

doi: 10.11823/j.issn.1674-5795.2025.04.12

基于十字标定块的卷积神经网络镜头角度标定方法

唐梓潇^{1#}, 王若彤^{2#}, 雷庆春^{3*}

(1. 宁波诺丁汉大学 电子电气工程学院, 浙江 宁波 315100;

2. 宁波诺丁汉大学 航空航天工程学院, 浙江 宁波 315100;

3. 西北工业大学 动力与能源学院, 陕西 西安 710129)

摘要: 基于层析技术的三维燃烧诊断需要利用多个方向的火焰图像进行三维重建, 镜头角度标定的准确性直接影响重建质量和精度, 为降低角度标定误差, 提出基于十字标定块的卷积神经网络(Convolutional Neural Network, CNN)镜头角度标定方法。设计新型十字标定块, 与传统标定块相比, 其具有更复杂的空间结构特征, 能够提升图像在旋转过程中的几何信息差异, 有助于CNN更准确地提取角度特征, 降低训练集中的角度标签误差。搭建基于残差神经网络(Residual Neural Network, ResNet)架构的CNN进行角度预测, 并基于开源框架PyTorch实现CNN训练, 避免了人工特征设计。开展实验对基于十字标定块的CNN镜头角度标定方法的应用效果进行验证, 结果表明: 采用传统三棱柱标定块进行镜头角度标定时, 角度标签误差较大, 导致镜头角度标定准确性较低; 采用十字标定块进行镜头角度标定时, 模型训练过程中损失函数收敛更快, 镜头角度标定准确性更高。基于十字标定块的卷积神经网络镜头角度标定方法展现出更高的鲁棒性与更强的泛化能力, 为提升燃烧图像重建准确性提供了技术支撑。

关键词: 三维测量; 十字标定块; 镜头角度; 标定误差; 卷积神经网络

中图分类号: TB922; TP183 **文献标志码:** A **文章编号:** 1674-5795 (2025) 04-0158-09

Convolutional neural network lens angle calibration method based on cross calibration block

TANG Zixiao^{1#}, WANG Ruotong^{2#}, LEI Qingchun^{3*}

(1. School of Electric and electronic engineering, University of Nottingham Ningbo China, Ningbo 315100, China;

2. School of Aerospace engineering, University of Nottingham Ningbo China, Ningbo 315100, China;

3. School of Power and Energy, Northwestern Polytechnical University, Xi'an 710129, China)

Abstract: Three-dimensional combustion diagnosis based on tomography technology requires the use of flame images in multiple directions for three-dimensional reconstruction. The accuracy of lens angle calibration directly affects the quality and precision of reconstruction. In order to reduce the error of angle calibration, a Convolutional Neural Network (CNN) lens angle calibration method based on cross calibration block is proposed. A new cross calibration block was designed. Compared with the traditional calibration block, it has more complex spatial structure characteristics, which can enhance the geometric information difference of the image during rotation, help CNN to extract angle features more accurately, and

收稿日期: 2025-04-14; 修回日期: 2025-06-03

基金项目: 国家财政稳定支持项目(GJCZ-0202-04)

引用格式: 唐梓潇, 王若彤, 雷庆春. 基于十字标定块的卷积神经网络镜头角度标定方法[J]. 计测技术, 2025, 45(4): 158-166.

Citation: TANG Z X, WANG R T, LEI Q C. Convolutional neural network lens angle calibration method based on cross calibration block[J]. Metrology & Measurement Technology, 2025, 45(4): 158-166.



reduce the angle label error in the training set. A CNN based on the Residual Neural Network (ResNet) architecture was built for angle prediction, and CNN training was implemented based on the open-source framework PyTorch to avoid artificial feature design. Experiments were conducted to verify the application effect of the CNN lens angle calibration method based on the cross calibration block. The results show that when the traditional triangular prism calibration block is used for lens angle calibration, the angle label error is large, resulting in low accuracy of lens angle calibration; when the cross calibration block is used for lens angle calibration, the loss function converges faster during model training and the accuracy of lens angle calibration is higher. The convolutional neural network lens angle calibration method based on the cross calibration block shows higher robustness and stronger generalization ability, providing technical support for improving the accuracy of combustion image reconstruction.

Key words: 3D measurement; cross calibration block; lens angle; calibration error; convolutional neural network

0 引言

在燃烧诊断研究中,三维成像测量技术能够在空间和时间维度上同步获取火焰的关键气热参数,为深入解析燃烧过程中的复杂物理现象提供有力支持^[1-3]。通过三维成像测量技术,能够更全面地探究燃烧过程中的多维度特征,为燃烧优化和相关工程应用提供重要参考。层析测量技术作为实现三维测量的重要手段之一^[4-6],近年来在火焰诊断领域得到了广泛应用。层析测量技术本质上是一种复原退化图像的技术,其利用三维实体在多个角度的投影图像,反推三维实体的空间信息,重建精度随使用的投影角度数量的增多而提高。由于测量结果可以清晰地展示三维实体的任意断层,层析测量技术也被称为断层扫描技术。研究人员已基于层析测量技术实现了温度场^[7]、中间自由基^[8-9]、烟灰体积分数^[10]、火焰结构^[7, 11]及速度场^[12]的高分辨率三维成像。

层析测量燃烧场时,首先需要同步采集不同视角下的火焰二维图像,再根据成像原理建立空间点与二维像素点的一一映射关系,结合重建算法得到火焰的三维结构,最后对重建结果进行分析。层析测量燃烧场涉及2个核心环节:①多相机标定;②结合多视角测量数据进行断层重建。多相机标定的精度直接影响燃烧场测量的准确性,尽管已有研究人员尝试利用深度学习技术实现免标定的层析测量^[13],但在实际复杂燃烧场测量中,仍需进一步验证该方法的有效性。

目前,最常用的相机标定方法为:通过分析

已知特征(如棋盘格或圆形阵列)的二维标定板在不同视角下的畸变来完成标定^[14-15]。然而,该方法存在一定局限性,当镜头从不同角度观察平面标定板时,部分镜头的视角可能受限,导致成像质量不佳,进而影响标定精度。例如,当镜头以较小的人射角度拍摄标定板时,图像可能会出现严重失焦。为应对这一问题,研究人员提出了旋转标定板方案^[16-17],使标定板围绕固定轴旋转,以确保每个镜头均能获取高质量的标定图像。然而,该方法需要使用额外的旋转装置,难以在空间受限的燃烧环境测量中应用。

角度标定的核心是利用相机在不同角度拍摄棋盘格图像,并应用标定算法计算相机相对目标的角度。从图像处理的角度分析,角度标定本质上属于图像特征提取过程,相应的角度标定算法可视为特征提取器。过去十年,得益于计算能力的提升和大规模数据获取的便利化,CNN已成为主流的图像特征提取方法,并广泛应用于深度学习等领域^[18]。SHAVIT Y等人^[19]系统总结了深度学习在相机姿态估计中的应用发展脉络,论述了其在标定任务中的潜力与应用趋势。与传统的特征提取算法相比,CNN无需人为设计算法结构,而是通过训练实现自主学习并优化模型权重^[20]。已有研究人员将CNN应用于相机姿态估计与角度标定任务,显著提升了相机测量系统对于光照变化与视角变化的适应性^[21],但该研究中所使用的标定块为传统标定块,对画面清晰度要求较高,难以应用于复杂成像条件下的镜头角度标定。

传统标定块包括平面结构标定块、多面体结

构(如正四面体、六棱柱等)标定块及非对称结构(通过结构或图案打破对称性)标定块。平面结构标定块加工简单,但对其进行大视角拍摄时容易出现失焦问题;多面体结构标定块虽具备多角度特征,但其结构复杂,加工精度要求高,且部分视角下存在图像相似性过高的问题,限制了图像特征差异度;非对称结构标定块通常需要配合高精度旋转平台或其他辅助结构使用,实用性有限^[22]。

针对上述问题,本文提出基于十字标定块的CNN镜头角度标定方法,所设计的新型十字标定块不仅便于制造和部署,而且在视觉特征提取方面具有显著优势,有助于CNN更准确地提取角度

特征信息。搭建基于ResNet架构的CNN并进行角度预测,分别采用传统三棱柱标定块和十字标定块开展镜头角度标定实验,验证基于十字标定块的CNN镜头角度标定方法的准确性。

1 CNN结构

ResNet是一种经典的深层卷积网络,通过引入残差连接,有效缓解了深层网络中的梯度消失问题,使网络计算性能更优^[23]。本研究所用的CNN基本框架如图1所示,其源于ImageNet图像集^[24]上预训练过的ResNet网络。待训练的指标是镜头角度数值,数据集通过CNN结构中的全局平均池化后,将最后一层展平为一维数值。




图1 CNN基本框架

Fig.1 Basic framework of CNN

2 CNN训练方法

训练过程涉及各层参数的优化,使CNN能够

根据输入的投影图像预测相应的相机镜头角度。该问题本质上属于回归任务,目标是在训练过程中最小化网络预测角度值 $\hat{y}$ 与真实角度值 y 之间的误差。

训练过程中, 损失函数 l_{loss} 的计算公式为

$$l_{\text{loss}} = \frac{(\hat{o} - o)^2}{n} \quad (1)$$

式中: $\hat{o}$ 为预测角度均值, o 为真实角度均值, n 为批次大小。

采用均方误差 (Mean Squared Error, MSE) 衡量预测结果与真实值之间的偏差, 其基本形式为

$$J(\theta_0, \theta_1, \theta_2, \dots, \theta_n) = \frac{1}{m} \sum_{j=0}^m (\hat{y}_j - y_j)^2 \quad (2)$$

式中: J 为全局损失函数; $\theta_0, \theta_1, \theta_2, \dots, \theta_n$ 为模型参数; m 为总样本数; $\hat{y}_j$ 和 y_j 分别为训练集样本中第 j 个图像的角度预测值和真实值。设定 MSE 作为优化的目标函数后, 运用梯度下降法对 $\theta_0, \theta_1, \theta_2, \dots, \theta_n$ 进行更新, 公式为

$$\theta_i \leftarrow \theta_i - \alpha \frac{\partial}{\partial \theta_i} J(\theta_0, \theta_1, \dots, \theta_n) \quad (3)$$

式中: θ_i 为神经网络中的第 i 个可训练参数; α 为学习率, 即参数更新时的步长。

然而, 标准梯度下降法存在以下 2 方面不足: ①若 α 过小, 优化过程收敛速度较慢; 若 α 过大, 则可能导致损失函数在极值附近震荡, 甚至无法收敛; ②梯度下降法的优化结果通常为局部极小值, 由于损失函数的非凸性, 不同的参数初始化可能导致优化过程收敛至不同的局部极小点, 无法保证获得全局最优解。

为解决上述问题, 本研究采用基于梯度下降 (Adaptive Moment Estimation, Adam) 的自适应估计优化算法^[25], 数学公式为

$$g_t = \nabla J(\theta_t) \quad (4)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (5)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (6)$$

式中: g_t 为损失函数第 t 轮迭代时的梯度, θ_t 为第 t 轮迭代时的模型参数, m_t 和 v_t 分别为迭代前梯度的一阶动量和二阶动量, β_1 和 β_2 分别为相应的指数加权平均参数。对梯度与梯度平方进行滑动平均, 使每次参数更新均与过去的参数相关。

在迭代的初始阶段, m_t 和 v_t 有着向 0 初始值偏差, 需要进行偏差校正, 公式为

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (7)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (8)$$

式中: $\hat{m}_t$ 为一阶动量的偏差校正估计, $\hat{v}_t$ 为二阶动量的偏差校正估计。随着 t 的增加, $1 - \beta_1^t$ 和 $1 - \beta_2^t$ 均逐渐趋向于常数值 1, 完成偏置校正的工作。最后对模型参数进行更新, 公式为

$$\theta_{t+1} = \theta_t - \hat{m}_t \cdot \frac{\eta}{\sqrt{\hat{v}_t} + \varepsilon} \quad (9)$$

式中: η 为模型参数更新的步长; ε 为预设常数, 一般有 $\varepsilon = 10^{-8}$ 。在训练过程中, 学习率 $\eta / (\sqrt{\hat{v}_t} + \varepsilon)$ 会自适应梯度变化, 且参数更新的方向是过去总共 $1 / (1 - \beta_1)$ 轮迭代的平均梯度。

3 镜头角度标定

在数据采集前, 需要对所有相机进行预调整, 使相机至旋转台中轴线的距离保持一致。为了提高训练数据的有效性, 并防止 CNN 提取与角度信息无关的特征, 拍摄的投影图像区域应大小相近, 且各投影图像的中心点应对齐测量区域的固定位置。具体操作流程: ①根据相机拍摄的九宫格标定图像, 计算每个镜头的中心点位置; ②调整镜头位置, 使其中心点与标定块上的固定标点对齐 (如图 2 所示); ③进一步调整各镜头, 使其至待测区域中心轴的距离相等。

完成上述位置标定后, 启动旋转台, 以恒定




图 2 调节镜头至测量区域中心

Fig.2 Adjusting the lens to the center of the measurement area

转速驱动三棱柱标定块进行匀速旋转。使用高速相机,在20 Frame/s拍摄频率和10 ms曝光时间条件下,通过九探头光纤束对测量区域进行连续拍摄。每个光纤束镜头均获得了不同角度下的投影图像,并且相邻图像帧对应的旋转角度增量保持恒定。图3展示了某一镜头在特定时刻拍摄的三棱柱标定块图像。该图像的右侧图案经过特定修改,使得整体标定块不再呈左右对称结构。




图3 改进的三棱柱标定块投影图像

Fig.3 Projected image of the improved triangular prism calibration block

为了使CNN能够正确识别输入图像对应的镜头角度,首先需要对标定块训练集中每张图像的角度进行标定,并以此作为角度标签训练CNN。然而,旋转台的转速受载重影响,导致理论计算的相邻帧角度增量并不精确,无法直接用于角度标定。因此,设定相机拍摄的总时间,待拍摄完成后,统计总图像数,并通过固定的相机拍摄频率计算相邻帧的角度变化量,并需根据基准图像角度进行累积计算。初步选定三棱柱标定块的正面投影作为基准图像,设定其角度值为 90° 。然而,由于高速相机的高帧率特性,标定块处于基准位置时,其投影变化梯度较小,导致连续多帧图像近似于正面投影,进而引入 $\pm 2.5^\circ$ 的误差。

为解决上述问题,设计了十字标定块,如图4所示。十字标定块的A面与B面分别贴有不同形状的棋盘格图案(如图5、图6所示),以消除左右对

称性,防止CNN将关于中轴线对称的两个角度错误地识别为相等。十字标定块中新增的垂直棱结构增强了基准角 90° 附近的投影差异,使不同角度图像的辨识度更高,从而提升CNN的角度特征提取能力。




图4 十字标定块模型

Fig.4 Cross calibration block model




图5 A面棋盘格图案

Fig.5 A side checkerboard pattern




图6 B面棋盘格图案

Fig.6 B side checkerboard pattern

确定十字标定块旋转至4个特定角度(见图7)时的图像帧编号(a, b, c, d), 其对应的镜头水平方位角 Y_{yaw} 分别为 180° 、 90° 、 0° 、 -90° 。由于相邻图像帧的角度增量恒定, 可根据转台转速反推其中3个角度(a, b, d)对应的 $Y_{\text{yaw}} = 0^\circ$ 时的帧编号(a', b', d'), 并与 $Y_{\text{yaw}} = 0^\circ$ 时的原始帧编号 c 联立, 取其均值 $\text{Mean}(a', b', c, d')$ 作为最终的 $Y_{\text{yaw}} = 0^\circ$ 基准图像帧编号。最终, 根据相邻帧的角度增量依次计算所有图像的角度标签。




图7 十字标定块标定俯视图

Fig.7 Top view of calibration using cross calibration block

经过位置调节与拍摄步骤, 每个镜头均获取了方位角 $10^\circ \sim 180^\circ$ 的十字标定块投影图像, 并附带其对应的角度标签。为验证 CNN 的角度预测精度, 随机选择 8 号镜头所拍摄的各角度投影图像, 并将其作为测试集, 而其余 8 个镜头的图像作为训练集。随后, 进行数据增强(主要包括图像旋转、仿射变换、随机裁剪、亮度与对比度扰动等, 以模拟不同成像条件下的输入变化, 提升模型的泛化能力)和正则化等预处理。考虑到角度标定任务对几何特征敏感, 所有增强操作均保持几何一致性, 确保关键结构不被破坏。训练阶段采用逐批随机打乱方式(shuffle per epoch), 在每一轮训练开始前对整个图像序列进行索引随机化, 以提升数据集的鲁棒性。

在实际训练过程中, 模型的损失函数在初始阶段常出现明显波动, 主要由以下因素引起: ① 输入样本中视角、亮度或结构信息差异较大, 导致特征提取阶段输出分布不稳定; ② 预测任务中角度误差对损失值变化较为敏感, 使得少量高误差样本容易主导梯度方向, 进而造成训练震荡。

4 实验及结果分析

基于开源框架 PyTorch 实现 CNN 训练, 整体训练流程如图 8 所示。该流程的核心思路是基于批量梯度下降, 并采用 Adam 优化器进行优化。初始学习率设为 10^{-4} , 在训练过程中随训练轮次自适应调整, 以确保目标函数更稳定地收敛。训练过程中记录损失函数的收敛曲线(如图 9 所示), 当损失函数趋于稳定后终止训练。




图8 CNN 训练流程

Fig.8 CNN training process

为了验证改进后的十字标定块相较三棱柱标定块的性能优势, 设置 2 组测试集开展实验, 以评估不同标定块在角度预测任务中的表现。2 组测试集分别为: ① 相机从 $-40^\circ \sim 130^\circ$ 连续拍摄的三棱

柱标定块投影图像；② 相机从 $10^\circ \sim 180^\circ$ 连续拍摄的十字标定块投影图像。三棱柱标定块在角度校正中的误差如图10所示，十字标定块在角度校正中的误差如图11所示。




图9 训练过程中损失函数变化情况

Fig. 9 Loss function variation during training




图10 三棱柱标定块在角度校正中的误差

Fig.10 Error of triangular prism calibration block in angle calibration




图11 十字标定块在角度校正中的误差

Fig.11 Error of cross calibration block in angle calibration

使用三棱柱标定块的投影图像作为训练集时，得到的角度标定误差较大，尤其是在方位角 0° 附近，误差接近 5° （方法的整体误差）。产生此现象的主要原因是：当三棱柱标定块处于基准角度 0° 附近时，相机拍摄的相邻图像帧之间变化较小，导致三维标定方法及基于CNN的标定方法均无法有效区

分角度。因此，各投影图像的真实角度标定误差显著增大，训练集的稳健性降低，初始误差大约在 2.5° 以内。此外，三棱柱标定块的空间构型较为均匀，导致其在旋转过程中未能为CNN提供足够的图像分辨力，进一步增加了角度标定误差。

使用十字标定块图像作为训练集有效改善了上述问题。训练集的角度标定误差降低至约 1° 。在旋转台转动过程中，与三棱柱标定块相比，十字标定块产生的图像变化幅度更大，如图12所示。




图12 十字标定块旋转变化情况

Fig. 12 Rotation variation of the cross calibration block

本实验中，基于十字标定块的CNN镜头角度标定平均误差约为 $\pm 0.8^\circ$ 。训练集使用了8个不同镜头拍摄的图像，每个镜头的图像集在真实值标定时存在 $\leq 1^\circ$ 的初始偏差，该偏差在网络训练过程中始终存在，且无法通过增加训练轮次消除。在此偏差的影响下，基于十字标定块的CNN镜头角度标定方法仍实现了较高精度的标定。

5 结论

设计了新型十字标定块并提出了配套的CNN标定方法，有效解决了传统三棱柱标定块在旋转过程中特征区分度不足的问题。实验结果表明：十字标定块的复杂几何特征使训练集的角度标签误差明显降低，显著提升了镜头角度标定精度。相较传统方法，基于十字标定块的CNN镜头角度标定方法展现出更强的工程适用性，所使用的基于ResNet的深度学习框架避免了人工特征设计，能够自适应补偿玻璃视窗畸变、离焦模糊等因素产生的干扰，为提升复杂条件下的镜头角度标定准确性提供了技术支撑。

然而，基于十字标定块的CNN镜头角度标定方法仍受旋转平台精度的影响，机械系统的角度

控制误差可能限制其在振动环境或狭小空间中的应用。未来将针对以下方面开展研究：①通过融合惯性测量单元^[26]构建多传感器标定系统，利用陀螺仪数据提供独立的角度参考基准；②探索基于图像序列时空连续性的自监督学习方法，实现无需依赖物理标定平台的角度标记自动生成。这些改进将进一步增强标定方法的泛化能力，使标定后的镜头能够应用于航空发动机燃烧室等动态苛刻环境中的三维诊断任务。

参考文献

- [1] JU Y, SUN W. Plasma assisted combustion: dynamics and chemistry [J]. *Progress in Energy and Combustion Science*, 2015, 48: 21–83.
- [2] ALLISON P M, FREDERICKSON K, KIRIK J W, et al. Investigation of supersonic combustion dynamics via 50 kHz CH* chemiluminescence imaging [J]. *Proceedings of the Combustion Institute*, 2017, 36(2): 2849–2856.
- [3] ROY G D, FROLOV S M, BORISOV A A, et al. Pulse detonation propulsion: challenges, current status, and future perspective [J]. *Progress in Energy and Combustion Science*, 2004, 30(6): 545–672.
- [4] ZHANG M, WANG J, JIN W, et al. Estimation of 3D flame surface density and global fuel consumption rate from 2D PLIF images of turbulent premixed flame [J]. *Combustion and Flame*, 2015, 162(5): 2087–2097.
- [5] YIP B, SCHMITT R L, LONG M B. Instantaneous three-dimensional concentration measurements in turbulent jets and flames [J]. *Optics letters*, 1988, 13(2): 96–98.
- [6] NG R, LEVOY M, BRÉDIF M, et al. Light field photography with a hand-held plenoptic camera [D]. Palo Alto: Stanford University, 2005.
- [7] CHO K Y, SATIJA A, POURPOINT T L, et al. High-repetition-rate three-dimensional OH imaging using scanned planar laser-induced fluorescence system for multiphase combustion [J]. *Applied Optics*, 2014, 53(3): 316–326.
- [8] HARKER M, HATTRELL T, LAWES M, et al. Measurements of the three-dimensional structure of flames at low turbulence [J]. *Combustion Science and Technology*, 2012, 184(10/11): 1818–1837.
- [9] ABDURAKIPOV S, DULIN V, KOZINKIN L, et al. Tomographic PIV measurements of azimuthal modes in jets issuing from circular and chevron nozzles [C]// *Proceedings of the 18th International Symposium on the Application of Laser and Imaging Techniques to Fluid Mechanics*, 2016: 4–7.
- [10] GRAUER S J, UNTERBERGER A, RITTNER A, et al. Instantaneous 3D flame imaging by background-oriented schlieren tomography [J]. *Combustion and Flame*, 2018, 196: 284–299.
- [11] ISHINO Y, HAYASHI N, ISHIKO Y, et al. Schlieren 3D-CT reconstruction of instantaneous density distributions of spark-ignited flame kernels of fuel-rich propane-air pre-mixture [C]// *Proceedings of the Heat Transfer Summer Conference*. American: American Society of Mechanical Engineers, 2016: V001T06A005.
- [12] SAMARASINGHE J, PELUSO S J, QUAY B D, et al. The three-dimensional structure of swirl-stabilized flames in a lean premixed multinozzle can combustor [J]. *Journal of Engineering for Gas Turbines and Power*, 2016, 138(3): GTP-15–1230.
- [13] HALLS B R, GORD J R, JIANG N, et al. High-speed three-dimensional tomographic measurements for combustion systems [C]// *Proceedings of the 32nd AIAA Aerodynamic Measurement Technology and Ground Testing Conference*, USA. Reston: AIAA, 2016: 4027.
- [14] RUAN C, YU T, CHEN F, et al. Experimental characterization of the spatiotemporal dynamics of a turbulent flame in a gas turbine model combustor using computed tomography of chemiluminescence [J]. *Energy*, 2019, 170: 744–751.
- [15] DEMUYNCK O, ESTEBAN O, LAZARO J L, et al. Non-homogeneous illumination correction of calibrated incoherent optical fiber bundles for image transmission purposes [C]// *2006 IEEE International Conference on Mechatronics*, Budapest, Hungary. Piscataway: IEEE, 2006: 150–153.
- [16] DEMUYNCK O. Optimized and quality improved incoherent optical fiber bundle calibration method for image transmission [C]// *Proceedings of the 8th Conference on Signal Processing*. Computational Geometry and Artificial Vision (ISCGAV'08), 2008: 73–78.
- [17] HOSSAIN M M, LU G, YAN Y. Three-dimensional reconstruction of combustion flames through optical fiber sensing and CCD imaging [C]// *2011 IEEE International Instrumentation and Measurement Technology Conference*, Hangzhou, China. Piscataway: IEEE, 2011: 1–5.

- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA. Piscataway: IEEE, 2016: 770–778.
- [19] SHAVIT Y, FERENS R. Introduction to camera pose estimation with deep learning [J]. arXiv preprint arXiv:1907.05272, 2019.
- [20] MELEKHOV I, YLIOINAS J, KANNALA J, et al. Image-based localization using hourglass networks [C]// 2017 IEEE International Conference on Computer Vision Workshops (ICCVW), Venice, Italy. Piscataway: IEEE, 2017: 879–886.
- [21] HOKMABADI I A S, AI M, MINARETZIS C, et al. Accurate and scalable contour-based camera pose estimation using deep learning with synthetic data [C]// 2023 IEEE/ION Position, Location and Navigation Symposium (PLANS), Monterey, CA, USA. Piscataway: IEEE, 2023: 1385–1393.
- [22] SALVI J, ARMANGUÉ X, BATLLE J. A comparative review of camera calibrating methods with accuracy evaluation [J]. Pattern Recognition, 2002, 35(7): 1617–1635.
- [23] LI Z, MIHAYLOVA L, YANG L. A deep learning framework for autonomous flame detection [J]. Neurocomputing, 2021, 448: 205–216.
- [24] 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 (CVPR), Miami, FL, USA. Piscataway: IEEE, 2009: 248–255.
- [25] KINGMA D P, BA J. Adam: a method for stochastic optimization [J]. arXiv preprint arXiv:14126980, 2014.
- [26] LU J, YE L, ZHANG J, et al. A new calibration method of MEMS IMU plus FOG IMU [J]. IEEE Sensors Journal, 2022, 22(9): 8728–8737.

(本文编辑: 刘圣晨)



第一作者: 唐梓潇(2004—), 男, 主要研究方向为电气工程及自动化控制。



共同第一作者: 王若彤(2004—), 女, 主要研究方向为航空航天工程。



通信作者: 雷庆春(1988—), 男, 教授, 博士, 主要研究方向为航空发动机燃烧测试与控制、发动机尾焰辐射特性测试、爆震/超音速燃烧光学诊断、计算成像技术。