados obtidos com 1 e 2 camadas ocultas foram similares provando que, teoricamente que a rede com pelo menos uma camada oculta pode resolver qualquer sistema [4]. A necessidade de se usar mais de uma camada oculta se deve quando o problema tem descontinuidade em seu domínio [11]. Neste trabalho, a rede generalizou com uma e duas camadas, concluindo que existe uma função de calibração contínua em seu domínio.

Com a precisão com erro 10^{-6} , não se obteve resultados precisos. Sendo as experiências direcionadas para erro 10^{-7} com 60 padrões de testes, o erro é na ordem 5%, ainda ruim. Mas com erro menor 10^{-8} , os resultados em média obtidos foram menos que 1% significativos para calibração de câmera com 100 padrões de testes os resultados foram similares.

Acima de 200 padrões de teste, o erro cai praticamente para arredondamento matemático e até nulos nos testes sem erro de aquisição. Os últimos resultados foram simulações com erro gaussiano nas entradas da rede. Da ordem de 5%, demonstrando a eficiência da rede capaz de convergir com erros na aquisição e

fornecendo resultados precisos, demonstrados e discutidos nas tabelas, foram menor que 1%, erros menores que a solução por mínimos quadrados.

Nos resultados dos testes com volumes, a rede neural generalizou em todos os testes, obtendo resultados com muito maior precisão inclusive nos pontos extremos ou vértices no espaço .

Sendo aconselhável trabalhar com erro 10^{-8} , nos testes a precisão com 100 e 300 pontos é bem pequena, com o erro 10^{-8} . Lembrando que acima de 100 pontos fica complicada a aquisição dos mesmos, já os mínimos quadrados conseguem resultados satisfatórios (inferiores a rede neural) e com principal vantagem no tempo de treinamento e facilidade de implementação.

Nas tabelas dos testes, foram comparados os valores reais com os resultados da rede neural com cálculos dos erros absolutos e erros relativos dados em porcentagem. De acordo com os resultados demonstrados, a proposta deste trabalho foi validada sendo assim uma ferramenta para calibração em estereovisão.

A rede neural, depois de treinada, é um sistema inteligente capaz de reconhecer parâmetros intrínsecos como o foco utilizado nas câmeras, sendo uma solução inteligente.

Os parâmetros intrínsecos em algumas aplicações são necessários, principalmente em sistemas móveis. Assim, vislumbrou-se a aplicação da rede para determinar o foco das duas câmeras (E) envolvidas em estereovisão, podendo ser estendido a um outro trabalho.

Nos testes realizados com câmeras reais a imagem gerada pela Webcam (imagem F1) tem maior distorção radial do a câmera Sony (imagem F2), sendo que os melhores resultados na segunda experiência foram muito bons, ficando a cargo de imprecisões de medidas de coordenadas do grid. Mesmo assim permitindo a localização dos pontos do grid no espaço, considerando um diâmetro de 1 cm desses pontos.

As R.N generalizaram em ambos os casos com melhor precisão que o M.Q. em modelos matemáticos. Mas em simulações com imagens reais os dois métodos são equivalentes com uma pequena vantagem para M.Q.

BIBLIOGRAFIA

- [1] Andreff Nicolas, Radu Horaud, Bernerd Espiau. *On-Line Hand-Eye Calibration*. Saint Martin: INTRIA Rhone-Alpes/GRAVIR-IMAG.
- [2] Braga Aontônio de Pádua, Tereza Bernarda Ludemir, André Carlos Ponce de Leon Ferreira Carvalho. *REDES NEURAIAS ARTIFICIAIS Teoria e Aplicações*. LTC Livros Técnicos Científicos.

- [3] – Bellon, Olga R. Pereira. *Visão Computacional: Um sistema para localização de objetos pliédricos no espaço 3D*. Tese. Campinas: Universidade Estadual de Campinas. Dezembro 1990.
- [4] – Chen, William and Bernard Jiang C., *3-D Camera Calibration Using Vanish Point Concept*, Departament of Matematica, Washington: University, St Louis.
- [5] Echigo Tomio. *A Camera Calibration Technique using Three Sets of Parallel Lines*. *Machine Vision and Applications* (1990) 3:159-167.
- [6] – Ganapathy, Sundaram. *Decomposition of matrizes for robot vision. Pattern Recognition*. *Letters* 2 (1984) 401-412.
- [7] Guisser L., R. Payrissat, S. Castan, *An accurate 3D vision system using a projected grid for surface descriptions*. *Image and vision computing* 18 (2000) 463-491.
- [8] – Gonzalez, Rafael C., Richard E Woods. *Processamento Digital de Imagens*. São Paulo: Edgard Blücher 2000.
- [9] – Haykin, Simon. *Redes Neurais, Princípios e prática*. São Paulo: Bookman C.2000.
- [10] Heikkilä Janne. *Geometric Camera Calibration Using Circular Control Points*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol 22 N°10 October 2000.
- [11] Imamura Marcos M., Ivan N. de Silva, Andre N. de Souza. *Uma abordagem neural para análise dos gases dissolvidos em oleo isolante em função das grandezas Físico-Químicas*. Bauru: UNESP 17033-360.
- [12] – Kim, C. *3D Structured Light Based Depth Extration*. Laboratory Research Areas: 3D Scanner
- [13] – Lay, David C. *Álgebra Linear e suas aplicações*, 2ª ed., Livros Técnicos e Científicos 1999.
- [14] 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.
- [15] – J.J Aguilar, F. Torres e M.A Lope., *Stereo Vision for 3D measurement: accuracy analisys, calibration and industrial applications*. Centro Politecnico Superior de Ingenieros, Universidad de Zaragoza, Maria de Luna, 3 E-50015 Zaragoza, Spain. 1996 Esevier Science. Vol 18 .N.4, pp 193-200.

- [16] – 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.
- [17] – Wang, Ling-Ling, Wen-Hsiang Tsai. *Computing Camera Parameters using Vanishing-Line Information from a Rectangular Parallelepiped*. Machine Vision and Applications, 1990, no. 3, pág. 129-141.
- [18] Wells Gordon, Christophe Venaille, Carme Torras. *Promising research, Vision-based robot positioning using neural networks*. Image and Vision Computing 14 (1996) 715-732.
- [19] – Weng Juyang Member, IEEE, Paul Cohen, and Marc Herniou. *Camera Calibration with Distortion Models and Accuracy Evaluation*. IEEE transactions on pattern analysis and machine inteligenca, vol. 14, N 10, October 1992.
- [20] Tien, F.-C.; Chang, C.A., *Using neural networks for 3D measurement in stereo vision inspection system*. Chaoyang Univ of Technology, Taichung County, Taiwan. International Journal of Production Research, 1999, v37, i9, p1935-1948.
- [21] – 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.
- [22] Yuncai Liu, Thomas S. Huang and Olivier D Faugeras, *Determination of Camera Location form 2-D to 3-D Line and Point Correspondence*. IEEE Transactions on Pattern Analysis and Machine Intelligence. vol. 12 N°1 January 1990.