

# 基于分割区间 LS-SVM 的摄像机标定

刘 胜, 傅荟璇, 王宇超

(哈尔滨工程大学自动化学院, 哈尔滨 150001)

**摘要:** 利用最小二乘支持向量机(LS-SVM)可以不考虑摄像机具体的内部参数和外部参数实现摄像机的标定。由于镜头的畸变主要由径向畸变引起, 根据摄像机畸变特点对畸变区域进行划分, 提出一种基于分割区间 LS-SVM 的摄像机标定法, 对不同的畸变区域进行单独处理。该方法与 BP 神经网络和基本 LS-SVM 预测结果对比表明, 分割区间 LS-SVM 摄像机标定法误差小、速度快、标定精度高。

**关键词:** 摄像机标定; 最小二乘支持向量机; 分割区间; 计算机视觉; BP 神经网络

## Camera Calibration Based on Divided Region LS-SVM

LIU Sheng, FU Hui-xuan, WANG Yu-chao

(College of Automatization, Harbin Engineering University, Harbin 150001)

**【Abstract】** By using Least Squares Support Vector Machines(LS-SVM), it need not consider internal and external parameters to achieve the camera calibration. Because the lens distortion is mostly caused by radial distortion, according to the camera distortion characteristic, it divides the distortion region. A new method of camera calibration based on divided region LS-SVM is proposed, and the distortion of different regions deals with separately. The comparison with other methods including BP Neural Network(BPNN) and LS-SVM shows that the calibration accuracy is improved by using the divided LS-SVM method, and the speed is higher.

**【Key words】** camera calibration; Least Squares Support Vector Machines(LS-SVM); divided region; computer vision; BP Neural Network(BPNN)

### 1 概述

摄像机标定是指建立图像像素位置和场景点位置之间的关系。摄像机标定过程就是确定摄像机的几何和光学参数(内部参数)和摄像机相对于世界坐标系的方位(外部参数)。标定精度的大小直接影响计算机视觉(机器视觉)的精度。

目前, 摄像机标定方案大致可分为线性法、非线性法、两步法、双平面法、主动标定法等。这些方法均计算出内部参数和外部参数, 可称为直接法, 若可以不考虑具体参数, 可使用神经网络、支持向量机(Support Vector Machines, SVM)等非线性建模的方法得到图像坐标与世界坐标之间的对应关系, 称之为间接法。这类方法在文献[1-4]中有一定的研究。以上研究对象都用神经网络实现, 神经网络主要基于经验风险最小化原则, 隐含地使用了样本无穷多的假设条件。在实际应用中, 这种前提条件往往得不到满足。SVM<sup>[5]</sup>是近几年来应用于建模的一种新的学习方法, 其最优解基于结构风险最小化思想。最小二乘支持向量机(Least Squares Support Vector Machines, LS-SVM)<sup>[6]</sup>是支持向量机的一种改进, 它将传统支持向量机中的不等式约束改为等式约束, 把解二次规划问题转化为求解线性方程组问题, 提高了求解问题的速度和收敛精度。

本文提出了一种基于 LS-SVM 的标定法, 考虑了点到图像中心距离的不同, 通过对点到图像中心距离的不同进行分段处理。仿真结果证明了该方法提高标定精度的有效性。

### 2 摄像机标定模型

在计算机视觉研究中, 三维空间中的物体到像平面的投影关系即为成像模型, 理想的投影成像模型是光学中的中心投影, 也称为针孔模型, 满足光的直线传播条件。实际摄像系统通常由透镜或透镜组组成。由于透镜设计的复杂性和工

艺水平等因素的影响, 因此实际透镜成像系统会产生镜头畸变, 主要有径向畸变和切向畸变。在实际应用中, 一般只考虑径向畸变。本文也只考虑径向畸变, 且认为畸变误差与透镜中心对称。无畸变理想图像点位置与有畸变实际图像点位置之间的关系如图 1 所示。




图 1 理想图像点与实际图像点

摄像机畸变模型可以简单地表示为

$$\begin{aligned} x_u &= x + \delta_x(x, y) \\ y_u &= y + \delta_y(x, y) \end{aligned} \quad (1)$$

其中,  $(x_u, y_u)$  表示理想情况下不存在畸变的图像坐标;  $(x, y)$  表示存在畸变的实际图像的图像点坐标;  $\delta_x$  与  $\delta_y$  是非线性畸变值, 它与图像点在图像中的位置有关。

**基金项目:** 黑龙江省自然科学基金资助项目(200419)

**作者简介:** 刘 胜(1957 -), 男, 教授、博士生导师, 主研方向: 随控系统最优估计与控制, 鲁棒控制系统; 傅荟璇、王宇超, 博士研究生

**收稿日期:** 2009-05-26 **E-mail:** fhx.3@163.com

实际摄像系统镜头的畸变主要由径向畸变引起，可以表示成一组无限级数的形式，在忽略高阶项的情况下，总的径向畸变  $\delta_r$  可以表示为

$$\delta_r = \frac{1}{\rho} (\delta_{x'}^2 + \delta_{y'}^2)^{1/2} = k_1 \rho^2 + k_2 \rho^4 + k_3 \rho^6 + \dots \approx k_1 \rho^2 \quad (2)$$

其中， $\rho^2 = x^2 + y^2$  表示到图像中心的径向距离。式(2)表明，透镜畸变量的径向畸变  $\delta_r$  相对量与到图像中心的径向距离的平方  $\rho^2$  近似成正比<sup>[3]</sup>，由于在整个图像中各部分的畸变量是不同的，因此距离图像中心越近，畸变量越小；越靠近图像边缘，畸变量越大。

### 3 基于 LS-SVM 的摄像机标定方法

#### 3.1 最小二乘支持向量机

文献[6]在标准支持向量机理论的基础上提出了 LS-SVM 方法，用于解决分类和函数估计问题。

对于训练数据  $\{(x_i, y_i) | i=1, 2, \dots, n\}$ ,  $x \in R^n$ ,  $y \in R$ ,  $n$  为样本个数，支持向量机算法用非线性映射  $\varphi(x)$  将样本从原空间映射到高维的特征空间，并在该高维的特征空间中构造如下回归函数实现对样本数据的拟合及对未来状态的预测。

$$y(x) = \omega^T \varphi(x) + b \quad (3)$$

其中， $\varphi(x)$  是非线性函数，将输入映射到特征空间； $\omega, b$  分别表示权系数和偏置。

标准支持向量机通过求解下述约束优化问题，构造式(4)的回归函数：

$$\begin{aligned} \min_{\omega, \xi} J_1(\omega, \xi) &= \frac{1}{2} (\omega^T \omega) + \gamma \sum_{k=1}^n \xi_k \\ y_k [\omega^T \varphi(x_k) + b] &= 1 - \xi_k, k=1, 2, \dots, n \\ \xi_k &\geq 0, k=1, 2, \dots, n \end{aligned} \quad (4)$$

在 LS-SVM 算法中，上述优化问题变为

$$\begin{aligned} \min_{\omega, b, \xi} J_2(\omega, b, \xi) &= \frac{1}{2} (\omega^T \omega) + \frac{1}{2} \gamma \sum_{k=1}^n \xi_k^2 \\ y_k [\omega^T \varphi(x_k) + b] &= 1 - \xi_k, k=1, 2, \dots, n \end{aligned} \quad (5)$$

其中， $\xi_k$  是松弛因子； $\gamma$  是惩罚参数，实现在允许的回归误差和算法复杂度之间的折中。

定义 Lagrange 函数：

$$L(\omega, b, \xi, \alpha) = J_2(\omega, b, \xi) - \sum_{k=1}^n \alpha_k \{y_k [\omega^T \varphi(x_k) + b] - 1 + \xi_k\} \quad (6)$$

其中， $\alpha_k \in R(k=1, 2, \dots)$  是 Lagrange 算子。对上式进行优化，经过变换可以写成

$$\begin{bmatrix} 0 & -Y^T \\ Y & ZZ^T + \gamma^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ \bar{1} \end{bmatrix} \quad (7)$$

其中，

$$Z = [\varphi(x_1)^T y_1, \varphi(x_2)^T y_2, \dots, \varphi(x_n)^T y_n], Y = [y_1, y_2, \dots, y_n], \bar{1} = [1, \dots, 1]^T, \alpha = [\alpha_1, \alpha_2, \dots, \alpha_n]$$

记  $\Omega = ZZ^T$ ，矩阵中的元素具有如下形式：

$$\Omega_{ij} = y_i y_j K(x_i, x_j)$$

核函数  $K(x, x_k)$  具有多种形式，本文采用径向基核函数：

$$K(x, x_k) = \exp(-\|x - x_k\|^2 / 2\sigma^2), \text{ 其中, } \sigma^2 \text{ 为核密度。}$$

经过上述方程组的求解最后可得到如下 LS-SVM 回归模型：

$$y(x) = \sum_{k=1}^n \alpha_k K(x, x_k) + b \quad (8)$$

#### 3.2 基于 LS-SVM 的标定预测模型

将最小二乘支持向量机引入到摄像机标定中，不需要计

算内外参数，跳过求取各参数的繁琐过程，最小二乘支持向量机采用最小二乘线性系统作为损失函数，有很强的鲁棒性，求解速度快。

对于摄像机标定，采用二输入三输出的形式，将摄像头采集到的像素图像坐标  $(x, y)$  作为输入，将  $(x, y)$  转化为极坐标的形式  $(\rho, \theta)$ 。由式(3)可知， $\delta_r \propto \rho^2$ ，也就是说离图像中心越远，边径向畸变越大。根据  $\delta_r$  的大小对图像分段处理。将世界坐标  $(x_w, y_w, z_w)$  作为输出，由于实验最后得到的是平面坐标，因此在本实验中暂不考虑  $z$  轴情况，输出变为  $(x_w, y_w)$ 。将  $0 < \rho < 0.5$  对应点的图像像素坐标和  $0.5 < \rho < 1$  对应点的图像像素坐标分别作为最小二乘支持向量机的输入，将与之对应点的世界坐标作为输出，分别进行训练，使网络实现给定的输入输出映射关系。

### 4 仿真实验结果

实验中用于标定的系统是一个基于 PMAC 控制卡的运动测量系统。摄像机像素是 656×492，图像采集卡采用嘉恒科技公司生产的 OK 系列 PCI 图像卡。调节光线对一张垂直于光轴的 10×7 的棋盘格(黑白棋格间距均为 2 cm)进行图像采集，原始采集图像如图 2 所示。再将采集的图像编辑后运用 Matlab 图像处理工具进行图像增强、滤波等处理。




图 2 原始采集图像

实验中用的摄像机的像素是 656×492，图像像素坐标  $x$  轴、 $y$  轴范围分别是(0, 656)和(0, 492)。为方便处理，将图像原点定义在摄像机光心，因此，所有图像像素坐标  $x$  轴、 $y$  轴范围分别是(-328, 328)和(-246, 246)。图像的有效采集点有 18×12，共 216 个，随机取其中 186 个点作为训练数据，其余 30 个点作为测试数据。核函数采用径向基核函数。本文采用绝对平均值相对误差(MAPE)作为误差评价标准：

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{y_i} \right| \quad (9)$$

其中， $y_i$  为预测样本的真实值； $x_i$  为预测值。

表 1 从 MAPE 值及训练速度对 BP 神经网络(BP Neural Network, BPNN)、LS-SVM、分割区间最小二乘支持向量机(DLS-SVM)进行比较。

表 1 3 种方法的误差和训练速度比较

方法		MAPE	时间/s
BPNN	$x_w$	0.091 4	55.359 0
	$y_w$	0.214 6	
LS-SVM	$x_w$	0.127 9	0.953 0
	$y_w$	0.153 6	
DLS-SVM	$x_w$	0.059 9	0.102 8
	$y_w$	0.052 1	

图3~图8给出了具体的误差图。图中  $x$  轴和  $y$  轴是测试数据点的图像像素  $x$  轴和  $y$  轴坐标值, 单位为像素,  $z$  轴是真实值与预测值的  $x$  维或  $y$  维坐标的相对误差值  $e$ ,  $e = (x_i - y_i) / y_i, i = 1, 2, \dots, 30$ 。图中反映出每个测试数据的真实值与预测值的  $x$  维、 $y$  维坐标的差值, 凸凹大小反映误差  $e$  大小, 由此可见 DLS-SVM 标定结果误差明显小于其他 2 种方法。




图3 BP神经网络  $x$  轴误差




图4 BP神经网络  $y$  轴误差




图5 LS-SVM  $x$  轴误差




图6 LS-SVM  $y$  轴误差




图7 DLS-SVM  $x$  轴误差




图8 DLS-SVM  $y$  轴误差

通过以上仿真结果可见:LS-SVM 标定结果优于 BPNN, 而且训练速度比神经网络快。DLS-SVM 标定结果比普通 LS-SVM 得到的误差更小, 精度更高, 速度更快。

## 5 结束语

本文研究了基于分割区间最小二乘支持向量机的摄像机标定法, 建立了分割区间最小二乘支持向量机模型。这种摄像机标定法。不需要确定摄像机具体的内部参数和外部参数, 只需要知道部分已知点(已知世界坐标的点)的图像坐标, 就能完成摄像机的标定。并且根据摄像机畸变的特点将图像进行分段处理, 大大提高了标定精度和速度。实验结果证明, 在无参摄像机标定法中, 本文提出的方法是可行有效的。

## 参考文献

- [1] 赵清杰, 孙增圻, 兰 丽. 摄像机神经网络标定技术[J]. 控制与决策, 2002, 17(3): 336-342.
- [2] 吕朝辉, 张兆杨, 安 平. 基于神经网络的立体视觉摄像机标定[J]. 机械工程学报, 2003, 39(9): 93-96.
- [3] 崔彦平, 林玉池, 张晓玲. 基于神经网络的双目视觉摄像机标定方法的研究[J]. 光电子·激光, 2005, 16(9): 1097-1100.
- [4] Jun Jian, Kim C. Robust Camera Calibration Using Neural Network[C]//Proceedings of IEEE Region 10 TENCON Conference. [S. l.]: IEEE Press, 1999: 694-697.
- [5] Vapnik V. The Nature of Statistical Learning Theory[M]. New York, USA: Springer, 1995.
- [6] Suykens J A K. Nonlinear Modeling and Support Vector Machines[C]//Proceedings of Instrumentation and Measurement Technology Conference. Budapest, Hungary: IEEE Press, 2001.

编辑 张正兴