

文章编号 1004-924X(2026)12-1843-13

微小圆线圈的语义分割与精密测量研究

王晓东, 侯瑞阳, 张子涵, 高昆桦, 徐 征*
(大连理工大学 机械工程学院, 辽宁 大连 116024)

摘要:微小圆线圈的尺寸与装配位姿测量是保障精密电磁类机电产品性能的重要环节,但是其伪边缘干扰和视场限制等对测量影响显著。本文提出一种融合语义分割的跨尺度精密测量方法。首先,构建了融合 Efficient Channel Attention (ECA)注意力机制与边缘增强分支的 U-Net++ 网络,实现线圈区域的鲁棒分割与粗定位;然后,在分割掩膜约束的兴趣区域内,采用 8 阶 Zernike 矩提取亚像素边缘点,并通过四视场坐标统一与 Levenberg-Marquardt (LM) 圆拟合实现线圈轮廓的高精度重建,最后,将建立的测量方法融入线圈自动装配设备进行线圈零件的自动化装配应用实验。实验结果表明,改进模型在线圈显微图像分割任务中的 Dice 系数、mIoU 和 Precision 分别达 94.95%, 90.46%, 95.27%, 体现出良好的抗干扰能力。此外,在 10 组装配实验中,上下线圈平均同轴度误差分别为 12.6 μm 和 13.3 μm , 相较其他常用方法降低了约 43%, 装配达标样本数由 3 组提高至 9 组。可见,本文提出的方法具有较好的鲁棒性和测量精度,为微小线圈组件的自动装配中的视觉引导提供了新思路。

关键词:微装配;显微视觉测量;语义分割;微小圆线圈

中图分类号: TP394.1; TH691.9 **文献标识码:** A

doi: 10.37188/OPE.20263412.1843 **CSTR:** 32169.14.OPE.20263412.1843

Semantic segmentation and precision measurement of micro circular coils

WANG Xiaodong, HOU Ruiyang, ZHANG Zihan, GAO Kunju, XU Zheng*

(School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China)

* Corresponding author, E-mail: xuzheng@dlut.edu.cn

Abstract: Measuring the dimensions and assembly pose of tiny circular coils is crucial for ensuring the performance of precision electromechanical products. However, pseudo-edge interference and field-of-view limitations significantly impact the measurement process. This paper proposed a cross-scale precision measurement method that integrated semantic segmentation. First, a U-Net++ network integrating Efficient Channel Attention (ECA) and edge enhancement branches was constructed to achieve robust segmentation and coarse localization of the coil region. Then, within the region of interest constrained by the segmentation mask, sub-pixel edge points were extracted using 8th-order Zernike moments. High-precision reconstruction of the coil contour was achieved through four-field-of-view coordinate unification and Levenberg-Marquardt (LM) circle fitting. Finally, the established measurement method was integrated into an

收稿日期: 2026-03-19; 修订日期: 2026-05-19.

基金项目: 部委基础科研计划资助项目 (No. JCKY2022203B006); 中央高校基本科研业务费资助项目 (No. DUT24LAB112)

automated coil assembly equipment for automated assembly application experiments. Experimental results show that the improved model achieves Dice coefficients, mIoU, and Precision of 94.95%, 90.46%, and 95.27%, respectively, in the coil microscopic image segmentation task, demonstrating good anti-interference capabilities. Furthermore, in 10 assembly experiments, the average coaxiality errors of the upper and lower coils were 12.6 μm and 13.3 μm , respectively, which is about 43% lower than other commonly used methods. The number of assembly samples that met the standards increased from 3 to 9. This demonstrates that the method proposed in this paper has good robustness and measurement accuracy, providing a new approach for visual guidance in the automated assembly of micro-coil components.

Key words: micro-assembly; microscopic vision measurement; semantic segmentation; micro circular coil

1 引 言

微小圆线圈是广泛应用于音圈致动器、电感传感器等机电产品中的核心部件^[1],其几何尺寸直接影响器件性能。例如,在高精度的电感式位移传感器中,线圈的尺寸、排布密度、均匀性决定了最终位置检测的分辨率;而在音圈致动器中,线圈的制造和装配误差则制约着响应速度与控制精度。受工艺所限,一些误差因素在精密圆线圈组件集成过程中是难以避免的,这会导致线圈工作磁场分布畸变、参数漂移、传感信号失真等问题,从而最终影响整机性能的稳定性^[2]。可见,对微小圆线圈的几何尺寸与装配位姿检测是保障此类产品性能的重要环节。

高精度线圈线径一般小于 100 μm ,其材质柔软易受力变形,接触式测量易对其造成损伤。显微图像测量能在避免接触损伤的前提下,将测量精度提升至微米级,满足线圈精密检测的需求^[3-4]。

细金属丝缠绕并经胶固化后的线圈零件在显微视场下内部存在密集绕线纹理与局部不均匀反光,同时线圈边界可以视为具有与绕制线径同尺寸的圆角,表现为灰度平缓过渡,导致零件区域边界不够锐利。显然,常见的图像几何特征提取方法(如梯度算子、特征点描述的匹配算法)严重依赖人工设计的微分算子与特征模板结构和参数,泛化能力与鲁棒性不足,易受到干扰,将线圈内部间隙误提取为边缘,导致测量失效,难以满足自动化装配对检测的需求^[5-6]。

基于深度学习的语义分割方法通过从标注数据中自动学习深度特征实现端到端的像素级

分割预测,在各类任务中展现出优异性能^[7-8]。现有的语义分割方法按架构可分为全卷积网络、编码器-解码器网络、多尺度与注意力机制三类:全卷积网络通过替换全连接层实现像素级预测,但其连续的下采样会导致空间细节丢失严重、分辨率受限^[9];以 U-Net 及其变体(例如 Dense U-Net, U-Net++)为代表的编码器-解码器结构通过对称的下采样编码和上采样解码路径恢复分辨率,并引入跳跃连接融合多尺度特征,从而实现在小样本条件下依然表现突出^[10-11];多尺度与注意力机制的代表是 DeepLab 的空洞空间金字塔池化和 PSPNet 的空洞池化模块等,这些方法通过并行多感受野提取特征,虽然增强了上下文感知能力,但是对计算资源要求高^[12-13]。近年来,人们进一步研究了语义分割的网络优化与小样本特征建模。例如,刘腊梅等提出的 DFNet 通过消除解码器提高了效率。刘玉等分别从双交叉注意力 Transformer 和双重聚合机制出发,增强了少样本条件下的区域表征能力^[14-16]。

然而,上述研究主要面向通用的常规尺度图像分割任务,对于显微视觉中由纹理伪边缘、灰度缓变边界及多视场拼接误差引起的几何量提取问题涉及较少^[17]。当前深度学习方法是基于统计学习范式建立的,尽管其输出结果是像素级的分类图,但从统计角度判别的像素粒度并不等同于测量精度。而通过亚像素算法可实现亚像素级定位,有望将特征提取精度提升至图像分辨率的水平^[18]。

此外,微小圆线圈具有典型的跨尺度结构特征:其整体外形处于厘米量级,而壁厚、线径等关键特征处于毫米甚至微米量级。显微视觉单次

成像难以兼顾线圈整体轮廓与局部细节分辨率,需要通过多视场采样与拼接实现测量,这就要考虑拼接过程中相机或被测对象运动误差的影响^[19-20]。

针对上述问题,本文提出了融合语义分割与亚像素拟合的跨尺度测量方法。首先,利用引入注意力机制与边缘增强分支的 U-Net++ 对线圈区域进行分割,实现目标圆弧的粗对齐;其次,在分割结果约束下,结合 Zernike 矩完成局部亚像素边缘精提取;最后,通过多视场统一与 LM 圆拟合实现线圈特征尺寸求解。通过将深度学习的强鲁棒性与亚像素定位的高精度优势相结合,为微小圆线圈的跨尺度视觉测量提供了新途径。

与已有显微视觉测量和语义分割辅助测量方法相比,本文工作的实质性改进点如下:将注意力模块、边缘增强分支和混合损失引入 U-

Net++ 以稳定获取目标线圈区域,从源头上减弱非目标边缘对后续测量的影响;将分割掩膜约束下的 Zernike 亚像素边缘与四视场坐标统一、LM 圆拟合相结合,实现线圈内圈完整圆轮廓的跨尺度重建,并在自动装配系统中验证了工程适用性。综合来看,围绕线圈跨尺度显微测量任务形成了“语义粗定位-亚像素精提取-多视场全局拟合”的完整测量链路。

2 测量方案原理与方法

2.1 测量方法基本原理

针对线圈零件的跨尺度测量的工作原理如图 1 所示:

首先,使用语义分割算法获取目标线圈圆弧所在区域;接着,基于 Zernike 矩获得亚像素轮廓点集,将点集转换到统一坐标系;最后,利用 LM 圆拟合准确获取最终的特征尺寸。




图 1 跨尺度的圆线圈高效特征提取原理

Fig. 1 Schematic of efficient cross-scale feature extraction for the target coil

2.2 分割获取目标圆弧所在区域

线圈圆弧特征提取方法的第一步就是定位到线圈圆弧特征的目标区域。本文使用改进的 U-Net++ 算法完成目标区域的分割,因为面向的是精密装配过程中的高精度测量,分割结果不

仅需要具备较好的区域识别能力,还需要尽量保留目标轮廓的边界细节以满足后续亚像素边缘提取和圆轮廓拟合的需求,结合 U-Net++ 网络的结构特点,本文从注意力机制、边缘增强分支和损失函数三个方面进行改进,如图 2 所示。




图 2 改进的 U-Net++ 语义分割模型

Fig. 2 Improved U-Net++ semantic segmentation model

2.2.1 注意力机制的选择

注意力机制能够使网络学习聚焦于目标特征并弱化非关键特征的干扰,本文在基线 U-Net++ 模型上引入 Efficient Channel Attention (ECA) 高效注意力模块^[21],结合本文所需的显微视觉测量场景,分析 U-Net++ 多层特征分布的结构:输入的浅层特征 $X^{0,0}$ 由于包含大量纹理与噪声边缘,直接施加注意力检测措施会同步增强非目标信息的干扰,放大噪声,最深层特征 $X^{4,0}$ 由于经过多次下采样后空间分辨率显著降低,使得边界细节表达能力受限,因此也不适合嵌入注意力模块。

综合考虑,本文在编码器中间尺度 $X^{1,0} \sim X^{3,0}$ 嵌入 ECA 模块,在保留边界分辨率的同时增强通道间的判别性语义响应的效果;在解码端高分辨率融合路径的结点 $X^{0,1} \sim X^{0,3}$ 后嵌入 ECA 模块,对多源特征拼接后的通道响应进行自适应重标定,从而提升边界信息在嵌套跳跃连接中的有效传递。

2.2.2 边缘增强分支

精密测量更强调对线圈目标轮廓边界的准确定位。为了增强网络对边界细节的表征能力,在网络主干上引入边缘增强分支,如图 2 所示,该分支使用 Canny 从原始图像中提取显式边缘先验特征并通过多尺度尺寸对齐与通道对齐后分别注入编码器的中间尺度特征 $X^{1,0} \sim X^{3,0}$ 以提升

模型在噪声、反光、灰度缓变等复杂成像条件下的边界鲁棒性。

原始图像经由 Canny 算子获得二值边缘图 E ,为了匹配编码器不同尺度的空间分辨率,对边缘图进行下采样尺度变换,其中 $E^{(1)}, E^{(2)}, E^{(3)}$ 分别与 $X^{1,0}, X^{2,0}, X^{3,0}$ 的空间尺寸一致:

$$E^{(k)} = \text{Resize}_k(E), \quad k \in \{1, 2, 3\}, \quad (1)$$

其中: E 为 Canny 算子提取的单通道边缘图, k 为尺度编号, $\text{Resize}_k(\cdot)$ 表示将边缘图下采样到第 k 层编码特征的空间尺寸,由于 $E^{(k)}$ 为单通道边缘图,为了与编码器特征在通道维度上对齐,引入 1×1 卷积进行映射:

$$E_c^{(k)} = \text{Conv}_{1 \times 1}(E^{(k)}; W_{1 \times 1}^{(k)}), \quad k \in \{1, 2, 3\}, \quad (2)$$

其中: W_k 为 1×1 卷积的可学习参数, $E_c^{(k)}$ 为通道对齐后的边缘特征,采用逐元素相加的方式将边缘先验与编码器特征融合,得到融合后的增强特征:

$$\tilde{X}^{k,0} = X^{k,0} \oplus E_c^{(k)}, \quad k \in \{1, 2, 3\}, \quad (3)$$

其中, $\oplus$ 表示逐元素相加。

本文选择 Canny 算子作为边缘先验提取方式,主要基于以下原因:首先, Canny 算子具有非极大值抑制和双阈值连接机制,相比 Sobel 或 Laplacian 算子响应,不易产生宽边缘和离散结构,能够较好地保持线圈边界的连续性。此外,受工艺条件所限,本文样本规模有限,若进一步引入多分支,会引起训练不稳定性,采用单一边缘先

验有利于稳定训练。

为了进一步验证边缘先验提取的合理性,在保持主干网络结构、ECA 注意力模块、混合损失函数等一致的条件下,将边缘提取方式分别设为 Sobel 和 Canny,并对相同样本开展对比实验,结果见表 1。

表 1 不同边缘先验提取方式对分割性能的影响

Tab. 1 Comparison of segmentation performance under different edge priors (%)

Edge prior	Dice	mIoU	Precision
Sobel	94.37	90.08	94.82
Canny	94.89	90.44	95.23

可见,使用 Canny 边缘先验的模型在 Dice, mIoU 和 Precision 指标上优于 Sobel 方案,说明 Canny 的非极大值抑制与双阈值连接机制更有利于保持线圈边界的连续性,抑制显微图像中由纹理和反光引起的离散伪边缘。因此,本文最终选用 Canny 作为边缘先验提取方式。

本文采用逐元素相加而非 concat 后再卷积的边缘增强分支的融合方式,一方面在保持空间对应关系的同时直接增强编码特征中的边界响应,另一方面也可以减少额外卷积计算带来的参数增长与计算开销,更符合对测量稳定性和高效性的要求。

2.2.3 损失函数优化

为兼顾分割结果的区域完整性与边界定位精度,本文构建 Dice 损失与 L1 边缘损失相结合的混合损失函数,其表达式为:

$$L_{\text{total}} = \lambda_1 L_{\text{Dice}} + \lambda_2 L_{\text{edge}}, \quad (4)$$

其中: L_{Dice} 用于约束预测区域与真实区域之间的重叠程度, L_{edge} 用于增强预测边界与真实边界之间的一致性, λ_1 和 λ_2 表示两项损失的归一化权重系数,且满足 $\lambda_1 + \lambda_2 = 1$ 。

Dice 损失采用 Soft Dice 形式,从区域重叠角度优化分割结果:

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i \in \Omega} y_i \hat{y}_i + \epsilon}{\sum_{i \in \Omega} y_i + \sum_{i \in \Omega} \hat{y}_i + \epsilon}, \quad (5)$$

其中: $y_i, \hat{y}_i$ 分别为第 i 个像素的真实标签和模型预测概率, Ω 为像素集合, ϵ 为极小常数。

引入 Sobel 梯度响应的边缘损失强化对目标

轮廓的约束。任意分割图 $M \in \{Y, \hat{Y}\}$ 的边缘响应为:

$$E(M) = \sqrt{(S_x * M)^2 + (S_y * M)^2 + \delta}, \quad (6)$$

其中: S_x 和 S_y 分别为 Sobel 水平方向和垂直方向的梯度算子,* 表示卷积运算, δ 为为了保持运算中数值稳定的极小常数。基于真实边缘响应 $E(Y)$ 与预测边缘响应 $E(\hat{Y})$,定义 L1 边缘损失如下:

$$L_{\text{edge-L1}} = \frac{1}{|\Omega_b|} \sum_{i \in \Omega_b} |E(\hat{Y})_i - E(Y)_i|, \quad (7)$$

其中: Ω_b 表示边界像素集合, i 为边界像素索引,该项损失能够有效抑制分割结果中的边界模糊与轮廓偏移问题。

Dice 损失侧重提升区域分割完整性,而 L1 边缘损失侧重提高边界定位精度,两者联合能更好地满足对测量区域一致性和边缘准确性的双重要求。

2.3 亚像素边缘提取

通过改进的 U-Net++ 模型获得线圈内圈圆弧所在区域的分割掩膜后,在掩膜限定的 ROI 内进行亚像素边缘提取,获得高精度轮廓点集。考虑到线圈边界在显微图像中通常表现为灰度缓变,本文采用 Zernike 矩^[22]描述局部灰度分布。以候选边缘像素为中心构造 15×15 滑动窗口,并将窗口内像素坐标归一化映射到单位圆域内;窗口沿 ROI 边界区域以单像素步长逐点滑动,保证边缘提取的连续性。

随后,基于归一化后的局部灰度分布计算 Zernike 矩系数,并以矩系数幅值作为边缘存在性判据。当窗口满足边缘判定条件时,进一步结合复系数相位信息估计边缘法向方向,并通过局部灰度曲线拟合求取边缘相对窗口中心的偏移量,从而得到亚像素边缘坐标,其表达式如下:

$$(u_i, v_i) = (u_c + \delta u, v_c + \delta v), \quad (8)$$

其中: (u_c, v_c) 是候选边缘像素对应滑动窗口中心的像素坐标, $(\delta u, \delta v)$ 是边缘点相对于窗口中心的亚像素偏移量, (u_i, v_i) 是最终求得的亚像素边缘坐标。

为验证 Zernike 阶数选择的合理性,在保持分割结果、滑动窗口大小、滑动步长及后续 LM 拟合参数一致的前提下,将矩阶数分别设置为 4, 6, 8, 10, 并对同一批线圈零件开展测量对比实

验。分别统计最大误差和均方根误差(RMSE)以及单张 512×512 图像的平均处理耗时,结果见表 2。

表 2 不同 Zernike 阶数下的测量性能对比

Tab. 2 Comparison of measurement performance under different Zernike orders

Order	Max error/ μm	RMSE/ μm	Avg. time/ms
4	12.1	3.8	60.2
6	8.8	2.6	75.4
8	8.0	2.2	97.7
10	7.8	2.1	164.3

可知,当 Zernike 阶数由 4 提升至 8 时,测量误差持续减小,说明较高阶数能更充分地刻画线圈边界的灰度缓变特征;当阶数提高到 10 时,误差改善幅度有限,而耗时明显增加。综合考虑测量精度与处理效率,选取 8 阶 Zernike 矩作为亚像素边缘提取参数。

2.4 多点位数据融合与高精度圆轮廓拟合

由于所需要拟合的线圈圆轮廓大于显微成像视野,如图 3 所示,测量过程中分别获取线圈上下左右四个测量点位的图像,随后结合观测位置的几何关系,将各视野下的边缘点统一转换到全局坐标系中,实现数据融合。

相机图像坐标系为 $O-UV$,相机像素尺寸为 s_x, s_y (单位: $\mu\text{m}/\text{pixel}$),镜头放大倍率为 M_{lens} (本文放大倍率为 1 倍),实际测量中滑台带动线圈移




图 3 线圈零件四方位的数据融合示意图

Fig. 3 Schematic of four-view data fusion for the coil part

动至四个观测点的坐标分别为 (X_{tA}, Y_{tA}) , (X_{tB}, Y_{tB}) , (X_{tC}, Y_{tC}) , (X_{tD}, Y_{tD}) (对应上、下、左、右测点)。考虑到滑台存在安装误差,在多视野测量中考虑滑台偏角,如图 4 所示,分别定义滑台 X 轴正向与图像 U 轴正向之间的夹角为 α_x ,滑台 Y 轴正向与图像 V 轴正向之间的夹角为 β_y 。




图 4 坐标系转换示意图

Fig. 4 Schematic of coordinate transformation

前序步骤获取的单亚像素边缘点 (u_i, v_i) (图像坐标系)转换为滑台全局坐标系 (X_i, Y_i) 的公式为:

$$\begin{bmatrix} X_i \\ Y_i \end{bmatrix} = \begin{bmatrix} X_t \\ Y_t \end{bmatrix} + \begin{bmatrix} \cos \alpha_x & -\sin \beta_y \\ \sin \alpha_x & \cos \beta_y \end{bmatrix} \begin{bmatrix} \Delta u \\ \Delta v \end{bmatrix}, \quad (9)$$

$$\Delta u = \frac{(u_i - u_0)s_x}{M_{\text{lens}}}, \Delta v = \frac{(v_i - v_0)s_y}{M_{\text{lens}}}, \quad (10)$$

其中: (X_t, Y_t) 为当前视场对应的滑台定位坐标, (u_0, v_0) 为相机图像坐标系的中心像素坐标。通过该转换公式,将四视场的所有边缘点统一至全局坐标系,得到融合边缘点集 $\{(X_i, Y_i)\}_{i=1}^N$, 其中 N 为统一后的总边缘点数。

在完成多视野边缘点坐标统一后,本文采用 LM 算法对融合点集进行圆轮廓拟合^[23]。设待拟合圆的参数向量为:

$$\mathbf{p} = [X_c, Y_c, R]^T, \quad (11)$$

其中: X_c 和 Y_c 分别为圆心坐标, R 为圆半径。对于融合点集中的第 i 个边缘点 (X_i, Y_i) , 其对应的残差为:

$$r_i(\mathbf{p}) = \sqrt{(X_i - X_c)^2 + (Y_i - Y_c)^2} - R. \quad (12)$$

则圆拟合问题可表示为最小化残差平方和:

$$\min_{\mathbf{p}} F(\mathbf{p}) = \sum_{i=1}^N r_i^2(\mathbf{p}). \quad (13)$$

对上述目标函数迭代求解,设当前迭代参数为 $\mathbf{p}_k$, 对应残差向量为 $\mathbf{r}$, 雅可比矩阵为 $\mathbf{J}$, 则参数

增量 Δp 满足:

$$(J^T J + \mu I) \Delta p = -J^T r, \tag{14}$$

其中: μ 为阻尼因子, I 为单位矩阵, $J = \partial r / \partial p$ 为残差向量对参数向量的雅可比矩阵。更新公式为:

$$p_{k+1} = p_k + \Delta p. \tag{15}$$

通过迭代更新,最终获得线圈圆轮廓的最优拟合值,即圆心坐标和半径。

为提高 LM 圆拟合的收敛稳定性,首先以融合边缘点集的几何中心作为初始圆心估计,并以各点到初始圆心的平均距离作为初始半径估计。考虑到局部噪声点可能对非线性拟合产生干扰,在拟合前基于邻域一致性准则剔除少量离散异常点。四个视场的边缘点统一到滑台全局坐标系后等权参与拟合;同时,对点数差异较大的视场按固定步长进行均匀抽样,以减弱局部圆弧长度差异和采样密度差异对拟合结果的影响。LM 迭代初始阻尼因子设为 0.01,当迭代后残差平方和减小时令因子缩小为原来的 1/10,反之放大 10 倍;当相邻两次的残差平方和变化量小于 10^{-8} 或

迭代次数达到 100 次时停止迭代。

3 实验设备及数据集构建

3.1 实验设备

在课题组研制的精密线圈装配设备上进行了实验,该设备主要包括显微视觉模块、作业工作台模块、线圈操纵模块、硅组件翻转模块等,如图 5 所示,其主要性能参数见表 3。




图 5 装配设备整体结构
Fig. 5 Overall structure of the assembly equipment

表 3 设备性能参数
Tab. 3 Performance parameters of the experimental setup

Module	Item	Value
Industrial camera	Resolution	3088(U) × 2064(V)
	Pixel size	2.4 μm × 2.4 μm
	Working distance	65.0 mm
Telecentric lens	Magnification	1×
	Absolute positioning accuracy	5.0 μm
Precision stage	Repeat positioning accuracy	0.5 μm
	Motion resolution	0.5 μm

3.2 分割实验数据集与评价指标

3.2.1 数据集构建与划分

共选取 30 个微小圆线圈零件作为数据采集对象,每个零件在不同光照强度、轻微姿态变化和局部反光条件下采集约 50 张显微图像,最终获得原始图像 1 500 张。为避免同一零件的相似图像同时出现在训练集和验证集中造成数据泄露,本文以零件实例为单位进行划分,训练集与验证集比例为 4:1,其中训练集包含 1 200 张原始图像,验证集包含 300 张原始图像。数据增强仅对训练集进行,增强方式包括亮度扰动、噪声叠加、轻微旋转和平移等;验证集不进行增强,用于评

价模型在不同光照、姿态和局部反光条件下的泛化能力。

图像标注采用 LabelMe 软件完成。标注时将线圈所在目标区域作为前景,将视野中夹具、灰尘、局部反光和背景区域均标记为背景。对于灰度过渡较平缓的边界区域,以线圈内圈真实边界的连续走势为依据进行人工校正,保证标注边界与后续亚像素边缘提取区域一致。

3.2.2 训练设置

模型训练在 PyTorch 环境下完成,网络主干采用改进的 U-Net++ 编码器—解码器结构,输入图像尺寸统一为 512 × 512。训练过程中采用

Adam 优化器,初始学习率设为 1×10^{-4} ,结合 StepLR 学习率衰减策略进行优化,消融实验中最大训练轮数设为 50, Batch size 设为 8。训练过程中不采用早停策略,而是在完成全部预设训练轮数后,根据验证集评价结果保存最优权重。模型训练与推理在 NVIDIA GeForce RTX PRO 6000 GPU 和 22 vCPU Intel(R) Xeon(R) Platinum 8470Q CPU 平台上完成。

3.2.3 评价指标

为评估模型对线圈区域的分割性能,采用 Dice 系数 (Dice)、均交并比 (mean Intersection over Union, mIoU)、均查准率 (Precision, P) 为评价指标^[24]。

设正类为目标线圈区域,则:

$$P = \frac{TP}{TP + FP}, \quad (16)$$

$$mIoU = \frac{TP}{TP + FP + FN}, \quad (17)$$

$$Dice = \frac{2TP}{2TP + FP + FN}, \quad (18)$$

其中: TP 表示被正确预测为正类的像素数, FP 表示被错误预测为正类的像素数, FN 表示被错误预测为负类的像素数。

4 实验结果与讨论

4.1 混合损失权重配比优化实验

为确定混合损失函数中 Dice Loss 与 L1-edge Loss 的合理权重配比,在保持网络结构及其余训练参数一致的条件下,对损失函数中的权重系数设置了不同比例组别并进行了对比实验。不同权重配比下的实验结果如表 4 所示。其中,

表 4 损失函数混合权重对比

Tab. 4 Comparison of weighting ratios for the hybrid loss function (%)

$\lambda_1 : \lambda_2$	Dice	mIoU	P
2:8	92.95	87.92	93.14
4:6	93.22	88.69	93.86
6:4	93.47	88.97	93.95
8:2	93.14	88.79	93.75
1:0	92.38	87.75	92.57

1:0 对应纯 Dice 损失,用作损失函数对比实验的基线配置。

根据实验结果,最终选择 6:4 作为最优的混合比例,此时模型取得最高 93.47% 的 Dice 系数,同时 mIoU 和 Precision 分别达到 88.97% 和 93.95%,综合表现优于其余配比组合。

4.2 改进 U-Net++ 的特征分割对比实验与消融分析

为验证本文在 U-Net++ 中引入注意力机制、边缘增强分支与损失函数对分割性能的影响,从两个方面开展实验分析。一方面,通过模块消融实验比较各模块对分割性能的影响,验证模块的独立作用及组合效果;另一方面,与 U-Net, U-Net++, DeepLabV3+ 和 PSPNet 等典型语义分割模型进行对比,评价本文方法在同类分割模型中的综合性能。

首先开展模块消融实验。基线模型选用原始 U-Net++,在此基础上分别引入 ECA 注意力模块、边缘增强分支和混合损失函数,并进一步构建双模块组合与完整模型。各实验组的配置及结果见表 5。

表 5 改进 U-Net++ 的消融实验结果

Tab. 5 Ablation results of the improved U-Net++

Configuration	Baseline	+ECA	+Edge	+Loss	+ECA +Edge	+ECA +Loss	+Edge +Loss	Ours
ECA module	×	✓	×	×	✓	✓	×	✓
Edge-enhancement branch	×	×	✓	×	✓	×	✓	✓
Hybrid loss (Dice+L1-edge)	×	×	×	✓	×	✓	✓	✓
Dice/%	92.38	92.75	93.52	93.47	93.97	94.48	94.52	94.95
mIoU/%	87.75	88.23	89.10	88.97	89.45	89.92	90.07	90.46
Precision/%	92.57	93.07	93.78	93.95	94.23	94.77	94.69	95.27




图 6 改进 U-Net++消融实验结果对比

Fig. 6 Comparison of improved U-Net++ ablation experiment results

相较于基线 U-Net++, 引入不同组件后模型分割性能均有提升, 但提升幅度存在差异。单独引入 ECA 注意力机制后, Dice, mIoU 和 Precision 分别提升至 92.75%, 88.23% 和 93.07%, 说明通道重校准能够增强模型对目标结构的判别能力, 但其对线圈内圈边界感知的改善相对有限。相比之下, 边缘增强分支和混合损失函数带来的增益更为明显: 前者使 Dice, mIoU 和 Precision 提升至 93.52%, 89.10% 和 93.78%, 说明显式边缘先验有助于增强网络对目标轮廓区域的响应; 后者使三项指标达到 93.47%, 88.97% 和 93.95%, 表明区域重叠约束与边缘一致性约束的联合优化有助于减少误分割和伪边缘响应。

双模块组合实验也表明, 各改进组件之间具有较好的互补关系。其中, 边缘增强分支与混合损失函数的组合在 Dice 和 mIoU 上表现最佳, 而 ECA 与混合损失函数的组合在 Precision 上略优。完整模型在三项指标上均取得最优结果, Dice, mIoU 和 Precision 分别达到 94.95%, 90.46% 和 95.27%, 较基线 U-Net++ 分别提升 2.57%, 2.71%, 2.70%。说明 ECA 注意力增强、边缘先验引导与混合损失优化之间具有较好的协同增益效应。

在完成改进模块有效性验证的基础上, 为进一步比较本文方法与典型语义分割模型在相同任务条件下的性能差异, 在相同数据集划分、输入尺寸和训练策略下, 对 U-Net, U-Net++, DeepLabV3+, PSPNet 及本文方法进行对比实验, 结果见表 6。

相较其他几种通用的分割模型, 本文方法在

表 6 不同语义分割模型的分割性能对比

Tab. 6 Comparison of segmentation performance of different semantic segmentation models (%)

Model	Dice	mIoU	P
U-Net	91.34	86.48	91.74
U-Net++	92.38	87.75	92.57
DeepLabV3+	92.16	87.42	92.86
PSPNet	91.78	87.02	92.31
Ours	94.95	90.46	95.27

Dice, mIoU 和 Precision 三个指标上均取得较优结果, 说明所提出的改进策略能够有效提升线圈显微图像中目标区域的完整性和边界分割稳定性。与横向对比的这几个模型相比, 本文方法在圆弧边界连续性和局部伪边缘抑制方面表现更稳定, 更适合后续的测量任务。

4.3 测量精度与鲁棒性

4.3.1 光照变化条件下的测量鲁棒性

在不同光强条件下使用本文方法和 Canny 搭配特征提取的方法(对照方法)分别对线圈内径进行测量, 使用工具显微镜测量该线圈最大内接圆半径 9 996.8 μm 作为标准值, 以光源控制器的光强控制值(0~255)衡量光强大小, 测量结果如图 7 所示。




图 7 光强对测量的影响

Fig. 7 Effect of illumination intensity on measurement accuracy

随着光强逐步提高, 两种方法的测量结果均趋近于标准值, 表明充足光照有利于增强边缘灰度对比度并减弱纹理干扰, 但光强过高会由于局部灰度饱和与弥散导致两种方法分辨力的下降。

在中高光强条件下,本文的方法相较对照方法能更准确地逼近标准值,说明本文的方法具有更宽的适宜区间和更高的准确度,适用于成像条件和零件批次差异波动较大的场景。

4. 3. 2 零件角度变化条件下的测量稳定性

由于待测线圈超出视场范围,实际测量时获取的是局部圆弧边缘,不同位姿下进入视场的圆弧段位置与长度存在差异,因此测量结果会随零件角度变化产生波动。本文采集线圈不同角度下的图像并进行测量,并将工具显微镜测量获得的该线圈最大内接圆半径为标准值,如图 8 所示。

结果表明,本文方法在不同角度条件下的最大相对误差为 $3.1\text{ }\mu\text{m}$,最大测量值与最小测量值之间的波动范围为 $5.0\text{ }\mu\text{m}$,均方差为 1.73;对照方法的最大相对误差为 $6.9\text{ }\mu\text{m}$,波动范围为 $11.2\text{ }\mu\text{m}$,均方差为 3.54。本文的方法不仅减小了极值误差,同时抑制了不同视角下测量结果的波动,对零件位姿变化具有更强的适应




图 8 零件摆放角度对测量影响

Fig. 8 Effect of part orientation on measurement accuracy

能力。

4. 3. 3 不同批次零件测量一致性验证

采用本文方法和对照方法在相同条件下对随机选取的 50 个线圈零件进行测量,规定测量结果与参考值偏差超过 $10\text{ }\mu\text{m}$ 时判定为不合格,结果见表 7。

表 7 测量误差对比

Tab. 7 Comparison of measurement errors

	Max error/ μm	Min error/ μm	RMSE/ μm	Pass rate/%
Proposed method	8.1	0.3	2.2	94
Comparison method	25.7	1.6	5.6	80

可知,本文方法在误差极大值、极小值及 RMSE 上均表现出更优的结果。本文测量的误差极大值降低 $17.6\text{ }\mu\text{m}$,极小值降低 $1.3\text{ }\mu\text{m}$,RMSE 降低 $3.4\text{ }\mu\text{m}$ 。测量合格率提升 14%,表现出优于对照方法的精度与鲁棒性,为线圈组件自动装配的高精度对准需求提供了可靠支撑。

4. 4 装配验证实验

为进一步验证本文方法在真实装配流程中的应用效果,在 3.1 节所示的精密线圈自动装配设备上完成验证实验,本文的方法作为其中的视觉测量环节。待装配零部件如图 9 所示,由中间的圆筒状硅组件和对称粘贴在硅组件两端面的两个圆形线圈组成,它工作时通过对称的线圈切割磁场产生差分信号,可见,线圈的安装精度影响输出信号的准确度。

线圈的高精度测量针对线圈内圈展开,该型




图 9 待装配核心零部件的结构

Fig. 9 Schematic of the core component to be assembled

号线圈与硅组件的内圈直径均为 20 mm ,需要实现的装配精度为线圈与下方硅组件同轴度 $\leq 20\text{ }\mu\text{m}$ 。

将本文的测量方法嵌入线圈自动装配设备进行装配实验,具体步骤如下:

(1)通过视觉模块测量上、下层线圈圆心点位及放置在夹具上的硅组件的圆心点位;

- (2)硅组件夹持机械臂按照测量获得的硅组件点位完成对其的夹取;
- (3)测量已完成夹取后的硅组件的点位,消除夹持过程带来的干扰;
- (4)利用已经获得的下层线圈及硅组件的各自圆心点位,完成硅组件在下层线圈上的对准放置;
- (5)利用已获得的上层线圈点位,移动上线圈作业机械臂吸附上层线圈并完成最终的装配。

表 8 为使用线圈自动装配设备完成的 10 套装配的结果数据。

由表 8 可知,本文方法在当前 10 组装配验证中表现出更优的装配精度和更高的合格率。相比作为对照的 Canny 测量方法,本文方法在上线圈和下线圈装配中的平均同轴度误差分别降低了 9.8 μm 和 9.6 μm ,降幅约为 43.8% 和 41.9%。而且,本文方法对应的最大装配同轴度误差也明显减小,有效保证了装配一致性。

表 8 线圈元件的装配误差

Tab. 8 Coaxiality errors of coil components

Num	Coaxiality error of Comparison method/ μm		Coaxiality error of proposed method/ μm	
	Up coil	Down coil	Up coil	Down coil
1	21.3	26.5	8.2	11.5
2	18.7	15.8	10.7	13.6
3	24.9	26.1	18.1	16.4
4	16.6	16.3	21.6	19.5
5	26.9	23.0	9.0	9.5
6	23.0	25.6	9.2	8.7
7	33.7	38.4	15.6	17.3
8	21.7	18.1	12.7	13.2
9	16.2	10.7	11.4	9.9
10	21.2	28.6	9.7	12.9
Mean/ μm	22.4	22.9	12.6	13.3

需要指出的是,在第 4 组装配结果中,本文方法对应的上线圈同轴度误差为 21.6 μm ,略高于 20 μm 的装配指标。该组下线圈同轴度误差为 19.5 μm ,已经接近指标上限,说明该组样本在前序对准和后续上线圈放置过程中存在一定误差累积。结合装配流程分析,造成该组上线圈误差偏大的原因可能包括:上线圈由吸附头拾取和转移,柔性线圈在吸附过程中可能产生轻微偏心或姿态偏转;硅组件与下线圈之间仍处于胶液未完全固化状态,接触放置过程中可能产生微小滑移;同时,视觉测量误差、夹持残余误差和装配机构重复定位误差也会在最终线圈放置阶段发生叠加。

后续将从吸附头定心精度、吸附稳定性、接触力控制和放置后复测补偿等方面进一步优化装配流程。优化夹具定位和胶量控制,减小胶层流动对线圈最终位置的影响,进一步提高批量装

配的一致性和达标率。

5 结 论

本文针对微小圆线圈在显微视觉测量中存在的纹理干扰、边界模糊及跨尺度拟合问题,提出了一种融合改进 U-Net++ 语义分割、Zernike 矩亚像素边缘提取与多视野 LM 圆拟合的高精度测量方法,在批量装配任务中验证其有效性。主要结论如下:

(1)提出了结合 ECA 注意力机制、边缘增强分支与混合损失函数的改进 U-Net++ 语义分割模型,有效抑制复杂成像条件下的纹理伪边缘与局部反光干扰。在目标区域提取任务中,Dice 系数、mIoU 和查准率分别达到 94.95%,90.46% 和 95.27%,较原始 U-Net++ 分别提升 2.57%,2.71% 和 2.70%。

(2)构建了“粗定位+精提取+多视场融合”的测量流程,在Zernike矩亚像素边缘提取与LM圆拟合的协同作用下,实现了跨尺度圆弧特征重建。批量测量实验合格率达94%。

(3)将该方法集成于自动装配系统,在10组装配任务中进行应用验证,结果表明上下线圈的平均同轴度误差分别为12.6 μm 和13.3 μm 。采用本文方法后装配达标样本数由3组提高到9组,说明该方法在复杂工况下具备较好的鲁棒性和工程适用性。

参考文献:

- [1] SHAN G Q, LI Y Z, ZHANG L W, *et al.* Contributed Review: Application of voice coil motors in high-precision positioning stages with large travel ranges[J]. *Review of Scientific Instruments*, 2015, 86(10): 101501.
- [2] 王晓东,崔世鹏,徐征,等. 面向精密微装配的视觉复合定位[J]. *光学精密工程*, 2023, 31(19): 2857-2866.
WANG X D, CUI S P, XU Z, *et al.* Visual composite positioning for precision microassembly [J]. *Opt. Precision Eng.*, 2023, 31(19): 2857-2866. (in Chinese)
- [3] 徐征,何佳珩,王彦琪,等. 面向显微视觉的端对端去模糊模型[J]. *光学精密工程*, 2024, 32(20): 3047-3058.
XU Z, HE J H, WANG Y Q, *et al.* End-to-end deblurring model for microscopic vision[J]. *Opt. Precision Eng.*, 2024, 32(20): 3047-3058. (in Chinese)
- [4] FLORES-FUENTES W, TRUJILLO-HERNÁNDEZ G, ALBA-CORPUS I Y, *et al.* 3D spatial measurement for model reconstruction: a review [J]. *Measurement*, 2023, 207: 112321.
- [5] 曾猛杰,汪晨曦,赖俊杰,等. 亚像素边缘检测算法综述[J]. *光学精密工程*, 2024, 32(23): 3513-3524.
ZENG M J, WANG C X, LAI J J, *et al.* Review of sub-pixel edge detection algorithms[J]. *Opt. Precision Eng.*, 2024, 32(23): 3513-3524. (in Chinese)
- [6] 郝飞,顾志鹏,关鸿耀,等. 机器视觉测量明暗场复合照明系统优化设计[J]. *光学精密工程*, 2025, 33(20): 3203-3213.
- 本文针对这种类型的跨尺度圆线圈,展现出了较好的视觉测量效果。后续研究将在此基础上结合更多类型的微装配零件拓展方法的通用性。
- 作者贡献声明:**
王晓东:方法构建和系统设计;
侯瑞阳:结构设计、方法实现和论文撰写;
张子涵:应用实验;
高昆桦:样本采集与标注;
徐 征:精度分析和模型设计。
- HAO F, GU Z P, GUAN H Y, *et al.* Optimization design of combined brightfield and darkfield illumination system for machine vision measurement [J]. *Opt. Precision Eng.*, 2025, 33(20): 3203-3213. (in Chinese)
- [7] BRAR K K, GOYAL B, DOGRA A, *et al.* Image segmentation review: Theoretical background and recent advances [J]. *Information Fusion*, 2025, 114: 102608.
- [8] MO Y J, WU Y, YANG X N, *et al.* Review the state-of-the-art technologies of semantic segmentation based on deep learning [J]. *Neurocomputing*, 2022, 493: 626-646.
- [9] LONG J, SHELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation [C]. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 7-12, 2015, Boston, MA, USA. IEEE, 2015: 3431-3440.
- [10] 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.
- [11] ZHOU Z W, RAHMAN SIDDIQUEE M M, TAJBAKHS N, *et al.* UNet++: A Nested U-Net Architecture for Medical Image Segmentation [C]. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. Cham: Springer, 2018: 3-11.
- [12] CHEN L C, PAPANDREOU G, KOKKINOS I, *et al.* DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. *IEEE Transactions on*

- Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [13] ZHAO H S, SHI J P, QI X J, *et al.* Pyramid Scene Parsing Network[C]. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. July 21-26, 2017, Honolulu, HI, USA. IEEE, 2017: 6230-6239.
- [14] 刘腊梅, 杜宝昌, 黄惠玲, 等. DFNet: 高效的无解码语义分割方法[J]. 液晶与显示, 2024, 39(2): 121-130.
- LIU L M, DU B C, HUANG H L, *et al.* DF-Net: efficient decoder-free semantic segmentation networks[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(2): 121-130. (in Chinese)
- [15] 刘玉, 郭迎春, 朱叶, 等. 基于双交叉注意力Transformer网络的小样本图像语义分割[J]. 液晶与显示, 2024, 39(11): 1494-1505.
- LIU Y, GUO Y C, ZHU Y, *et al.* Dual cross-attention Transformer network for few-shot image semantic segmentation[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(11): 1494-1505. (in Chinese)
- [16] 刘玉, 于明, 朱叶. 基于双重聚合和自合并网络的小样本图像语义分割[J]. 液晶与显示, 2024, 39(10): 1421-1430.
- LIU Y, YU M, ZHU Y. Bi-aggregation and self-merging network for few-shot image semantic segmentation[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(10): 1421-1430. (in Chinese)
- [17] TANG K K, ZHANG P, ZHAO Y D, *et al.* Deep learning-based semantic segmentation for morphological fractography[J]. *Engineering Fracture Mechanics*, 2024, 303: 110149.
- [18] WANG R, DUAN F J, FU X, *et al.* Method for measuring geometric dimensions of micro parts based on a telecentric camera[J]. *Optics Express*, 2025, 33(11): 23580.
- [19] LI L, LI B, SUN Z J, *et al.* A hybrid optical metrology framework integrating telecentric imaging and an optical micrometer for multi-scale geometric evaluation of aero-engine shafts[J]. *Measurement*, 2026, 262: 120053.
- [20] 张瑞, 周昌黎, 卞富, 等. 分步光束法平差多目视觉测量系统[J]. 光学精密工程, 2025, 33(23): 3618-3629.
- ZHANG R, ZHOU C Y, BIAN F, *et al.* Step-wise bundle adjustment-based multi-camera vision measurement system[J]. *Opt. Precision Eng.*, 2025, 33(23): 3618-3629. (in Chinese)
- [21] WANG Q L, WU B G, ZHU P F, *et al.* ECA-net: efficient channel attention for deep convolutional neural networks[C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 11531-11539.
- [22] JI L, QIN S L, HAN G, *et al.* Sub-pixel detection method for an aviation plugbased on Zernike moments[J]. *Applied Optics*, 2026, 65(1): 237-243.
- [23] CHERNOV N, LESORT C. Least squares fitting of circles[J]. *Journal of Mathematical Imaging and Vision*, 2005, 23(3): 239-252.
- [24] TERVEN J, CORDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A, *et al.* A comprehensive survey of loss functions and metrics in deep learning[J]. *Artificial Intelligence Review*, 2025, 58(7): 195.

作者简介:



王晓东(1967—),男,黑龙江哈尔滨人,教授,博士生导师,1989年于南京航空学院获得学士学位,1992年于哈尔滨船舶工程学院获得硕士学位,1995年于哈尔滨工业大学获得博士学位。主要从事微装配技术与系统、精密仪器设计与制造等方面的研究。E-mail:xdwang@dlut.edu.cn

通讯作者:



徐征(1973—),男,河南郑州人,博士,副研究员,1997年和2000年于吉林工业大学分别获得学士和硕士学位,2004年于大连理工大学获得博士学位,主要从事显微视觉与智能微装配、微纳流体等方向的研究工作。E-mail:xuzheng@dlut.edu.cn