

基于深度学习的单张图像畸变校正

陈文艺¹, 许洁^{1*}, 杨辉¹, 杨小宝², 惠小强²

¹西安邮电大学物联网与两化融合研究院, 陕西 西安 710061;

²西安邮电大学通信与信息工程学院, 陕西 西安 710121

摘要 为了增强畸变校正方法的实时性和适用性,提出了一种基于卷积神经网络(CNN)的图像畸变校正方法。首先,使用具有自校准功能的运动结构重建真实相机拍摄的图像序列,以估计相机参数;然后,根据拟合出的第一、第二阶径向畸变参数之间的函数关系,生成常见径向畸变范围内的图像,解决带有第一、第二阶径向畸变注释的畸变图像较少的问题;最后,利用 CNN 强大的学习能力学习径向畸变的特征,以估计径向的变形情况,并将输入图像映射为畸变系数,实现图像的畸变校正。实验结果表明,相比传统相机标定法,本方法的校正误差约为 1 pixel。

关键词 机器视觉;深度学习;图像畸变;相机标定

中图分类号 TH741 **文献标志码** A

doi: 10.3788/LOP57.241504

Distortion Correction of Single Image Based on Deep Learning

Chen Wenyi¹, Xu Jie^{1*}, Yang Hui¹, Yang Xiaobao², Xi Xiaoqiang²

¹*Institute of Internet of Things and Integration of IT Application and Industrialization, Xi'an University of Posts & Telecommunications, Xi'an, Shannxi 710061, China;*

²*College of Communication and Information Engineering, Xi'an University of Posts & Telecommunications, Xi'an, Shannxi 710121, China*

Abstract For the convenience and applicability of distortion correction methods, a distortion correction method based on convolutional neural networks is presented in this paper. First, the self-calibration functional motion structure is used to reconstruct the image sequence taken by the real camera to estimate the camera parameters. Second, according to the functional relationship between the first and second-order radial distortion parameters, the images within the common radial distortion range are generated to solve the problem of less distorted images with the first and second-order radial distortion annotation. Finally, by using the powerful learning ability of CNN, the radial distortion features are learned to estimate the radial deformation, and the input image is mapped to the distortion coefficient to realize the image distortion correction. Experimental results show that the calibration error of this method is about 1 pixel compared with the traditional camera calibration method.

Key words machine vision; deep learning; image distortion; camera calibration

OCIS codes 150.0155; 150.1488; 120.4820

1 引言

计算机视觉领域中,摄像机标定作为摄像测量技术的基础,是计算机视觉任务中的第一步,如三维(3D)重建。摄像机光学成像不是理想的小孔成像,导致空间点在成像平面上的实际成像点与理想成像点有一定偏差,且两者间存在复杂的非

线性关系,即镜头畸变^[1]。镜头畸变会影响相机标定的精度,从而影响三维重建和测量的精度。因此,在相机标定中,对镜头的畸变校正是一个非常重要的环节。

传统的畸变校正方法主要有三种,第一种是利用精密几何标定物的传统标定方法^[2-4],该方法需要使用特定的标定物,并通过相应的算法得到相机内

收稿日期: 2020-03-16; 修回日期: 2020-05-20; 录用日期: 2020-06-11

基金项目: 国际科技合作计划(2018KW-026)、陕西省教育厅专项科研计划(2018JK0716)

* E-mail: 1141849828@qq.com

外参数。不利于一些标定物设置困难的环境,且计算量大、标定过程繁琐。第二种是基于几何特征的校正方法,在畸变模型的基础上,利用空间特征的不变性,避免了畸变系数与像机参数耦合求解的不稳定性和标定算法的发散性^[5-6]。但该方法依赖于检测和特定的线索,如共线点、平行线。而摄像机在实际工作中,多数情况下无法满足这类标定物的需求,不利于在线实时校正。第三种是基于主动视觉的校对方法^[7-8],通过摄像机或标定物在标定平台上进行的精准相对运动实现相机标定。该方法精度较高,对实验条件的要求也较高,需要高精度的标定平台,成本高,不适用于运动参数未知或无法控制的场合。

随着大规模 ImageNet 数据集的出现和图形处理器(GPU)计算及神经网络的发展,人们提出了用基于学习的方法对畸变进行校正。这些方法主要分为三种,第一种是利用神经网络直接建立物点和像点之间的映射关系^[9-10];第二种是建立线性成像模型,然后用神经网络进行优化^[11];第三种是训练卷积神经网络(CNN)分别对相机内外参进行回归预测^[12-13]。前两种方法由于摄像机成像系统复杂的光学特性,得到的神经网络模型和畸变参数不具有普遍适用性,在其他系统中可能失效。Li 等^[14]用合成的失真数据集训练 CNN,以预测失真图像和校正图像之间的位移场,估计失真参数,从而校正输入图像中的几何畸变。Alemán-Flores 等^[15]提出了一种基于扩展霍夫变换自动校正径向透镜畸变的方法,但该方法对广角镜的校正结果较差。为了使畸变校正方法具有更好的实时性和适用性,本文结合第一、第二阶径向畸变系数之间的函数关系,提出了一种高效、自动校正畸变的方法,可在 ImageNet 原始数据集^[16]的基础上生成大量具有第一、第二阶径向畸变系数的图像,避免了 CNN 的过拟合现象;为了降低连续值到离散类的误差,使用一种细分类方法促进失真系数附近的强相关性。

2 摄像机镜头的畸变模型

摄像机成像中经典的针孔模型是一种不考虑各种畸变的理想模型。实际成像过程中,由于镜头畸变的影响,摄像机的真实成像系统和理论成像模型间有一定偏差,导致物体的位置、投影中心点以及二维图像点间的关系发生变化,不符合严格的线性关系。因此,实际像点坐标与理想像点坐标并不完全重合,二者的关系如图 1 所示,其中, d_r 为径向畸

变, d_t 为切向畸变。




图 1 实际像点与理想像点的关系

Fig. 1 Relationship between the actual and ideal image points

现有相机标定方法中^[17-19],物理坐标系下的实际像点 $p(x, y)$ 与理想像点 $\tilde{p}(\tilde{x}, \tilde{y})$ 之间的关系可表示为

$$\tilde{x} = x + \delta_x = x + x(k_1 r^2 + k_2 r^4 + \dots + k_n r^n) + p_1(r^2 + 2x^2) + 2p_2 xy, \quad (1)$$

$$\tilde{y} = y + \delta_y = y + y(k_1 r^2 + k_2 r^4 + \dots + k_n r^n) + 2p_1 xy + p_2(r^2 + 2y^2), \quad (2)$$

式中, (δ_x, δ_y) 为理想像点与实际像点之间的相差, $r^2 = (x - u_0)^2 + (y - v_0)^2$, (u_0, v_0) 为圆心的坐标, k_1, k_2, \dots, k_n 为径向畸变系数, p_1, p_2 为切向畸变系数。

Tsai^[20]的研究表明,实际求解时,考虑到多镜头畸变的影响,在成像过程中加入更多的畸变参数,可能会导致计算解不稳定,对提高摄像机的标定精度没有太多帮助。在图像的各种畸变中,径向畸变占主导地位,实际相机中几乎不会引入明显的切向畸变。因此,通常情况下,只考虑二阶径向畸变系数 k_1, k_2 带来的误差,其畸变模型可简化为

$$\tilde{x} = x + \delta_x = x + x(k_1 r^2 + k_2 r^4), \quad (3)$$

$$\tilde{y} = y + \delta_y = y + y(k_1 r^2 + k_2 r^4). \quad (4)$$

3 数据集的选择和生成

3.1 径向畸变系数 k_1, k_2 之间的函数关系

实验使用分类的方法近似回归,由于在设定的 k_1, k_2 取值范围内对 k_1, k_2 进行排列组合、生成数据集,所需的数据量过多;与一阶畸变系数相比,二阶畸变系数对径向畸变的影响较小。因此,首先用具有自校准的运动恢复结构(SfM)重

建图像序列,得到相关相机的参数;然后利用相机参数中的径向畸变系数 k_1 、 k_2 拟合出两者的函数关系,大大减少了所需的数据量^[21]。为了估计真实的相机参数,从 Mapillary 上下载了 1000 张街道图像,主要由市场上常见的相机拍摄。SfM 对初始校准参数较敏感,因此,重复用新估计的相机进行参数进行初始化,直至参数收敛;然后用得到的数据进行多项式拟合,结果如图 2 所示,该分布模型的解析表达式为

$$k_2 = 0.805k_1^2 + 0.019k_1. \quad (5)$$




图 2 k_1 和 k_2 的函数关系

Fig. 2 Functional relationship between k_1 and k_2

3.2 数据集的选择和生成

3.2.1 数据集的选择

径向畸变是一种沿透镜半径方向分布的畸变,包括桶形畸变和枕形畸变两种,且畸变程度随畸变系数 k 的绝对值的增加而增加。桶形失真的 k_1 为负值,枕形失真的 k_1 为正值。对于真实的镜头,畸变系数 k_1 异常时为正值,因此实验只关注畸变系数 k_1 的负项。

用 ImageNet 数据集中的图像生成数据集,考虑到基于几何的畸变校正方法对包含一定特征,如直线的图像校正效果较好^[6],因此,通过霍夫变换提取直线从 ImageNet 数据集中筛选出包含一定数量直线的图像,使网络能更好地学习畸变特征。霍夫变换将一个空间中具有相同形状的曲线或直线映射到另一个坐标空间的一个点上形成峰值,从而将检测任意形状的问题转化为统计峰值的问题。为了得到包含较多直线的图像,对数据集中图像的筛选条件可表示为

$$l_{\text{mean}} \geq \vartheta \cdot \max(u, v), \quad (6)$$

式中, ϑ 为数据集的选择因子, l_{mean} 为每张图像通过霍夫变换检测得到最长十条直线的长度均值, u 、 v

分别为图像的长、宽。通过多次实验,在保证数据量足够多且图像中含有明显直线特征的前提下,得到 $\vartheta = 0.6$ 。即在满足(6)式的条件下, l_{mean} 越大,图像中包含的直线越多。

3.2.2 数据集的生成

使用镜头时,径向畸变系数 k_1 通常为 10^{-3} 量级,当畸变系数的数量级小于 10^{-5} 时,相邻畸变系数的变化对畸变性能的影响很小。因此,用多个离散值标签代替回归问题中估计的连续失真系数。为了降低连续值到离散类的误差,在常见畸变系数 k_1 的取值范围内设置其数量级为 10^{-5} ,将畸变系数分成 401 类。即设置标签整数集 k_1 为 $\{400, 399, 398, \dots, 1, 0\}$, 对应 $\{-400 \times 10^{-5}, -399 \times 10^{-5}, -398 \times 10^{-5}, \dots, -1 \times 10^{-5}, 0\}$ 。按照(5)式生成包含径向畸变系数 k_1 、 k_2 标记的数据集,将畸变系数的回归问题变成对 401 类的分类问题。首先,通过霍夫变换检测直线对 ImageNet 原始数据集进行筛选;然后,将合成数据集中的图像进行缩放,降采样后,图像短边的长度为 227 pixel;最后,从获得的图像中裁剪出尺寸为 227 pixel \times 227 pixel 的色块。根据镜头畸变模型,生成 108000 张畸变图像,其中,99360 张用来训练模型,8640 张用来测试模型。合成数据集中的部分图像如图 3 所示,可以看出,合成数据集中图像的内容和径向畸变方面均呈现出明显的可变性。

4 网络结构

4.1 迁移学习

迁移学习^[22]的目的是将从一个场景中(源域)学习到的知识应用到新场景(目标域)中,从相关领域中迁移标注数据或知识结构,完成、改进目标领域或任务的学习效果。实验使用迁移学习中的模型迁移,保存其在 ImageNet 数据集上训练得到的网络模型权重,将新数据集输入该模型进行参数调优(Fine-tune),以达到对新任务的分类。

4.2 网络结构

AlexNet 是 Krizhevsky 等^[23]在 2012 年提出的一种 CNN,其网络结构如图 4 所示。分为 8 层,包括五个卷积层 conv 和三个完全连接层 FC,部分卷积层后面含有池化层。该网络将 120 万张图像作为训练集,约有 6000 万个参数。AlexNet 采用 dropout 策略和修正线性单元



图 3 合成数据集中的部分图像

Fig. 3 Part of the image in the synthetic dataset




图 4 AlexNet 的结构

Fig. 4 Structure of AlexNet

(ReLU)激活函数缓解过拟合问题,同时用 GPU 提高训练速度。AlexNet 的基本架构与 LeNet 相似,但其具有更深的网络结构。实验在 ImageNet 数据集上预训练的 AlexNet 中输入尺寸为 $227 \text{ pixel} \times 227 \text{ pixel}$ 的失真图像,3 为图像的深度,对模拟的 401 类失真图像进行分类。在最后一层得到输入畸变图像对应的径向畸变系数 k_1 。再根据 k_1 、 k_2 之间的函数关系得到 k_2 ,从而得到径向畸变双参数的估计值,实现图像的畸变校正。

5 实验结果与分析

5.1 模型训练结果与分析

实验模型代码的编写和训练环境:显卡为 Geforce RTX2080 Ti,软件为 Matlab2018b,系统为 Windows10。由于本方法是一个分类模型,因此从分类的准确率和损失率评价模型的性能。图 5 为相同条件下分别使用自适应矩估计 (Adam) 算法和引入一阶动量的随机梯度下降 (SGDM) 算法的测试集准确率。可以发现,采用 Adam 算法时,模型的测试集准确率可达到 84.8%,相比 SGDM 算法,提高了 6.8%,且使用 SGDM 算法时出现了震荡现象。图 6 为相同条件下,分别用 Adam 和 SGDM 算法的测试集损失率。损失率是指模型在训练过程中的学习效果,损失率越小,曲线越收敛,表明学习的效果越好。可以发现,Adam 算法的曲线收敛情况更好,损失率更低,约为 0.5,这表明本模型可以有效地学习径向畸变的相关特征。

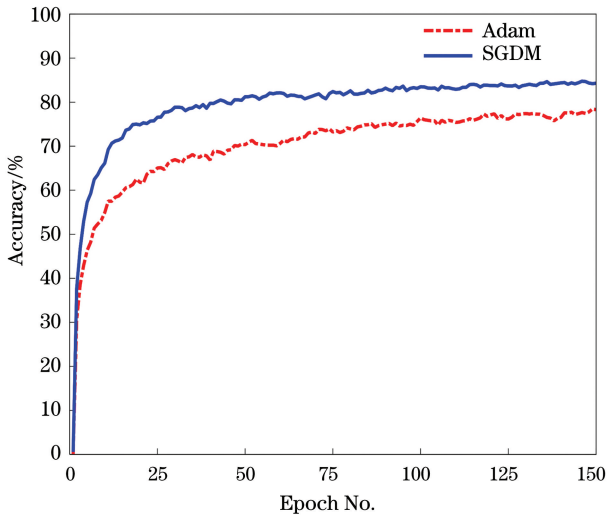


图 5 两种算法在测试集上的准确率

Fig. 5 Accuracy of the two algorithms on the test set

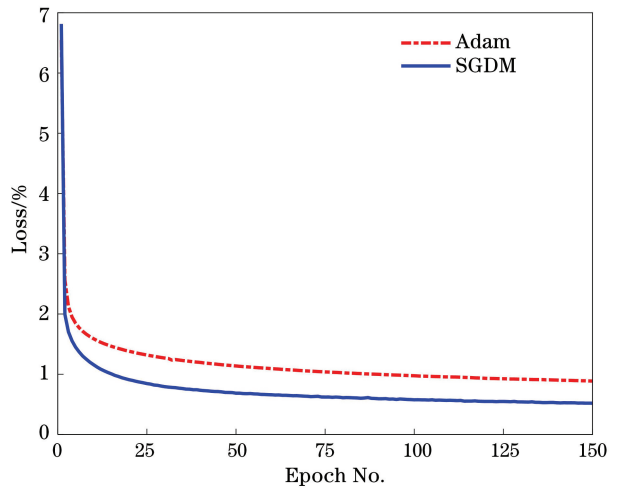


图 6 两种算法在测试集上的损失率

Fig. 6 Loss rate of the two algorithms on the test set

5.2 畸变校正性能分析

5.2.1 畸变校正的评价指标

为了更直观地验证本方法的有效性和可靠性,在 Matlab2018b 环境下用训练好的 CNN 模型分别对棋盘格仿真图像和真实棋盘格标定图像进行实验,用均方根误差 (RMSE) 衡量预测结果的好坏, RMSE 可表示为

$$f_{\text{RMSE}} = \sqrt{\frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [(x'_{ij} - x_{ij})^2 + (y'_{ij} - y_{ij})^2]}, \quad (7)$$

式中, (x_{ij}, y_{ij}) 、 (x'_{ij}, y'_{ij}) 分别为原始无畸变图像的真实坐标和矫正后图像的理想坐标, m 、 n 分别为横、纵方向提取的特征点 (棋盘格的角点坐标) 个数。

5.2.2 畸变校正性能

图 7 为仿真的标准图像和畸变图像,首先用标准棋盘格图像生成 50 张不同分辨率的原始棋盘格图像。实验考虑的图像畸变中心为图像中心,按照上文中给出的畸变图像合成方法,在径向畸变系数 $k_1 = -0.004$ 、 $k_2 = -6.312 \times 10^{-5}$ 时合成棋盘格的失真图像。




图 7 仿真图像。(a) 标准图像; (b) 畸变图像

Fig. 7 Simulation image. (a) Standard image;

(b) distorted image

图 8 为 50 次随机实验得到校正后的仿真棋盘格图像角点坐标与无畸变图像角点坐标的 RMSE, 可以发现, 50 次随机实验得到的角点坐标 RMSE 基本在 1 pixel 以内, 这表明本方法求解的稳定性较




图 8 50 次随机实验得到的角点坐标 RMSE

Fig. 8 RMSE of corner coordinates obtained from 50 random experiments

好, 也证明了实验中训练模型的有效性。

用液晶显示器上生成的棋盘格图像进行实物实验, 使用的棋盘格标定板实际尺寸为 $28.5 \text{ mm} \times 28.5 \text{ mm}$ 。采集了 20 张带有畸变的棋盘格图像预处理后输入训练好的模型, 本方法和张正友标定法^[4]校正后的图像如图 9 所示。可以发现, 本方法的校正效果比较明显。由于仿真的畸变图像是按照训练集生成的, 仅包含径向畸变, 而真实畸变图像中虽然径向畸变占主导地位, 但仍然存在偏心畸变, 如薄棱镜畸变, 会对实验效果造成影响, 因此, 对仿真畸变图像的校正效果好于对真实畸变图像的校正效果。

图 10 为 20 张带有畸变的真实棋盘格图像通过两种方法校正后图像角点坐标的 f_{RMSE} 。可以看出, 以张正友方法为基准, 畸变图像通过本模型的校正后, 除了 1 组角点的 f_{RMSE} 与未校正图像相比无明显变化, 其余图像角点的 f_{RMSE} 均小于 1.5 pixel, 且集中在 1 pixel 左右, 这也验证了本方法的有效性。

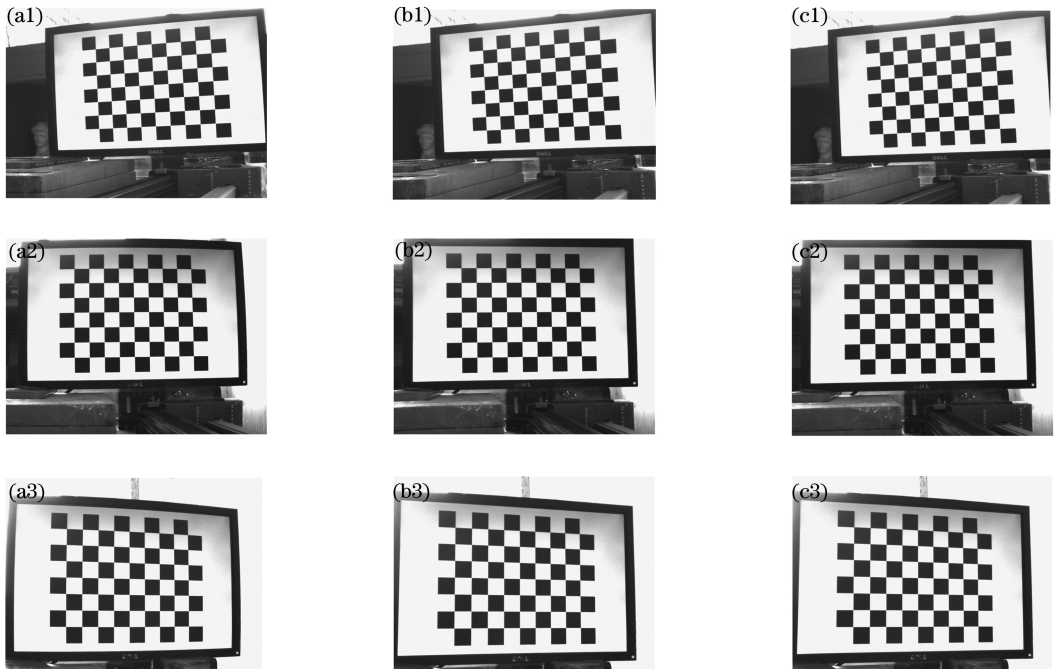


图 9 真实棋盘格图像的实验结果。(a)畸变图像;(b)文献[4]校正后的图像;(c)本方法校正后的图像

Fig. 9 Experimental results of real checkerboard images. (a) Distorted image; (b) image corrected by Ref. [4]; (c) image corrected by our method

为了证明(5)式的适用性及本方法在大畸变环境下的可行性, 在 HTC One M9+ 广角镜头拍摄的图像上用本方法进行畸变校正, 结果如图 11 所示。可以发现, 当图像包含的直线较多时, 如

图 11(a1)~图 11(a3), 本方法具有良好的校正性能; 同时, 在包含直线较少的图像上进行测试, 如图 11(a4), 进一步验证了本方法的畸变校正性能。




图 10 真实棋盘格图像均方根误差

Fig. 10 RMSE of real chessboard image



图 11 广角镜头的校正效果。(a)畸变图像;

(b)用本方法校正后的图像

Fig. 11 Correction effect of wide-angle lens. (a) Distorted image; (b) image corrected by our method

6 结 论

在考虑第一、第二阶径向畸变的畸变模型中,提出了一种基于 CNN 的图像畸变校正方法。人工合成带有第一、第二阶径向畸变系数标记的图像,并用其在 AlexNet 上进行迁移学习,得到分类精度达到 84.8% 模型;通过一种细分类方法,增加了相邻分类标签之间的强相关性,以张正友标定法为基准,本方法的校正误差在 1 pixel 左右。实验结果表明,本方

法能在包含直线较少的图像上进行畸变校正,可在工业相机和广角镜头拍摄的图像上实现畸变校正,但需要大量带有畸变系数标记的畸变图像做支撑;且当畸变较大、径向变形超出模型的覆盖范围时,畸变校正能力会受到影响。在今后的研究中,还需探索如何将本方法扩展到更复杂的模型中及如何提高模型的精度。

参 考 文 献

- [1] Bai F Z. Fundamentals of visual measurement technology [M]. Beijing: Publishing House of Electronics industry, 2013: 15-24.
白福忠. 视觉测量技术基础[M]. 北京: 电子工业出版社, 2013: 15-24.
- [2] Quan Y M, Qin Z B, Li W S, et al. Multi-camera calibration of one-dimensional calibration objects based on normalization algorithm [J]. Acta Optica Sinica, 2019, 39(4): 0415001.
全燕鸣, 覃镇波, 李维诗, 等. 基于归一化算法的一维标定物多相机标定 [J]. 光学学报, 2019, 39(4): 0415001.
- [3] Tsai R. A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses [J]. IEEE Journal on Robotics and Automation, 1987, 3(4): 323-344.
- [4] Zhang Z. A flexible new technique for camera calibration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330-1334.
- [5] Yang Q, Li T W, Huang Q, et al. Lens distortion correction method based on linear projection features [J]. Computer Measurement & Control, 2018, 26(9): 264-268.
杨麒, 李天伟, 黄谦, 等. 基于直线投影特征的镜头畸变校正方法 [J]. 计算机测量与控制, 2018, 26(9): 264-268.
- [6] Wang A Q, Qiu T S, Shao L T. A simple method of radial distortion correction with centre of distortion estimation [J]. Journal of Mathematical Imaging and Vision, 2009, 35(3): 165-172.
- [7] Ma S D. A self-calibration technique for active visionsystems [J]. IEEE Transactions on Robotics and Automation, 1996, 12(1): 114-120.
- [8] Pei M T, Jia Y D. Linear self-calibration technique based on active vision [J]. Transactions of Beijing Institute of Technology, 2006, 26(1): 27-30, 35.

- 裴明涛, 贾云得. 基于主动视觉的摄像机线性自标定方法[J]. 北京理工大学学报, 2006, 26(1): 27-30, 35.
- [9] Qi Z S, Wang Z, Huang J H, et al. Research on system calibration of structured-light measurement based on neural network[J]. Acta Photonica Sinica, 2016, 45(5): 0512002.
齐召帅, 王昭, 黄军辉, 等. 基于神经网络的结构光系统标定[J]. 光子学报, 2016, 45(5): 0512002.
- [10] Xiang P, Zhou B, Zhu Y K, et al. Camera calibration based on deep neural network in complex environments[J]. Laser & Optoelectronics Progress, 2019, 56(11): 111505.
向鹏, 周宾, 祝仰坤, 等. 复杂环境下基于深度神经网络的摄像机标定[J]. 激光与光电子学进展, 2019, 56(11): 111505.
- [11] Jiang X K, Fan Y Q, Wang W. BP neural network camera calibration based on particle swarm optimization genetic algorithm[J]. Journal of Frontiers of Computer Science & Technology, 2014, 8(10): 1254-1262.
江祥奎, 范永青, 王婉. 基于粒子群遗传算法的BP神经网络摄像机标定[J]. 计算机科学与探索, 2014, 8(10): 1254-1262.
- [12] Workman S, Greenwell C, Zhai M H, et al. DEEPFOCAL: a method for direct focal length estimation[C]//2015 IEEE International Conference on Image Processing (ICIP), September 27-30, 2015, Quebec City, Canada. New York: IEEE, 2015: 1369-1373.
- [13] Hold-Geoffroy Y, Sunkavalli K, Eisenmann J, et al. A perceptual measure for deep single image camera calibration [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 2354-2363.
- [14] Li X Y, Zhang B, Sander P V, et al. Blind geometric distortion correction on images through deep learning [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 4850-4859.
- [15] Alemán-Flores M, Alvarez L, Gomez L, et al. Line detection in images showing significant lens distortion and application to distortion correction[J]. Pattern Recognition Letters, 2014, 36: 261-271.
- [16] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database [C] // 2009 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 248-255.
- [17] Yu J, Chen C, Gao N, et al. Camera calibration based on phase target[J]. Laser & Optoelectronics Progress, 2018, 55(11): 111203.
于瑾, 陈超, 高楠, 等. 基于相位标靶的相机标定[J]. 激光与光电子学进展, 2018, 55(11): 111203.
- [18] Sun Q, Wang X Y, Xu J P, et al. Camera self-calibration with lens distortion[J]. Optik-International Journal for Light and Electron Optics, 2016, 127(10): 4506-4513.
- [19] Brown D C. Close-range camera calibration [J]. Photogrammetric Engineering & Remote Sensing, 1971, 37(8): 855-866.
- [20] Tsai R. An efficient and accurate camera calibration technique for 3D machine vision[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, June 22-26, 1986, Miami, FL, USA. New York: IEEE, 1986: 364-374.
- [21] López M, Marí R, Gargallo P, et al. Deep single image camera calibration with radial distortion[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 11809-11817.
- [22] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [23] Krizhevsky A, Sutskever I, Hinton G E, et al. ImageNet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems 25 (NIPS 2012), December 3-6, 2012, Lake Tahoe, Nevada, United States. Canada: NIPS, 2012, 141, 1097-1105.