

基于改进UNet模型的光条纹中心提取方法

张 铄^{1,2}, 王 怀¹, 吴禹铮¹, 孙 宇¹

(1. 东北大学秦皇岛分校 计算机与通信工程学院, 河北 秦皇岛 066004;

2. 东北大学秦皇岛分校 河北省海洋感知网络与数据处理重点实验室, 河北 秦皇岛 066004)

摘 要: 针对复杂环境下工件表面不均匀强反射、背景噪声干扰与高精度测量需求之间的矛盾, 提出一种基于改进U型网络(UNet)的光条纹中心提取算法。首先, 在UNet模型中的编码器和解码器中分别引入分组深度可分离卷积模块与密集残差卷积模块, 构建了基于多重卷积、特征融合和注意力机制的U型分割模型, 以降低光条纹图像异常曝光引起的干扰, 提高对光条纹整体分割的精度。然后, 在测试集上进行实验, 结果表明, 光条纹分割任务中的相似系数、平均交并比和精确率分别为0.9018, 0.8354, 0.9135, 与UNet模型相比, 分别提高了6.43%, 9.13%, 15.51%。最后, 采用基于海森矩阵的光条纹中心提取Steger算法对光条纹中心线进行精确提取, 实验结果证明了改进后的UNet模型与Steger算法相结合的有效性, 即使在光条纹图像异常曝光时也具有较高的准确性。

关 键 词: 图像处理; 线结构光; 光条纹中心提取; 图像分割; UNet

中图分类号: TP 391 文献标志码: A 文章编号: 1005-3026(2026)02-0010-08

Light Stripe Center Extraction Method Based on Improved UNet Model

ZHANG Yao^{1,2}, WANG Huai¹, WU Yu-zheng¹, SUN Yu¹

(1. School of Computer and Communication Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China; 2. Hebei Key Laboratory of Marine Perception Network and Data Processing, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China. Corresponding author: WANG Huai, E-mail: 2372415@stu.neu.edu.cn)

Abstract: Light stripe center extraction algorithm based on an improved U-shaped network (UNet) was proposed to resolve the contradiction among uneven strong reflections on workpiece surfaces, background noise interference, and the demand for high-precision measurement in complex environments. Firstly, grouped depthwise separable convolution modules and dense residual convolution modules were introduced into the encoder and decoder of the UNet model, respectively. A U-shaped segmentation model based on multiple convolutions, feature fusion, and attention mechanisms was established to reduce interference caused by abnormal exposure in stripe images and improve the overall accuracy of stripe segmentation. Experiments on the test set show that for the stripe segmentation task, the Dice coefficient, mean intersection over union, and precision reach 0.9018, 0.8354, and 0.9135, respectively, which are improved by 6.43%, 9.13%, and 15.51% compared with the original UNet model. Finally, based on the segmentation results, Steger algorithm based on the Hessian matrix is applied to accurately extract the centerline of the light stripe. Experimental results verify the effectiveness of combining the improved UNet model with Steger algorithm, which demonstrates excellent accuracy even under abnormal exposure conditions in light stripe images.

Key words: image processing; line structured light; light stripe center extraction; image segmentation; UNet

在智能制造领域,线结构光三维测量技术具有广泛的应用前景.由于其非接触、高精度、低成本、抗干扰能力强等优点,该技术被广泛应用于工业检测、医疗、军事等光学领域^[1-4].线结构光三维测量技术基于三角法原理,由线激光器和工业相机组成三角测量结构.其中,光条纹中心提取方法是线结构光三维测量系统的关键组成部分,其提取精度直接决定了系统的整体性能.

目前,根据提取方法原理的不同,可将光条纹中心提取方法分为3类^[5]:①基于几何中心的光条纹中心提取方法,包括阈值法、边缘法^[6]和细化法^[7]等.阈值法和边缘法速度快,但易受噪声影响,精度不高;细化法易受光强和光条纹形状的影响,导致提取出的中心线出现毛刺或不连续现象.②基于光条纹能量中心的提取方法,包括灰度重心法^[8]、极值法^[9]、曲线拟合法^[10]和方向模板法^[11]等.灰度重心法易受噪声和光条纹曲率影响,并且对光条纹的灰度分布依赖性强;极值法和曲线拟合法仅在光条纹截面的灰度分布符合高斯分布的情况下才表现良好;方向模板法计算量大,耗时长,对预设模板有较强的依赖性.③更具特征的提取方法,包括Steger算法^[12]和基于深度学习的提取方法等.Steger算法结合海森(Hessian)矩阵确定光条纹的法线方向,然后在法向上求得极值点,以此定位光条纹的亚像素级中心.该方法精度高、稳健性好,是目前应用最广泛的光条纹中心提取方法.然而,基于光条纹几何中心和能量中心的传统算法,在面对反射、散射等光学现象时,遇到了巨大的挑战.在复杂工业零件表面,由于反射率分布不均,所采集的光条纹图像会出现过曝光、欠曝光等异常情况.这将直接影响图像分割结果,并增大最终测量的误差.因此,在复杂工业零件的测量中,如何快速准确地分割条纹并提取其中心是完成三维测量的重要技术基础.

近年来,随着深度学习技术在图像分割、图像分类和目标检测等领域取得突破性进展,其在光条纹中心提取方向的应用也取得了一定进展.张宇等^[13]使用改进的密集跳跃U型网络模型(UNet++)进行图像分割,粗提光条纹中心区域,再利用灰度重心法精确提取亚像素中心,但是传统的灰度重心法对斜向曲折的光条纹提取效果不佳.Ye等^[14]建立了基于特征融合和注意力机制的UNet分割模型,可有效解决反

射引起的干扰,并能分割光条纹的整体分布和弯曲特性.Jiang等^[15]基于多尺度注意力UNet模型进行图像分割,再利用Steger算法对光条纹中心线进行精确提取.张勇停等^[16]提出基于循环卷积神经网络(RCNN)单元的UNet模型,利用端到端的深度学习方法提取线结构光条纹中心.

针对现有光条纹中心提取方法的不足,以及光条纹图像异常曝光的难点,本文提出了一种基于改进UNet的语义分割模型.通过设计新的编码模块和解码模块,引入注意力机制,并进行特征融合,增强对光条纹边缘和细节的捕捉能力.在此基础上,结合Steger算法进行光条纹中心亚像素提取,为复杂工业环境下光条纹中心提取提供一种兼具精度与鲁棒性的方法.

1 网络模型

1.1 网络总体结构

由于系统采用主动成像方法,需要在被测工件上投射光条纹,这使测量具有反射特性的物体表面变得更加困难.这种现象会影响光条纹的分割和条纹中心的提取,最终导致测量误差甚至测量失败^[17].为此,本文提出了一种基于多重卷积、特征融合和注意力机制的分割网络模型,命名为GDUNet,该模型的网络框架基于UNet结构,由编码模块、解码模块和跳跃连接3部分组成.

GDUNet结构如图1所示,在编码特征提取阶段,为了捕获不同层次的语义信息并进行特征融合处理,在减少模型中参数数量的同时,采用了分组深度可分离卷积(group depthwise separable convolution, group-DSC)模块替代传统卷积提取更丰富的特征信息.在解码模块中,使用反卷积进行上采样,并引入了密集残差卷积(dense residual convolution, dense-RES)模块,这种组合能够在解码阶段有效增强光条纹特征的提取、融合和表达,确保恢复高质量的特征图.跳跃连接模块负责完成跳跃连接,将编码模块和解码模块中的多尺度特征进行有效融合,以增强解码模块的特征表达能力,最大化利用编码模块和解码模块中不同分辨率的特征图,这种融合对于分割光条纹图像中的精细结构至关重要,能够更好地恢复图像中的细节信息,从而提升光条纹图像分割的精度.

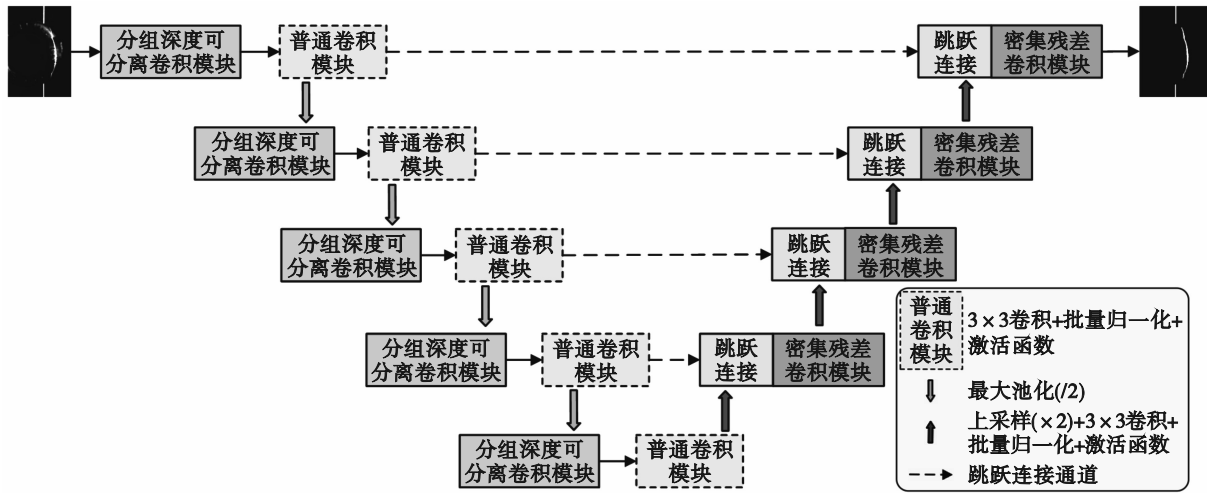


图 1 GDUNet 结构

Fig. 1 GDUNet structure

1.2 group-DSC 模块

在基础的 UNet 模型中,使用了大量的 3×3 卷积,使网络参数不断增加.为了提高网络的运行速度,平衡网络参数的数量,本文先采用了分组卷积将输入特征图分成 4 组,每组独立进行卷积操作,并使用深度可分离卷积进行模型压缩,然后进行通道混合排列通道顺序,打破分组卷积操作的独立性,促使不同通道间的信息相互融合,增强模型对复杂特征的表达能力^[18].其中深度可分离卷积分为深度卷积和点卷积.深度卷积独立处理每个输入通道的空间特征,其卷积核数量与输入通道数一致,仅执行空间滤波而不进行通道融合;点卷积则通过 1×1 卷积核实现跨通道的信息整合.这种分解策略降低了卷积操作的参数量与计算成本.深度可分离卷积的参数量 $M_{DSCconv}$ 与普通卷积的参数量 M_{Conv} 之比为

$$\frac{M_{DSCconv}}{M_{Conv}} = \frac{O+H \times H}{O \times H \times H} = \frac{1}{H^2} + \frac{1}{O} \quad (1)$$

式中: H 为卷积核尺寸; O 为输出通道数.该比值体现了深度可分离卷积在参数效率上的优势,尤其在输出通道数较大时更为显著.

group-DSC 模块结构如图 2 所示.首先输入特征 X_0 通过 4 分组 3×3 卷积和深度可分离卷积提取,得到初始特征.卷积运算后,通过批量归一化(BN)和 ReLU 激活函数,使模型更容易学习图像的稀疏特征,防止信息丢失.然后将分组卷积单元的输出特征与下层深度可分卷积单元的输出特征融合,这是为了提高模型的表达能力,使模型特征更加丰富,并促进特征的跨路径复用.最后将融合后的特征传递到压缩激励(SE)注意力

模块,让网络对光条纹特征进行通道增强,抑制无关或冗余的背景特征,从而提高网络模型对光条纹分割的精确度,得到输出特征 Y .group-DSC 模块的函数表达式如下:

$$X_1 = W_1^{3 \times 3} * X_0 + b_1, \quad (2)$$

$$X_2 = \varepsilon \left(\sigma \left(\gamma \cdot \frac{W_2^{3 \times 3} * X_1 + b_2 - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \right) \right), \quad (3)$$

$$X_3 = \lambda(X_2 + X_1), \quad (4)$$

$$Y = W_3^{3 \times 3} * X_3 + b_3. \quad (5)$$

式中: X_0 为输入特征; W 为卷积核,下标为卷积块的索引,上标为卷积核的大小; b 为卷积层的偏置,下标为卷积块的索引; $X_i(i=1,2,3)$ 为模型的中间输出; $*$ 为卷积运算; σ 为 ReLU 激活函数; ε 为通道混合; λ 为 SE 注意力机制; B 为当前计算的批次样本, μ_B 和 σ_B^2 分别为批次内该通道的均值和方差; ϵ 为任意极小常数; γ 和 β 分别为批量归一化的缩放参数和偏移参数.




图 2 模块 group-DSC 的结构

Fig. 2 Structure of group-DSC module

SE注意力模块首先接收输入特征 X ,该特征图的高度和宽度分别为 P_0 和 Q_0 ,通道数为 C_0 ,随后通过特征变换操作 F_{tr} 生成中间特征图 U ,然后通过压缩操作,将中间特征图进行全局平均池化,生成1个 $1 \times 1 \times C$ 的向量,其中 C 为中间特征图通道数,这样每个通道用1个数值表示,压缩过程函数表达式如下:

$$F_{sq}(U_c) = \frac{1}{P \times Q} \sum_{i=1}^P \sum_{j=1}^Q U_c(i, j). \quad (6)$$

式中: P 和 Q 分别为特征图 U 的高度和宽度, U_c 为第 C 个通道的特征图.压缩后进行激励操作 F_{ex} ,该操作由2个全连接层组成:第1个全连接层有 $C \times R$ 个神经元,输入为 $1 \times 1 \times C$,输出为 $1 \times 1 \times C \times R$,第2个全连接层有 C 个神经元,输入为 $1 \times 1 \times C \times R$,输出为 $1 \times 1 \times C$,其中 R 为通道缩放系数, R 可减少通道个数从而降低计算量.最后通过缩放操作 F_{scale} ,将SE模块计算出的各通道权重值分别与原特征图对应通道的二维矩阵相乘,得到最终的输出特征图.

1.3 dense-RES 模块

在光条纹图像分割任务中,上采样阶段的处理尤为关键.为了准确恢复条纹的细节特征,首先通过反卷积操作对特征图进行尺寸扩展,然后通过跳跃连接,将编码阶段提取的、包含精确位置信息的早期特征与解码阶段的深层特征进行

对齐与融合.最后将连接后的特征图通过密集残差模块进行处理,其密集连接促进了不同层次特征之间的交互,使模型能够同时依据局部纹理细节与全局语义理解来判断每个像素的类别,特别是对于光强不均匀或存在局部断裂的条纹区域.密集卷积网络能够利用多层级上下文信息进行合理推断与插补,并且残差结构有助于保持信息传递的完整性^[9].这种设计在上采样阶段不仅确保了光条纹细节的精确恢复,还提升了分割的整体精度和鲁棒性.

dense-RES 模块结构如图3所示,该密集残差块由4层卷积组成,每层卷积都接收前1层的输出,并将其与自身的输出进行拼接,从而实现特征的逐层积累与融合.在密集块的末尾连接一个残差卷积层,它通过1个 1×1 卷积将累积的特征进行融合,并与输入特征进行相加.在密集连接的基础上,残差连接进一步提升了特征的传递效率,通过引入残差学习机制,网络能够更加稳健地进行训练,减少由于网络加深而引起的梯度消失问题.dense-RES 模块的函数表达式如下:

$$X_l = H_l[X_0, X_1, \dots, X_{l-1}], \quad (7)$$

$$Y = X_0 + X_4. \quad (8)$$

式中: X_l 为第 l 层的输出; $H_l(l=1,2,3,4)$ 为第 l 层的卷积与ReLU激活函数运算; $[X_0, X_1, \dots, X_{l-1}]$ 为将之前所有层的输出进行通道方向的拼接.




图3 模块dense-RES的结构

Fig. 3 Structure of dense-RES module

1.4 损失函数

成像系统捕获的图像除了光条纹和背景外,还包含反射和复杂纹理等干扰.真实光条纹在图像中所占比例较小,导致正负样本不平衡.这可能会增大训练过程的误差,从而导致预测失败.在训练过程中,相似损失具有更深层次挖掘前景目标有效特征的能力,可以增强正面效果.同时,为了在网络的中间层直接获取损失反馈,并在更早阶段引导网络的特征学习,本文在前3层

dense-RES 模块后添加深监督层,为模型的中间层提供了附加的监督信息,以增强训练效果,尤其在处理复杂特征时,能够帮助网络学习更加准确的光条纹图像分割特征.因此,本文采用交叉熵损失 L_{CE} 、相似损失 L_{Dice} 和各深监督层损失 $L_{dsi}(i=1,2,3)$ 相结合的损失函数 L_E 对光条纹进行分割.综合损失函数表达式为

$$L_{CE} = -\frac{1}{N} \sum_{i \in N} \sum_{c \in M} g_i^k \ln s_i^k, \quad (9)$$

$$L_{\text{Dice}} = -\frac{1}{M} \sum_{k \in M} \frac{\sum_{i \in N} g_i^k s_i^k}{\sum_{i \in N} g_i^k + \sum_{i \in N} s_i^k}, \quad (10)$$

$$L_{\text{main}} = \frac{L_{\text{CE}} + L_{\text{Dice}}}{2}, \quad (11)$$

$$L_{\text{E}} = L_{\text{main}} + \eta \times (L_{\text{ds1}} + L_{\text{ds2}} + L_{\text{ds3}}). \quad (12)$$

式中: M 为类别数; N 为每批像素的集合; L_{main} 为交叉熵损失与相似损失的平均融合损失; g_i^k 为第 i 个像素在类别 k 上的独热编码标签; s_i^k 为第 i 个像素被预测为类别 k 的概率值; 混合权重 η 为 0.33.

2 实 验

2.1 实验环境与数据集

2.1.1 实验设备

本文实验采用 13th Gen Intel(R) Core(TM) i9-13900K@2.60GHz 处理器, 内存为 32 GB, GPU 为 RTX4060; 采用 Basler acA1600-20gm 工业相机采集图像, 输出分辨率为 1 626×1 236; 采用波长为 650 nm、功率为 1 W 的直线激光发射器为光源.

2.1.2 图像预处理

在黑暗环境下工业相机采集的图像中, 光条纹仅占原图像的小部分, 因此在进行图像分割时, 存在大量无关的背景像素点, 这会对分割结果产生干扰. 为了提高本文提出的 GDUNet 的运行速度, 需要对初始采集的光条纹图像进行裁剪, 以得到光条纹中心提取任务的感兴趣区域. 通过选取并裁剪光条纹区域, 将光条纹图像尺寸缩小为 750 像素×1 040 像素, 增加光条纹在图像中所占的比例. 然后对光条纹图像应用高斯滤波, 进一步平滑图像并减少噪声干扰.

2.1.3 数据集制作

通过 labelme 软件对预处理图像中的光条纹与背景进行标注, 生成每张样本图像的背景真值标签, 以此构建了包含 5 种复杂工业零件图像的综合数据集. 该数据集涵盖了光条纹过曝光、欠曝光等不良情况, 共包含 700 张样本图像, 其中 500 张用于训练, 100 张用于验证, 100 张用于测试.

2.2 参数设置

实验采用 PyTorch 1.13.0 深度学习框架, 初始学习率 l_r 为 0.000 01, 训练迭代次数为 150, 采用自适应矩估计优化器, 以其自适应学习率调整的特性, 有助于加快模型收敛并防止陷入局部最优, 在损失函数最终收敛时停止训练.

2.3 评价指标

为了评估模型的分割性能, 计算了 3 个指标:

相似系数 F_{Dice} 、平均交并比 F_{mIoU} 和精确率 F_{Pre} . 函数表达式如下:

$$F_{\text{Dice}} = \frac{2 \times S_{\text{TP}}}{2 \times S_{\text{TP}} + S_{\text{FP}} + S_{\text{FN}}}, \quad (13)$$

$$F_{\text{mIoU}} = \left[\sum_i^n \left(\frac{S_{\text{TP}}}{S_{\text{FN}} + S_{\text{FP}} + S_{\text{TP}}} \right) \right] / n, \quad (14)$$

$$F_{\text{Pre}} = \frac{S_{\text{TP}}}{S_{\text{TP}} + S_{\text{FP}}}. \quad (15)$$

式中: S_{TP} 为模型预测为阳性的阳性样本; S_{FP} 为被模型预测为阳性的阴性样本; S_{FN} 为模型预测为阴性的阳性样本.

2.4 消融实验

2.4.1 损失函数的对比消融验证

综合损失函数由交叉熵损失、相似损失及深监督损失组成. 为量化各损失项对分割效果的贡献, 本文设计了 4 组消融实验, 结果如表 1 所示. 在单独使用交叉熵损失时, 模型的相似系数为 0.865 1, 主要因正负样本不平衡、光条纹在图像中占比不足 10%, 以及交叉熵损失偏向背景类预测, 导致弱曝光条纹分割不完整; 在单独使用相似损失时, 相似系数为 0.878 3, 相似损失通过计算预测与标签的交并比, 能深度挖掘光条纹特征, 有效缓解样本不平衡问题, 尤其改善过曝光区域的分割精度; 结合交叉熵损失和相似损失后, 相似系数为 0.891 1, 较前两组实验分别提升 2.99% 和 1.46%, 这是由于交叉熵损失的类别区分优势与相似损失的区域重叠度优化优势形成协同, 既减少背景误判现象, 又强化对光条纹边缘及弱曝光区域的特征捕捉能力, 弥补了单一损失在分类精度或区域完整性上的短板; 引入深监督损失后, 各项指标达到最优, 相似系数达 0.901 8, 证明中间层附加监督可引导网络早期学习有效特征, 减少梯度消失对深层特征提取的影响, 显著优化异常曝光场景下光条纹分割的完整性与连续性.

表 1 损失函数消融实验结果

Table 1 Loss function ablation experiment results

损失函数	F_{Dice}	F_{mIoU}	F_{Pre}
L_{CE}	0.865 1	0.792 3	0.845 6
L_{Dice}	0.878 3	0.805 1	0.832 4
L_{main}	0.891 1	0.811 2	0.876 7
L_{E}	0.901 8	0.835 4	0.913 5

2.4.2 网络模型的对比消融验证

通过消融实验验证了 GDUNet 模型中各模块的有效性, 实验结果如表 2 所示, 本文提出的网络模型各项评价指标均达到了最优, 并使用粗体标

记,相似系数从 UNet 的 0.847 3 提高到 0.901 8;平均交并比从 UNet 的 0.765 5 提高到 0.835 4;精确率从 UNet 的 0.790 8 提高到 0.913 5,分别提高了 6.43%, 9.13%, 15.51%。此外,只引入 group-DSC 模块,分割指标相较 UNet 有所提高,说明有效的编码网络可以获得更具体的特征信息。同时,引入 dense-RES 模块使分割结果在对局部细节的捕捉上表现得更好,说明该模块增强了特征提取和融合的能力。实验结果表明,该方法提升了整体分割性能,可以为异常曝光情况下的光条纹分割任务提供很大帮助。

为进一步验证 GDUNet 模型的综合性能,将其与针对半透明光学元件光条纹分割网络(LL-Net)进行对比^[15]。从核心指标来看,GDUNet 的相似系数、平均交并和精确率分别高于 LL-Net 的 0.885 9, 0.825 6 和 0.902 7, GDUNet 在光条纹分割精度上展现出明显优势。同时, GDUNet 的网络

参数量明显低于 LL-Net 的 79.764×10^6 , 参数量效率更优。这一差异源于两者结构设计的侧重。LL-Net 依赖多尺度子网络与残差网络 34 层编码器实现抗干扰分割,虽提升了特征捕捉范围,但导致参量冗余;而 GDUNet 通过 group-DSC 轻量化编码器结合 dense-RES 精准解码器的协同设计,在抑制异常曝光干扰、强化光条纹细节分割的同时,有效控制了参数量规模,更适配工业场景下光条纹分割的需求。group-DSC 模块采用 4 分组卷积拆分通道、深度可分离卷积拆解空间与通道映射,大幅削减了编码器的参数量冗余,成为轻量化模型的核心;dense-RES 模块通过密集连接让每层卷积融合前序特征,需承载更多通道计算,虽然导致参数量增长,但为高精度模型提供关键支撑。两者通过互补逻辑结合,既避免了单一轻量化导致的特征贫瘠,也规避了单纯增加参数量造成的冗余,实现了精度与参数量的平衡。

表 2 使用不同算法的消融实验结果
Table 2 Ablation experiment results using different algorithms

评价指标	FCN	LL-Net	UNet	UNet+group-DSC	UNet+dense-RES	GDUNet
F_{Dice}	0.819 5	0.885 9	0.847 3	0.884 2	0.888 3	0.901 8
F_{mIoU}	0.734 2	0.825 6	0.765 5	0.811 3	0.816 8	0.835 4
F_{Pre}	0.790 7	0.902 7	0.790 8	0.868 1	0.884 8	0.913 5
参数量 $\times 10^{-6}$	10.593	79.764	34.531	29.865	98.742	67.439

为了验证本文算法在异常曝光场景下的光条纹分割性能,选取不同曲率的反射物体和不同背景干扰的场景作为测试对象。不同算法的光条纹分割结果如图 4 所示,阈值大津(Otsu)法、全卷积网络模型(FCN)和 UNet 模型的分割结果明显存在较大的误差,尤其容易受到背景以及光照条件的干扰。此外,在 UNet 模型上分别加入 group-DSC 模块和 dense-RES 模块,虽然在整体上可以获得较好的分割效果,但是当线激光照射在圆柱形金属工业零件表面时,无法有效分割圆弧形光条纹的局部过曝光点。LL-Net 视觉上的分割效果与 GDUNet 相近,能一定程度抑制背景干扰与弱曝光区域误分割,但从分割核心指标来看,仍和本文算法有一定差距。相比之下,本文提出的 GDUNet 模型可以更加有效地抑制光照不均匀、背景干扰以及条纹反射引起的局部异常曝光的影响,为后续的中心线提取实验提供了坚实的基础,有助于提高整体光条纹中心线提取方法的精度和鲁棒性。

2.5 中心线提取实验

为了评估光条纹中心线提取的精度,本文测

试了 Steger 光条纹中心提取算法与各种分割算法相结合的精度。Steger 算法作为亚像素级光条纹中心定位的经典方法,其精度依赖于输入光条纹区域的纯度与完整性,而不同分割算法的输出质量存在显著差异,因此,测试实验需要严格确保 Steger 算法参数一致性,排除 Steger 算法自身参数波动对评估结果的干扰。

本文计算了使用 Steger 算法结合最佳光条纹分割网络 GDUNet 的中心线提取过程的坐标,将 Steger 算法应用于基础真值标签作为比较参考。此外,使用 Otsu 算法进行光条纹分割,然后使用 Steger 算法进行中心线提取。提取的中心线被高亮突出显示,并与原始图像合并以实现可视化,如图 5 所示。为量化提取精度,实验测量前 5 张最具代表性图像的均方误差(mean squared error, MSE),该指标的定义为“提取中心线像素坐标与基础真值标签坐标的欧氏距离平方均值”,直接反映光条纹中心定位的偏差程度,如表 3 所示。此外,还计算了另外 20 张测试图像的均方误差,图 6 为 Otsu-Steger, FCN-Steger, UNet-Steger 以及本文提出的 GDUNet-Steger 深度学习方法的均

方误差对比,以此对比不同光条纹中心提取方法在精度和鲁棒性上的差异验证 GDUNet-Steger 方法在复杂工业环境下的综合优势.




图 4 使用不同算法的光条纹分割结果

Fig. 4 Light stripe segmentation results using different algorithms

(a)—输入图像; (b)—背景真值; (c)—Otsu; (d)—FCN; (e)—LL-Net; (f)—UNet; (g)—UNet+group-DES; (h)—UNet+dense-RES; (i)—本文算法.




图 5 光条纹中心线提取结果

Fig. 5 Extraction results of light stripe centerline

(a)—Otsu-Steger; (b)—背景真值-Steger; (c)—GDUNet-Steger.

图 5 表明,本文提出的 GDUNet-Steger 算法取得了与在背景真值标签上使用 Steger 算法相近的结果,并且显著优于 Otsu-Steger 算法. Otsu-Steger 算法存在对过曝光条纹中心过度提取,欠曝光条纹中心提取断裂,以及提取结果易受背景噪声干扰等问题.在 Otsu-Steger 算法中,为达到最优结果,需要执行拓扑打开和关闭操作等预处

理步骤,手动调整其高斯滤波器参数以及 Otsu 法分割阈值,极大增加了工业场景下的操作复杂度.相比之下,使用本文提出的 GDUNet 模型进行光条纹分割,可以适应更多异常曝光情况并有效避免这些问题.

表 3 不同光条纹中心提取算法的均方误差
Table 3 Mean square error of different light stripe centerline extraction algorithms

算法	图像 1	图像 2	图像 3	图像 4	图像 5	平均值
Otsu-Steger	67.48	51.02	68.04	61.50	57.46	61.10
FCN-Steger	36.53	31.95	29.02	8.61	13.66	23.95
UNet-Steger	17.33	19.42	21.34	2.90	3.71	12.96
GDUNet-Steger	10.38	7.74	9.38	2.51	2.24	6.45

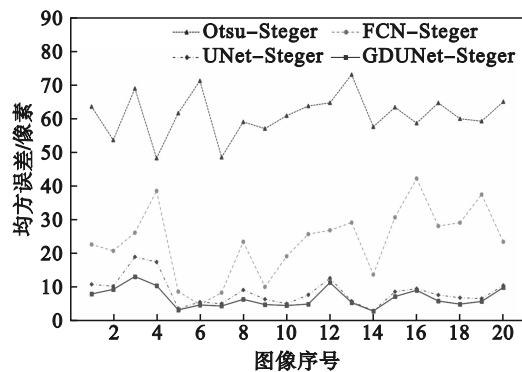


图 6 测试图像的均方误差结果

Fig. 6 Mean square error results of test images

表3给出了本文提出的GDUNet-Steger, FCN-Steger, UNet-Steger和传统的Otsu-Steger算法的均方误差比较.本文算法的均方误差比UNet-Steger算法降低了50.23%.实验证明,本文算法结合了改进的UNet结构和Steger算法的亚像素级定位优势,在准确定位光条纹中心的同时,显著减少了均方误差,提升了结果的可靠性.此外,与传统的Otsu-Steger算法相比,本文算法也取得了更优的光条纹中心提取结果,不仅能够应对噪声、异常曝光等复杂情况,对不同曲率的工业零件表面也能稳定输出连续、完整的光条纹中心线,还能够避免因全局阈值选取不当引起的误差.

3 结 语

针对复杂环境下光条纹图像因异常曝光和背景噪声干扰导致光条纹中心提取困难的问题,提出了一种基于多重卷积、特征融合和注意力机制的改进型UNet模型,即GDUNet.该模型充分利用了深度学习在特征学习方面的优势,有效地克服了异常曝光、局部反射以及背景噪声对光条纹分割带来的影响.本文引入Steger算法对分割后的光条纹图像进行精确的中心线提取,确保了高精度的中心定位.实验结果表明,本文算法在光条纹分割任务中的相似系数、平均交并比和精确率分别为0.901 8, 0.835 4, 0.913 5,比基准模型UNet提升了6.43%, 9.13%, 15.51%,同时均方误差为6.45像素.这表明本文将深度学习与传统算法结合的方式,能够在复杂环境下取得更优的结果,提供了一种有效的光条纹中心提取新方法.

参考文献:

- [1] Yang L, Fan J F, Huo B Y, et al. Image denoising of seam images with deep learning for laser vision seam tracking [J]. *IEEE Sensors Journal*, 2022, 22(6): 6098-6107.
- [2] Li W M, Wei C N, Chen S B, et al. Narrow weld joint recognition method based on laser profile sensor [J]. *IEEE Sensors Journal*, 2023, 23(2): 1295-1307.
- [3] Leal-Junior A, Guo J J, Min R, et al. Photonic smart bandage for wound healing assessment [J]. *Photonics Research*, 2021, 9(3): 272-280.
- [4] Min R, Ortega B, Marques C. Fabrication of tunable chirped mPOF Bragg gratings using a uniform phase mask [J]. *Optics Express*, 2018, 26(4): 4411-4420.
- [5] 张铤, 夏雨风, 王梓琦, 等. 基于骨架邻近像素匹配的光条纹中心提取方法 [J]. *东北大学学报(自然科学版)*, 2023, 44(11): 1529-1536.
(Zhang Yao, Xia Yu-feng, Wang Zi-qi, et al. Extraction method of light stripe center based on the matching of adjacent pixels of skeleton [J]. *Journal of Northeastern University (Natural Science)*, 2023, 44(11): 1529-1536.)
- [6] 杨建华, 杨雪荣, 成思源, 等. 线结构光三维视觉测量中光条纹中心提取综述 [J]. *广东工业大学学报*, 2014, 31(1): 74-78.
(Yang Jian-hua, Yang Xue-rong, Cheng Si-yuan, et al. Review of extracting the centers of linear structured light stripes for 3D visual measurements [J]. *Journal of Guangdong University of Technology*, 2014, 31(1): 74-78.)
- [7] Zhang T Y, Suen C Y. A fast parallel algorithm for thinning digital patterns [J]. *Communications of the ACM*, 1984, 27(3): 236-239.
- [8] Zhou P, Xu K, Wang D D. Rail profile measurement based on line-structured light vision [J]. *IEEE Access*, 2018, 6: 16423-16431.
- [9] 梅峻华, 赖磊捷. 结构光测量系统光条纹中心提取算法研究 [J]. *电子测量技术*, 2018, 41(21): 8-13.
(Mei Jun-hua, Lai Lei-jie. Research on extraction algorithm of light strip center in structured light measurement system [J]. *Electronic Measurement Technology*, 2018, 41(21): 8-13.)
- [10] Park J, Kim C, Na J, et al. Using structured light for efficient depth edge detection [J]. *Image and Vision Computing*, 2008, 26(11): 1449-1465.
- [11] 胡斌, 李德华, 金刚, 等. 基于方向模板的结构光条纹中心检测方法 [J]. *计算机工程与应用*, 2002(11): 59-60, 109.
(Hu Bin, Li De-hua, Jin Gang, et al. New method of obtaining the center of structured light stripe by direction template [J]. *Computer Engineering and Applications*, 2002(11): 59-60, 109.)
- [12] Steger C. An unbiased detector of curvilinear structures [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1998, 20(2): 113-125.
- [13] 张宇, 黄丹平, 田颖, 等. 复杂物体线结构光中心线提取方法研究 [J]. *电子测量技术*, 2023, 46(1): 167-172.
(Zhang Yu, Huang Dan-ping, Tian Ying, et al. Research on extraction method of structured light center line of complex object [J]. *Electronic Measurement Technology*, 2023, 46(1): 167-172.)
- [14] Ye C A, Li Y H, Wang C, et al. A method of binocular laser 3D scanning imaging for reflective workpieces [J]. *IEEE Sensors Journal*, 2023, 23(13): 15188-15198.
- [15] Jiang H, Fu W J, Zhang X M, et al. Extraction of laser stripe centerlines from translucent optical components using a multi-scale attention deep neural network [J]. *Measurement Science and Technology*, 2024, 35(8): 085404.
- [16] 张勇婷, 李锋. 基于改进UNet网络的线结构光光条纹中心提取 [J]. *计算机与数字工程*, 2023, 51(9): 2092-2097.
(Zhang Yong-ting, Li Feng. Center extraction of line structured light strip based on improved UNet network [J]. *Computer & Digital Engineering*, 2023, 51(9): 2092-2097.)
- [17] Guo X Z, Shi Z Y, Yu B, et al. 3D measurement of gears based on a line structured light sensor [J]. *Precision Engineering*, 2020, 61: 160-169.
- [18] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 6848-6856.
- [19] Lin Z C, Li S Y, Jiang Y Z, et al. Feedback multi-scale residual dense network for image super-resolution [J]. *Signal Processing: Image Communication*, 2022, 107: 116760.