

面向精密测量场景的鲁棒亚像素级光斑中心定位方法研究

孙佳鑫 葛双超 高正阳

(中北大学仪器与电子学院 太原 030051)

摘要: 在增强现实(AR)显示、激光光束校准及衍射光学元件检测等精密测量任务中,光斑中心的亚像素级定位精度对系统稳定性与可靠性具有关键影响。受限于系统像差、衍射畸变以及结构噪声等因素,传统基于模型拟合与规则提取的定位方法在复杂场景中难以实现稳健、准确的光斑中心估计。为此,构建了一种基于 U-Net 架构的光斑中心定位框架,提出自适应双通道热图监督机制,协同建模光斑中心及其扩散结构,实现对真实点扩散函数特征的精细表征。推理阶段引入基于 Hessian 矩阵的二阶差分极值检测方法,增强亚像素级峰值定位的稳定性。实验结果表明,所提出方法在真实光学数据集上误差分布集中、RMSE 达 0.413 pixel,与关键点检测模型 HRNet 及特征增强方法 FFD 相比,定位精度和稳定性均获得显著提升。

关键词: 衍射光斑;亚像素定位;光斑中心定位

中图分类号: TP183;TN249 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research on a robust sub-pixel spot center localization method oriented to precision measurement scenarios

Sun Jiaxin Ge Shuangchao Gao Zhengyang

(School of Instrument and Electronics, North University of China, Taiyuan 030051, China)

Abstract: In precision measurement tasks such as augmented reality (AR) displays, laser beam calibration, and diffractive optical element inspection, the sub-pixel localization accuracy of spot centers is critical for system stability and reliability. Conventional positioning methods based on model fitting or rule extraction struggle to achieve robust and accurate spot center estimation in complex scenarios due to system aberrations, diffraction distortions, and structural noise. To address these limitations, a U-Net-based spot center localization framework is proposed. This framework incorporates an adaptive dual-channel heatmap supervision mechanism to simultaneously model the spot center and its diffusion structure, enabling precise characterization of real-world point spread function (PSF) features. During inference, a Hessian matrix-based second-order differential extremum detection method is employed to enhance the stability of sub-pixel peak localization. Experimental results demonstrate that the proposed method exhibits a concentrated error distribution on real optical datasets, achieving an RMSE of 0.413 pixel. Compared with HRNet and FFD, the proposed method significantly improves both localization accuracy and stability.

Keywords: diffracted light spots; subpixel localization; spot center localization

0 引言

高精度的光斑中心定位是诸多成像与计量任务中的基础环节,广泛应用于光学校准、微位移测量、均匀性^[1]及衍射光学元件的结构表征^[2]。在增强现实等新兴技术中,衍射波导(例如全息光学元件^[3]或表面浮雕光栅^[4])可实现紧凑、高分辨率的视觉叠加,其中光栅参数(如周期、方向及对

准误差)的精确测量依赖于衍射光斑的亚像素级中心定位。然而,由于系统像差、衍射引起的畸变以及复杂背景噪声等因素^[5],实际观测到的光斑往往偏离理想的高斯分布,这对传统的定位方法在稳健性和准确性方面提出了严峻挑战。

类似的高精度光斑定位需求同样存在于相机标定^[6]、精密仪器校准以及航空航天系统中,包括飞机地面测试^[7]、卫星激光通信^[8]和高精度导航^[9]等任务场景。在此类应用

中,光斑中心的亚像素级定位性能直接影响整个测量链的精度边界,决定了系统的可靠性与工程可用性。因此,设计一种同时具备高精度与强鲁棒性的光斑中心定位方法,始终是该领域亟待解决的关键科学问题之一。

现有光斑中心定位方法主要可归纳为3类技术路径:1)基于灰度分布特征的统计类方法,如质心计算与灰度矩分析^[10];2)基于先验模型的拟合类方法,典型代表为高斯函数或圆模型的非线性最小二乘拟合^[11];3)基于图像变换的结构提取方法,包括频域分析与边缘检测等。上述方法在理想条件下具有较高的定位精度与计算效率,但在实际应用中面临复杂背景干扰、信噪比降低以及光斑形态偏离理想模型等问题时,往往表现出鲁棒性不足与适应性受限等缺陷。

为突破传统光斑定位方法在鲁棒性、精度与实时性方面的瓶颈,国内外研究者提出了多种改进策略。基础方法如空间灰度重心推进可在提升效率的同时保障精度^[12];改进型RANSAC圆拟合算法增强了对噪声干扰的适应能力^[13];低秩与稀疏分解技术有效分离背景干扰与目标信号^[14];面向卫星激光定位场景,针对光斑与背景重叠问题的噪声分类与拟合优化方案^[15];针对复杂成像场景,亦有结合边缘阈值判定与非线性补偿的双重误差抑制方法^[16]及基于各向异性尺度空间的粘连光斑分离策略^[17]。分解质心计算方法通过行列分解与并行流水线实现无存储质心提取^[18]。在井下低照度、高粉尘环境中,最小内接矩形与椭圆拟合方法保障了激光特征点的可靠获取^[19]。

尽管上述方法在特定场景下表现良好,但由于依赖手工特征和模型假设,其在复杂形变光斑、强噪声背景以及高精度需求下仍存在局限。针对这些不足,研究者开始利用卷积神经网络的深层特征表达能力,通过梯度优化、几何归一化等机制实现光斑精确建模与定位^[20]。多尺度特征融合结构在保持空间分辨率与结构一致性方面表现突出,有效提升了定位精度^[21]。

随着关键点检测任务对精度与鲁棒性需求的提升,基于热图回归的定位框架凭借在像素空间中保持连续响应、缓解坐标回归不稳定性优势,逐渐成为关键点定位的主流方法。Wang等^[22]的方法通过多尺度解剖热图和双向序列学习建模人体结构依赖关系;魏龙生等^[23]利用知识蒸馏将热图信息传递给回归模型并引入动态区域细化。相关方法在头颅关键点检测任务中可达到 1.39 ± 1.06 mm的平均定位误差^[24]。但这些方法仍存在明显局限:一方面,它们高度依赖人体结构先验,对于缺乏空间约束的点源或光斑检测场景适用性有限;另一方面,热图回归与动态区域细化在高噪声或低对比度环境下容易出现峰值模糊或位置偏移,难以保证亚像素级精度;此外,人体关键点数据特性与光斑成像差异较大,直接迁移方法的鲁棒性受限。因此,针对光斑特征设计高精度、鲁棒的亚像素定位方法具有重要的研究价值和实际意义。

为应对上述挑战,提出自适应双通道热图网络(adaptive dual-channel heatmap network, ADH-Net),该方法基于U-Net架构,融合双通道热图监督机制以增强关键区域梯度感知能力,并利用热图尺度与光斑物理半径的动态映射实现自适应尺度建模,从而在复杂背景下实现高精度、鲁棒的光斑中心定位。

1 方法与实验设计

现有研究中,许多方法^[25]在处理光斑时普遍假设其灰度强度符合各向同性高斯分布。然而,实际采集的光斑图像常呈非对称椭圆形,具备显著的多尺度与多方向性特征,旋转对称性假设难以准确刻画其真实结构。此外,图像中除核心散斑外,往往叠加暗电流、读出噪声及热噪声等多种背景干扰,部分图像中甚至存在多个分离光斑,导致整体结构呈现高度复杂性与非一致性。图1展示了部分光斑图像。




图1 真实环境采集的样本散斑图像

Fig. 1 Sample speckle image acquired in a real environment

图2展示了理想高斯模型与实际光斑图像之间的拟合效果对比:图2(a)为受噪声和畸变影响的实际光斑图像,图2(b)为标准各向同性高斯分布,图2(c)为二者之间的残差图。结果显示,传统模型在处理真实光斑时存在显著拟合误差,难以满足精细建模需求。




图2 实际点分布和理想点分布的残差分析

Fig. 2 Residual analysis of actual vs. ideal point distributions

为更贴近实际观测条件并提升模型对复杂光斑结构的适应性,基于各向异性高斯函数构建了模拟数据集。

1.1 模拟光斑数据集构建

采用加噪声的二维高斯模型构建各向异性光斑图像。大小设置为 $256 \text{ pixel} \times 256 \text{ pixel}$ 。通过设置不同主轴方向的标准差 ($\sigma_x \neq \sigma_y$) 与旋转角度 θ , 实现光斑在空间中的椭圆形扩展及方向控制。在图像坐标系中, 先对中心坐标进行平移和旋转变换, 再依据式(1)生成各向异性高斯分布:

$$G(x, y) = A \cdot \exp\left(-\left(\frac{X_r^2}{2\sigma_x^2} + \frac{Y_r^2}{2\sigma_y^2}\right)\right) \quad (1)$$

式中: A 为光斑幅度, σ_x 与 σ_y 分别控制主轴方向上的扩展程度, X_r 与 Y_r 为旋转变换后的坐标分量。通过调节拉伸比 $\phi = \sigma_x / \sigma_y$ 与角度 θ 。

为增强模拟图像的真实感, 将生成的光斑图像与背景图像进行线性叠加, 并引入轻微的高斯噪声模拟成像过程中的干扰。背景图像 $B(x, y)$ 设置为均匀灰度图(灰度值设定为 0.2), 叠加重重设置为 $\alpha = 0.7, \beta = 0.3$, 满足 $\alpha + \beta = 1$, 以保持图像整体亮度均衡。高斯噪声 $N(x, y)$ 满足零均值、标准差为 σ_n 的正态分布:

$$N(x, y) \sim N(0, \sigma_n^2) \quad (2)$$

最终合成图像如图 3 所示, 可表示为:

$$I(x, y) = \alpha \cdot G(x, y) + \beta \cdot B(x, y) + N(x, y) \quad (3)$$




图 3 模拟光斑的二维和三维表示

Fig. 3 2D and 3D representations of the simulated spot

1.2 自适应双通道监督策略

为实现对光斑结构的多尺度精确建模, 设计了一种基于双通道高斯热图的监督机制。其核心在于通过动态计算目标区域的等效半径 r 来实时调整两个监督通道的高斯核尺度, 从而确保热图响应与目标的实际空间尺寸保持良好的尺度一致性。

模型同时预测两个热图通道, 每个通道采用高斯函数进行定义, 但拥有不同的尺度参数, 以分别捕获目标的中心和轮廓信息: 通道 0 描述光斑中心的尖锐响应, 用于精确指导模型学习核心位置, 控制热图的局部集中度, 如式(4)所示, 采用自适应标准差 σ_{cne} 为中心通道的尺度参数, 控制中心高斯核的紧致程度; 通道 1 刻画光斑的整体能量包络, 使用相对较大的高斯核来监督模型学习目标的实际空间轮廓和范围。如式(5)所定义, 使用较大尺度的标准差 σ_{sron} 为包

络通道的尺度参数, 生成更广泛的能量包络。

$$H_{\text{center}}(x, y) = \exp\left(-\frac{(x - x_c)^2 + (y - y_c)^2}{2\sigma_{cne}^2}\right) \quad (4)$$

$$H_{\text{surround}}(x, y) = \exp\left(-\frac{(x - x_c)^2 + (y - y_c)^2}{2\sigma_{sron}^2}\right) \quad (5)$$

式中: $H_{\text{center}}(x, y)$ 和 $H_{\text{surround}}(x, y)$ 分别表示用于描绘光斑中心峰和周围峰值的二维高斯函数, 其中 (x, y) 是函数的自变量, 代表光斑所在平面的坐标点。 x_c, y_c 表示光斑中心的横、纵坐标。

“自适应”的核心是通过等效半径 r 将目标的实际物理尺寸引入到监督信号的生成中。

在训练过程中, 首先从目标区域的真实标签中, 依据显著响应区域的轮廓信息计算其面积。等效半径 r 被定义为与该目标区域面积相等的圆形区域的半径。

这意味着 r 能够动态地、准确地反映图像中当前光斑目标在像素空间中的实际空间尺度。获得等效半径 r 后, 它即被用于动态地指导两个高斯核尺度参数的生成。具体的参数调整方式如式(6)与(7)所示。

$$\sigma_{cne} = \alpha_{\text{center}} \times r \quad (6)$$

$$\sigma_{sron} = \alpha_{\text{surround}} \times r \quad (7)$$

式中: α_{center} 与 α_{surround} 为经验设置的缩放因子, 用于建立高斯核尺度与目标实际尺寸 r 之间的比例关系。设置 $\alpha_{\text{center}} \in (0, 1)$ 以确保 σ_{cne} 相对较小, 聚焦于中心点; 而 $\alpha_{\text{surround}} > \alpha_{\text{center}}$ 以确保 σ_{sron} 较大, 用于捕捉更广的能量包络。

通过将目标的空间尺寸信息 r 动态地纳入 σ 的计算, 该机制确保了无论是大尺寸还是小尺寸的光斑目标, 所生成的监督热图都能与其尺寸完美匹配, 从而有效解决了传统固定尺度高斯核在处理多尺度目标时所面临的局限性。

1.3 U-Net 定位网络

本节详细介绍 U-Net 架构及其训练流程。该网络构建于 Ronneberger 等^[26]提出的经典 U-Net 结构之上。针对点中心定位任务进行了结构性改进, 主要优化包括输入尺寸的适配、改进的卷积填充方式以及更合理的通道配置, 以提升模型的特征表达能力和高精度定位的适应性(如图 4 所示)。

鉴于原始图像分辨率高达 $2048 \text{ pixel} \times 2048 \text{ pixel}$, 直接在全图尺度上训练 U-Net 模型将导致显著的计算资源开销, 难以满足实际训练效率与硬件限制的要求。为降低资源开销并提升模型训练的可行性, 训练过程中引入如图 5 所示的局部感知建模策略, 通过在关键点邻域内构建空间约束区域, 有效缓解全图训练所引发的资源瓶颈, 并增强模型对局部结构特征的聚焦能力。

具体而言, 设高分辨率图像 $I \in \mathbf{R}^{H \times W}$, $H = W = 2048$ 。训练过程中, 以该坐标为参考, 在原图中提取空间尺寸为 256×256 的中心对齐子区域作为网络输入, 从而实现面向关键区域的高效结构建模与监督学习。

在关键点检测任务中, U-Net 网络通过生成概率热图




图 4 具有双通道热图输出的基于 U-Net 定位网络架构
Fig. 4 U-Net with dual-channel heatmap outputs




图 5 应用 U-Net 进行精确定位的训练和应用流程
Fig. 5 Training and application pipeline of U-Net for precise localization

实现关键点的空间定位,其性能依赖于卷积、反卷积(上采样)、最大池化及跳跃连接等模块的协同作用。卷积层基于局部感受野逐层提取低层次特征(如边缘与纹理),并随着网络深度的增加,逐渐捕获更具语义层次的高级特征,从而增强对关键点复杂结构的表达能力。最大池化通过下采样降低特征图空间分辨率,减轻计算负担并提升特征的平移不变性。反卷积层逐步恢复空间分辨率,同时通过跳跃连接融合编码路径的低层细节特征与解码路径的高级语义信息,确保定位结果兼具空间精度与语义表达。最终,网络通过与输入尺寸一致的卷积层输出关键点响应图,利用 Sigmoid 函数将输出归一化至 $[0,1]$ 区间,形成连续的概率分布,反映每个像素位置为关键点的置信度。

在模型训练阶段,为提升热图预测的回归性能,引入平滑 L1 损失函数(SmoothL1Loss)作为监督目标。该损失

函数在误差较小时具备均方误差的平滑特性,有利于亚像素级误差的精细拟合;在误差较大时则表现为绝对误差,增强对异常值的鲁棒性,从而有效抑制极端样本对网络训练的干扰,提升定位精度与稳定性。

此外,优化器方面采用自适应矩估计算法(Adam),能够根据一阶与二阶矩动态调整各参数的更新速率,加速模型收敛并降低对初始超参数的敏感性。

为进一步提升训练稳定性,引入余弦退火学习率调度策略(cosine annealing scheduler),在整个训练过程中实现学习率的非线性衰减,有效避免陷入局部最优并延缓过拟合的出现。该调度机制通过周期性调整学习率,引导模型在不同阶段以不同步幅探索损失空间,提升训练效率与最终模型性能。

1.4 亚像素定位

在监督机制与后处理阶段均引入了结构化的亚像素

优化设计。该方法充分利用预测热力图中中心峰通道的局部结构信息,通过二阶曲面拟合精确回归峰值坐标,实现亚像素级光斑中心定位。具体而言,模型首先在中心热力图通道中选取亮度值最大的整数像素位置 $x_0 = (x_0, y_0)$ 作为初始估计点。随后,在其 3×3 的邻域窗口内,对





图 6 基于二维高斯函数的等值线二维和三维可视化示意图

Fig. 6 2D and 3D contour visualizations based on a two-dimensional Gaussian function

2 实验与结果分析

为全面验证所提出 ADH-Net 的有效性,分别在模拟数据与实测光斑图像上开展了实验验证。实验运行环境包括:第 12 代 Intel(R)Core(TM)i9-12950HX(2.30 GHz)处理器、NVIDIA GeForce RTX3090Ti 8 GB GPU、32 GB 内存,操作系统为 Windows11 x64,软件平台为 Python3.9。

2.1 评价指标

定位精度是衡量模型性能的核心指标。针对亚像素级关键点检测任务,以预测点与真实标注点之间的欧氏距离作为误差度量标准,并采用均方根误差 (root mean square error, RMSE)对所有样本的误差进行统计分析。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N E_i^2} \quad (8)$$

式中: N 为测试样本数量; E_i 为第 i 样本的欧氏定位误差。

为系统评估模型在不同容忍度下的检测鲁棒性,引入基于欧氏距离阈值 d 的关键点评估指标。当 $E_i \leq d$ 时,判定为一次成功检测 (true positive, TP);反之,则视为错误检测。在单光斑检测场景中,漏检数量 (false negative, FN)定义为总样本数与正确检测数之差,即:

$$FN = N_{\text{total}} - TP \quad (9)$$

基于上述分类结果,采用 3 项常用性能指标——精度 (precision)、召回率 (recall) 与 F1 分数 (F1Score),对模型的检测性能进行综合评估:

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

热力图强度分布函数 $f(x, y)$ 进行二阶泰勒展开近似。

如图 6 所示,梯度仅提供方向提示,而 Hessian 矩阵封装了二阶信息,可以直接计算到局部极值的最佳调整路径。此外,它的正确性可以作为验证真实局部最大值存在的标准,从而提高定位过程的可靠性和稳定性。

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (12)$$

2.2 模拟数据实验与结果分析

为验证模型在理想条件下的定位性能与关键设计要素的有效性,首先开展基于模拟光斑数据的实验分析。

1) 模拟光斑数据的热图参数调优与消融实验

在模拟数据集上开展消融实验,重点评估所提出自适应双通道热图设计的有效性。以固定半径高斯核生成的单通道热图作为基线方案。相比之下,自适应双通道策略引入比例因子 $(\alpha_{\text{center}}, \alpha_{\text{surround}})$,可根据光斑尺寸动态调整热图的空间响应范围。实验结果 (如表 1)显示,参数配置 (0.4, 0.8) 在中心聚焦与外围感知之间实现最优平衡,使均方根误差 (RMSE) 显著下降至 0.351 pixel。

表 1 不同的热图类型和参数配置的评估 ($\sigma_n = 0.03$)

Table 1 Evaluation of heatmap types and parameters ($\sigma_n = 0.03$)

热图类型	参数配置	F1	RMSE/pixel
固定单通道 (σ)	3	0	91.713
	5	0	69.762
	7	0	81.531
自适应双通道 ($\alpha_{\text{center}}, \alpha_{\text{surround}}$)	(0.3, 0.6)	0.962	0.632
	(0.4, 0.8)	1.000	0.351
	(0.5, 1.0)	0.695	2.365

2) 模拟光斑数据的对比实验

为验证所提方法的有效性,选取代表性的通用关键点检测模型高分辨率网络 (high-resolution network, HRNet) 和快速特征检测器 (fast feature detector, FFD) 作为对比方法。所有方法均在统一的数据集、训练配置及评估指标体系下开展实验,确保对比结果的公平性与可比性。

FFD 由 Ghahremani 等^[27]于 2021 年提出,是一种基于数学优化的新型多尺度斑点检测算法,具有较高的计算效率和亚像素级的定位精度。HRNet^[28]广泛应用于人体姿态估计与关键点检测任务,且与 ADH-Net 的核心思想(热图中心回归)一致。其网络结构较深、参数量大、训练成本较高。为保证实验公平性,采用其官方实现与默认超参数配置进行对比。

同时,对 HRNet 和 FFD 均采用与 ADH-Net 一致的亚像素拟合策略,确保 3 种方法在指标上的对比公平。

如表 2 所示,HRNet 检测效果较差,主要因为采用默认配置,缺乏针对光斑特征的微调,导致关键点检测指标下降,反映出通用人体姿态估计模型在光斑定位任务中的特征不匹配与鲁棒性不足。FFD 通过模型优化取得一定性能,而 ADH-Net 在 Precision、Recall 和 F1 上均达到 1.00, RMSE 仅为 0.351 pixel,充分验证了针对光斑特征设计的网络结构及训练策略的必要性与有效性。

表 2 亚像素点定位性能比较($d=1$ 像素, $\sigma_n=0.03$)

Table 2 Comparison of subpixel localization performance ($d=1$ pixel, $\sigma_n=0.03$)

方法	Precision	Recall	F1	RMSE/pixel
FFD	0.95	0.95	0.95	1.235
HRNet	0.033 3	0.033 3	0.033 3	5.523
ADH-Net	1	1	1	0.351

2.3 实测数据实验与结果分析

为验证模型在真实光学系统下的适用性与鲁棒性,进一步基于实测图像开展光斑定位实验。

1) 实测数据集构建与预处理

实测图像由维度科技 DL-BH-CMOS-400-1100 型高分辨率光斑分析仪采集(像元尺寸 $5.5\text{ }\mu\text{m}$,波段 $400\sim1\text{ }100\text{ nm}$),实验前对系统进行了成像校准,以确保数据一致性与空间定位精度。

实验采用 LTTROW 光路配置进行图像采集,该光路是波导显示系统性能评估的典型配置。相比其他测量方式,该配置能够在保持系统稳定性与重复性的前提下,高保真地还原出射光斑的强度与形态分布,从而有效反映耦合光栅的能量一致性、衍射效率及成像均匀性。其测试结果可作为波导显示系统核心光学性能的重要评价依据。

波长为 532 nm 的连续单色激光经过分光镜,沿直线

入射至增强现实 (AR) 镜片样品中的衍射光波导结构,照射区域为其光栅耦合段,该区域为光能量输入与输出的关键节点,其结构参数直接决定了光耦合效率、出射光斑分布及波前质量,从而影响 AR 显示的亮度均匀性、成像清晰度等核心性能。衍射后的出射光束经反射再次穿过分光镜,偏转后,汇聚至光斑分析仪感光面,完成光斑图像的采集与记录过程。该光路设计兼顾了光强控制与成像清晰度,可有效还原典型使用环境中的光斑分布特性。实验系统整体结构如图 7 所示。




图 7 采集光斑图像的实验装置

Fig. 7 Experimental setup for speckle image acquisition

实验采集 500 幅真实实验图像作为样本数据,每幅图像分辨率为 $2\text{ }048\text{ pixel}\times2\text{ }048\text{ pixel}$,图像格式为 PNG。剔除了存在明显不符合质量标准的异常样本。经过清洗后的数据集共包含 443 幅高质量图像,并按 8:1:1 的比例分为训练集、验证集和测试集。

由于 PNG 格式图像采用以左上角为原点的像素坐标系(X 轴向右, Y 轴向下),而 BeamHere 系统坐标系以画布中心为原点、 X 轴向右、 Y 轴向上,二者存在方向与尺度差异。因此,在生成检测算法的监督标签时,为实现预测结果与物理坐标真值之间的空间对齐,需将 BeamHere 系统输出的物理坐标映射至图像坐标系。

给定 BeamHere 物理坐标 ($X_{\text{BH}}, Y_{\text{BH}}$) (单位为 μm),将其转换为 OpenCV 像素坐标 ($X_{\text{cv}}, Y_{\text{cv}}$),其转换关系如式(13)和(14)所示。

$$X_{\text{cv}} = \frac{W_{\text{pixels}}}{2} + \frac{X_{\text{BH}}}{S} \tag{13}$$

$$Y_{\text{cv}} = \frac{H_{\text{pixels}}}{2} - \frac{Y_{\text{BH}}}{S} \tag{14}$$

式中: W_{pixels} 和 H_{pixels} 为图像分辨率(宽度与高度,单位为 pixel); S 为像素的物理尺寸(即每像素对应的微米数,单位为 $\mu\text{m}/\text{pixel}$)。

2) 实测数据实验结果与分析

基于 ADH-Net 模型在实测数据集上的训练结果,对测试集中一组具有代表性的样本进行了可视化分析(如图 8 所示)。图 8(a)中模型预测位置(“+”)与真实光斑中

心(“×”)高度重合,直观验证了其优异的空间定位精度。图 8(b)与(c)分别展示了真实中心与预测中心的局部热力图响应,二者在形态与位置上高度一致,表明模型具备良好的特征刻画能力。图 8(d)为误差分布图,清晰描绘了预测点与真实点之间的细微偏差,进一步验证了模型在复杂背景与噪声干扰下的稳定性与鲁棒性。




图 8 图像的定位结果及误差分析

Fig. 8 Localization results and error analysis of the images

为评估模型在实测数据上的定位性能,对其亚像素级误差分布进行统计分析(如图 9)。结果显示,80%的预测误差集中于 0.5 pixel 以内,呈现显著单峰分布,表明模型具备良好的稳定性与精度。误差在 0.2~0.3 pixel 区间达到分布峰值,反映出模型定位性能尤为可靠。




图 9 模型在实测数据集上的定位误差分布直方图

Fig. 9 Histogram of localization errors on the measured dataset

图 10 清晰地展示了所提出模型在光斑中心定位任务中的卓越表现,尤其在多个精度评价指标下均取得了优异

成绩。当误差容忍阈值设定为 1 pixel 时,模型在准确率(precision)、召回率(recall)和 F1 分数 3 项指标上均达到 1.0,说明模型不仅能够实现对所有目标点的全面检测(即召回率为 1.0),而且在检测结果中几乎不存在虚警或误报(即准确率为 1.0),从而使整体性能达到最优状态。在更为严格的亚像素级误差阈值条件下,尽管准确率略有下降,召回率仍维持在较高水平。出现的轻微性能波动可能源于目标边界模糊、成像噪声干扰或预测热图中的亚像素级响应偏移。




图 10 不同阈值下定位性能指标分数统计图

Fig. 10 Performance metrics under different thresholds

该结果表明,所提出方法在满足精度与完整性的双重要求下,已具备稳定的检测能力。

3) 实测数据的热图参数调优与消融实验

基于与合成数据集一致的处理流程,在实测数据集上开展了一系列系统性的消融实验。表 3 列出了对应的均方根误差的实验结果,可以看出,自适应双通道热图在亚像素级光斑定位中表现显著优于固定单通道方案。在所有参数配置中,(0.4, 0.8)×r 的自适应方案取得最优性能,F1 分数达 1,定位误差仅为 0.413 pixel。相比之下,固定单通道配置在 F1 和定位精度上均表现较差,误差范围达数十微米,说明其对光斑尺度变化的适应性较差,难以满足高精度检测需求。

表 3 不同热图类型及参数配置的定位误差

Table 3 Localization errors of various heatmap types and parameters

热图类型	参数配置	F1	RMSE/pixel
固定单通道(σ)	3	0	36.101
	5	0.170 2	7.507
	7	0.100 4	7.759
自适应双通道 ($\alpha_{center}, \alpha_{surround}$)	(0.3, 0.6)	1	0.562
	(0.4, 0.8)	1	0.413
	(0.5, 1.0)	0.786	1.325

4) 实测数据的对比试验

进一步设计并开展了针对真实图像的对比实验,以验

证模型在实际成像条件下的泛化性能。实验设置与合成数据集保持一致。结果如表 4 所示。

表 4 亚像素点定位性能比较($d=1$ pixel)

Table 4 Subpixel localization performance($d=1$ pixel)				
方法	Precision	Recall	F1	RMSE/pixel
FFD	0.821	0.782	0.800	0.931
HRNet	0.166 7	0.166 7	0.166 7	2.307
ADH-Net	1	1	1	0.413

由表 4 可知,FFD 与 HRNet 的检测精度和定位精度均明显低于 ADH-Net,其中 FFD 的 F1 值为 0.800、RMSE 为 0.931 pixel,HRNet 的 F1 值为 0.166 7、RMSE 为 2.307 pixel,整体性能受限于固定模型假设与热图分辨率,在复杂光斑场景下鲁棒性较弱。HRNet 虽具备多分辨率特征融合优势,但其网络结构主要面向大尺度目标的人体关键点检测任务,缺乏针对小光斑特征的适配与结构优化,难以有效提取细粒度亮度特征;FFD 在此基础上虽通过特征增强模块提升了局部响应,但仍未充分考虑光斑尺度差异与噪声扰动。相比之下,ADH-Net 通过双通道热图监督实现了高置信度检测与亚像素级定位,在各项指标上均取得显著优势。

2.4 对噪声的鲁棒性评价

与实测数据相比,模拟光斑具有参数可控、可重复性强的优势,能够更准确地反映模型在噪声扰动下的稳定性。为进一步验证模型在噪声干扰下的鲁棒性,在模拟光斑数据的基础上叠加不同强度的高斯噪声,构建三组模拟样本,将 ADH-Net 分别应用于 3 种不同噪声水平的光斑图像进行测试。图 11 分别给出了对应的二维与三维亮度




图 11 不同噪声下的光斑二维与三维分布图

Fig. 11 2D and 3D spot distributions under different noise levels

分布图, σ_n 分别设为 0.03、0.05 和 0.08。可以看出,随着 σ_n 的增大,光斑的中心峰值逐渐被噪声扰动,边缘过渡区模糊加重,三维亮度曲面由平滑单峰转变为起伏不均的形态,信噪比显著下降。

为全面评估模型在不同噪声强度和精度要求下的定位性能,在欧氏距离阈值 $d=1$ 和 $d=2$ pixel 下对不同噪声强度的光斑图像进行了多阈值对比分析。其中, $d=1$ 表征严格的亚像素定位精度, $d=2$ 反映模型在较宽容条件下的鲁棒性与稳定性。ADH-Net 的性能结果如表 5 和表 6 所示。

表 5 亚像素点定位性能比较($d=1$ pixel)


Table 5 Subpixel localization performance($d=1$ pixel)				
σ_n	Precision	Recall	F1	RMSE/pixel
0.03	1	1	1	0.413
0.05	0.953	0.945	0.947	0.526
0.08	0.881	0.873	0.875	0.608

表 6 亚像素点定位性能比较($d=2$ pixel)

Table 6 Subpixel localization performance($d=2$ pixel)				
σ_n	Precision	Recall	F1	RMSE/pixel
0.03	1	1	1	0.413
0.05	1	1	1	0.453
0.08	0.998	0.998	0.998	0.523

综合表 5 和 6 的结果可知,在不同噪声强度 $\sigma_n=0.03、0.05、0.08$ 及不同欧氏距离阈值 $d=1$ 与 $d=2$ 的条件下,ADH-Net 均表现出稳定的亚像素级定位性能。当噪声较低($\sigma_n=0.03$)时,模型在两种阈值下均实现接近 100% 的 Precision 与 Recall,表明其具有较高的检测准确率与可靠性;随着噪声增大至 0.08,性能指标虽略有下降,但仍保持在较高水平,其中 RMSE 始终控制在 0.6 pixel 以内。

当评价标准由 $d=1$ 放宽至 $d=2$ pixel 时,Precision、Recall 和 F1 均出现小幅提升,但整体变化趋势一致,说明模型具有良好的定位稳定性和抗噪鲁棒性。总体而言,



ADH-Net 在多噪声、多阈值条件下均能保持高精度与一致性的光斑中心定位性能,验证了其在复杂噪声环境下的可靠性与泛化能力。

3 结 论

针对高分辨率成像中光斑中心亚像素定位的需求,提出一种融合结构建模与精细估计的鲁棒检测方法。该方法构建端到端深度神经网络框架,融合结构感知的亚像素精定位模块,显著提升特征表达能力及定位分辨率。真实光学数据集验证结果表明,与 FFD 相比,ADH-Net 在 Precision、Recall 和 F1 上均有所提升,同时均方根误差显著降低;相较于 HRNet, RMSE 由 2.31 pixel 降至 0.413 pixel,充分表明 ADH-Net 方法在强噪声背景下光斑中心高精度定位任务中的优越性。

利用增强现实(AR)光波导样品光斑开展实验,验证方法在复杂光学散射与波前畸变条件下的适应性,有效抑制光学耦合误差及波导结构畸变,优化光束耦合效率和波前调控精度。该方法具备良好的泛化能力和鲁棒性,适用于激光传输、干涉测量、高分辨成像及微纳光学器件等多种精密光学测量领域,为增强现实显示技术与高端精密测量技术的深度融合提供理论与技术支撑。

参考文献

- [1] 张晰,杨建新,陈赞,等. 反射式计量圆光栅自动检测系统的设计[J]. 电子测量技术, 2019, 42(2): 63-66.
ZHANG X, YANG J X, CHEN Y, et al. Design of an automatic measuring system for reflective metrology circular grating[J]. Electronic Measurement Technology, 2019, 42(2): 63-66.
- [2] COPELAND C R, GEIST J, MCGRAY C D, et al. Subnanometer localization accuracy in widefield optical microscopy[J]. Light: Science & Applications, 2018, 7(1): 31.
- [3] NI D W, CHENG D W, WANG Y D, et al. Design and fabrication method of holographic waveguide near-eye display with 2D eye box expansion[J]. Optics Express, 2023, 31(7): 11019-11040.
- [4] DING Y Q, YANG Q, LI Y N Q, et al. Correction: Waveguide-based augmented reality displays: Perspectives and challenges[J]. eLight, 2024, 4(1): 2.
- [5] ZHOU CH H, XIN J, LI Y N, et al. Measuring small displacements of an optical point source with digital holography [J]. Optics Express, 2023, 31(12): 19336-19346.
- [6] TRIPICCHIO P, D' AVELLA S, CAMACHO-GONZALEZ G, et al. Multi-camera extrinsic calibration for real-time tracking in large outdoor environments[J]. 2022, 11(3): 40.
- [7] CUI J SH, LI Y H, HUO J, et al. A measurement method of motion parameters in aircraft ground tests using computer vision [J]. Measurement, 2021, 174: 108985.
- [8] 王辉. 卫星激光通信信标光定位跟踪算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
WANG H. Study on the spot locating and tracking algorithm of beacon in satellite laser communications[D]. Harbin: Harbin Institute of Technology, 2021.
- [9] ZHANG L, LI M, ZHU X H, et al. Navigation path recognition between rows of fruit trees based on semantic segmentation[J]. Computers and Electronics in Agriculture, 2024, 216: 108511.
- [10] KARAPARAMBIL V C, MANJAREKAR N S, SINGRU P M. Sieve search centroiding algorithm for star sensors[J]. Sensors (Basel, Switzerland), 2023, 23(6): 3222.
- [11] 潘登,李艳丽,高东,等. 基于椭圆拟合的多光斑重叠光斑中心提取方法[J]. 光学学报, 2020, 40: 67-74.
PAN D, LI Y L, GAO D, et al. Center extraction method for multiple and overlapping faculae based on ellipse fitting [J]. Acta Optica Sinica, 2020, 40: 67-74.
- [12] 卜民众,吴国新,黄金鹏,等. 基于空间灰度重心推进的线结构光中心提取[J]. 电子测量技术, 2024, 47: 44-50.
BU M ZH, WU G X, HUANG J P, et al. Center extraction of linear structured light based on spatial gray centroid progression[J]. Electronic Measurement Technology, 2024, 47: 44-50.
- [13] 贺锋涛,郭少辉,王瑞娜,等. 背景光干扰下水下激光光斑中心定位方法研究[J]. 激光与光电子学进展, 2025, 62: 46-54.
HE F T, GUO SH H, WANG R N, et al. Underwater laser spot center positioning method under background light interference [J]. Laser & Optoelectronics Progress, 2025, 62: 46-54.
- [14] DONG ZH X, SUN X W, XU F S, et al. A low-rank and sparse decomposition-based method of improving the accuracy of sub-pixel grayscale centroid extraction for spot images[J]. IEEE Sensors Journal, 2020, 20(11): 5845-5854.
- [15] 伍煜,龙小祥,杨坚,等. 高分七号卫星足印相机激光光斑中心定位方法研究[J]. 光学学报, 2021, 41: 166-172.
WU Y, LONG X X, YANG J, et al. Laser spot center positioning method in Gaofen-7 footprint camera[J]. Acta

- Optica Sinica, 2021, 41: 166-172.
- [16] 蒋佳雯, 康杰虎, 吴斌. 激光光斑中心高精度定位补偿算法研究[J]. 激光与光电子学进展, 2021, 58: 362-367.
- JIANG J W, KANG J H, WU B. High precision positioning and compensation algorithm for laser spot center[J]. Laser & Optoelectronics Progress, 2021, 58: 362-367.
- [17] SUN J H, XIE Y X. Subpixel spot localization using multiscale anisotropic Gaussian tensor[J]. Measurement, 2023, 214: 112756.
- [18] 张旭, 段发阶, 孙广开, 等. 高轨卫星目指自准直测量光斑实时定位方法[J]. 仪器仪表学报, 2025, 46(8): 206-217.
- ZHANG X, DUAN F J, SUN G K, et al. Real-time light spot localization method for target-pointing measurement with autocollimators in high-orbit satellites[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 206-217.
- [19] 张旭辉, 沈奇峰, 杨文娟, 等. 基于三激光点标靶的掘进机机身视觉定位技术研究[J]. 电子测量与仪器学报, 2022, 36: 178-186.
- ZHANG X H, SHEN Q F, YANG W J, et al. Research on visual positioning technology of roadheader body based on three-laser-point target[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36: 178-186.
- [20] TAO K D, NGUYEN T P A, NGUYỄN D D, et al. Accurate subpixel center determination for overlapping spots[J]. 2024. DOI:10.2139/ssrn.4781072.
- [21] SEO S D, MADUSANKA N, MALEKROODI H S, et al. Accurate acupoint localization in 2D hand images: Evaluating HRNet and ResNet architectures for enhanced detection performance [J]. Current Medical Imaging, 2024, 20:e15734056315235.
- [22] WANG J D, SUN K, CHENG T H, et al. Deep high-resolution representation learning for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10): 3349-3364.
- [23] 魏龙生, 付兴朋, 李唐强, 等. 基于知识蒸馏与动态区域细化的人体姿态估计[J]. 模式识别与人工智能, 2025, 38: 164-176.
- WEI L SH, FU X P, LI T Q, et al. Human pose estimation based on knowledge distillation and dynamic region refinement[J]. Pattern Recognition and Artificial Intelligence, 2025, 38: 164-176.
- [24] CHEN J, CHE H, SUN J, et al. An automatic cephalometric landmark detection method based on heatmap regression and Monte Carlo dropout[J]. 2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society(EMBC), 2023: 1-4.
- [25] CHEN J B, CHEN M Y, WU H, et al. Distortion spot correction and center location base on deep neural network and MBAS in measuring large curvature aspheric optical element[J]. Optics Express, 2022, 30(17): 30466-30479.
- [26] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer, 2015: 234-241.
- [27] GHAHREMAMANI M, LIU Y H, TIDDEMAN B, et al. FFD: Fast feature detector[J]. IEEE Transactions on Image Processing, 2021, 30: 1153-1168.
- [28] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2019: 5686-5696.

作者简介

孙佳鑫, 硕士研究生, 主要研究方向为图像处理、仪器与测试技术等。

E-mail: sunjx621.com

葛双超(通信作者), 博士, 副教授, 研究生导师, 主要研究方向为仪器与测试技术等。

E-mail: geshch@nuc.edu.cn