

DOI:10.19651/j.cnki.emt.2519603

面向航空发动机涡轮叶片表面缺陷的 Swin-DCUnet 分割及评估方法^{*}

何振华¹ 刘桂雄¹ 黎文富²

(1. 华南理工大学机械与汽车工程学院 广州 510640; 2. 广东光电杰泰技术有限公司 广州 510640)

摘要: 航空发动机涡轮叶片作为关键零部件,长时间服役后极易出现裂纹、烧伤等表面缺陷,直接影响飞机安全高效运行。针对普通机器视觉方法或语义分割方法对复杂环境下叶片缺陷分割效果局限性,本文提出一种航空发动机涡轮叶片表面缺陷的 Swin-DCUnet 分割及评估方法,重点研究其语义分割模型 Swin-DCUnet,它选用适用不同尺度特征提取的 Swin-Transformer 作为特征提取器,并与全卷积操作提取特征双通道融合,再引入混合损失函数,从而提升模型收敛速度及分割准确;研发模型预测分割结果与相关定量分析结合的等级评估方法,完成叶片表面缺陷危害严重性评估,为后续叶片检修工作提供参考。构建数据集与试验评价指标,开展相关消融实验,结果表明 Swin-DCUnet 指标 AR、AF1、mIoU、Dice 分别达到 92.18%、92.92%、87.44%、47.85%,具有先进性、有效性、实用性。

关键词: 航空发动机涡轮叶片;语义分割;U-Net;缺陷评估

中图分类号: TN958.98;TM75;TP391.4 **文献标识码:** A **国家标准学科分类代码:** 460.4030

Aero-engine turbine blade surfaces defect based on Swin-DCUnet segmentation and assessment method

He Zhenhua¹ Liu Guixiong¹ Li Wenfu²

(1. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou 510640, China;

2. Guangdong Photoelectric Jitai Technology Co., Ltd., Guangzhou 510640, China)

Abstract: As critical components of aero-engines, turbine blades are prone to defects such as cracks, burns after long-term service, which can directly affect the safe and efficient operation of aircraft. To address the limitations of conventional machine vision or semantic segmentation methods in accurately segmenting blade defects under complex conditions, this paper proposes a Swin-DCUnet-based segmentation and assessment method for aero-engine turbine blade surface defects. The core of this approach is the semantic segmentation model Swin-DCUnet, which employs the Swin Transformer—capable of extracting multi-scale features—as the backbone feature extractor. The extracted features are fused through a dual-channel convolutional process, and a hybrid loss function is introduced to improve model convergence speed and segmentation accuracy. Furthermore, a defect severity grading method is developed by integrating the predicted segmentation results with quantitative analysis, providing a valuable reference for subsequent blade maintenance. A dedicated dataset and evaluation metrics are constructed, and ablation experiments are conducted. Results show that the proposed Swin-DCUnet achieves AR, AF1, mIoU, and Dice scores of 92.18%, 92.92%, 87.44%, and 47.85%, respectively, demonstrating its advancement, effectiveness, and practicality.

Keywords: aero-engine turbine blades; semantic segmentation; U-Net; defect assessment

0 引言

航空发动机涡轮叶片(aero engine turbine blade, ATB)作为航空发动机关键零部件,长期工作于高温、高

压、环境恶劣工况下,极易产生裂纹、烧伤等表面缺陷,进一步可导致叶片失效,引发发动机故障^[1]。目前接近90%的涡轮叶片检测与评估方法采用内窥镜视觉人工测量,存在主观性强、准确度低、劳动强度大等问题^[2]。随着人工智能

收稿日期:2025-08-14

^{*} 基金项目:广东省重点领域研发计划项目(2019B010154003)资助

技术发展,基于图像 RGB 属性目标语义分割涡轮叶片检测技术研究也取得较大进展^[3-4]。同时,文献[5](2022)为提取损伤类别纹理信息,研究注重纹理的多尺度特征融合网络,引入 Balanced L1 损失函数去调节样本梯度及损失,较好地实现粗、细粒度定位平衡,在航空发动机受损叶片数据集上进行实验,mAP 仅达 61.2%;文献[6](2024)为精确分割甲状腺癌,研究双解码器 Transformer 架构的 DualSwinUnet++,在包含 691 张标注 RFA 图像的临床超声数据集上 Dice、Jaccard 分别为 84.36%、71.23%,但未解决 SwinUnet 细节提取能力弱,分割结果存在噪点问题;文献[7](2025)研究基于 Transformer 的 BWFormer 建筑三维重建方法,结果表明该优于其他最新方法,但其没有用于含缺陷的三维重建领域,计算量较大。

为此,本文针对 SwinUnet 细节特征提取能力较弱,同时考虑 ATB 表面缺陷裂纹、烧伤特点,提出面向 ATB 表面缺陷的 Swin-Transformer 与全卷积双通道融合网络(dual-channel U-Net with swin-transformer and convolutional fusion for surface defect segmentation, Swin-DCUnet)分割及评估方法。选用编码器为 Swin-Transformer^[8] 的类 U-net^[9]语义分割模型,通过添加全卷积通道(pure-convolutional channel^[10], PCC),加强细节特征提取,且实现非目标类与目标类间平滑过渡;设计融合 Dice^[11]损失 +

CE^[12](cross entropy, CE)损失混合损失函数,改善模型优化效果,提高缺陷分割准确率。采用自制 ATB 表面缺陷数据集,验证 Swin-DCUnet 语义分割模型科学性、有效性;针对点云三维重建计算量大问题,研发融合缺陷三维重建算法与相关定量分析的等级评估方法,避免无用点云的重建,实现 ATB 表面缺陷严重性评估^[13-14]。

1 Swin-DCUnet 分割与评估方法总体设计

总体设计思路是内窥镜检测 ATB 表面缺陷处于狭小昏暗环境、缺陷形态各异,且部分缺陷(裂纹)细节信息难以单独靠提取器 Swin-Transformer 完成,采用双通道语义分割网络 Swin-Transformer(提取高级语义特征)+Pure Convolutional(提取细节语义特征),对两种通道互补信息进行特征融合准确地获取表面缺陷掩膜,再由掩膜重建、提取缺陷三维点云与特征,完成缺陷等级评估。

图 1 为 ATB 表面缺陷分割与评估原理框图,双目内窥镜采集 ATB 表面缺陷 RGB 图像,一方面经 Swin-DCUnet 网络预测缺陷掩膜,另一方面双目 RGB 图像得视差图,由缺陷掩膜、视差图重建、提取缺陷三维点云及特征,结合缺陷评估依据得缺陷评估等级。Swin-DCUnet 是完成整个算法核心,实现 ATB 表面缺陷特征提取、通道特征融合与掩膜预测任务。




图 1 ATB 表面缺陷分割与评估方案

Fig. 1 Framework for segmentation and evaluation of surface defects on ATB

图 2 为 ATB 表面主要缺陷图像,根据它们缺陷形态特征进行分类与评估。表 1 为缺陷严重程度分级示例,缺陷分为 I(轻微损伤)、II(一般损伤)、III(严重损伤)、IV(重大损伤)4 个等级。具体到缺陷类型,本文有别于其他 ATB 表面缺陷目标检测和语义分割方法仅能定位与识别缺陷^[15-16],通过更为细致语义分割目标提取方法,捕捉像素级区域并赋予语义标签,获得缺陷掩膜及量化缺陷特征,裂纹缺陷可根据最大外接圆柱法计算裂纹最大长度 $L_{\max}$ 、宽度 W ,确定裂纹缺陷等级;烧伤缺陷可根据三角剖分法计算烧伤面积占比 P_{burn} ,确定烧伤等级。




图 2 ATB 表面主要缺陷图像

Fig. 2 Typical images of primary surface defects on ATB

表 1 缺陷严重程度分级示例

Table 1 Example of grading for defect severity

类别	缺陷描述	缺陷等级
裂纹	裂纹最大长度 $0\text{ mm} < L_{\max} \leq 1\text{ mm}$	I
	裂纹最大长度 $1\text{ mm} < L_{\max} \leq 3\text{ mm}$, 且宽度 $0\text{ mm} < W \leq 2\text{ mm}$	II
	裂纹最大长度 $1\text{ mm} < L_{\max} \leq 3\text{ mm}$, 且宽度 $2\text{ mm} < W \leq 3\text{ mm}$	III
	裂纹最大长度 $L_{\max} > 3\text{ mm}$	IV
烧伤	烧伤面积占比 $0 < P_{\text{burn}} \leq 10\%$	I
	烧伤面积占比 $10\% < P_{\text{burn}} \leq 15\%$	II
	烧伤面积占比 $15\% < P_{\text{burn}} \leq 20\%$	III
	烧伤面积占比 $P_{\text{burn}} > 20\%$	IV

2 Swin-DCUnet 网络结构

图 3 为本文提出面向 ATB 缺陷语义分割 Swin-DCUnet 模型结构图,它是一个类 U-Net 语义分割模型,主通道为 Swin-Transformer,副通道为 Pure Convolutional,将双通道特征进行融合,融合特征结果作为 Swin-DCUnet 网络的输出。

2.1 主通道 Swin-Transformer 提取高级语义特征

类 U-Net 网络编码结构层次相对较浅,学习能力受限,可选用 Swin-Transformer 作为 Swin-Transformer Channel 主通道的特征提取器,完成 ATB 表面缺陷特征提取与形态分割工作。Swin-Transformer 具备分层架构以捕捉不同尺度特征,以移动窗口机制降低计算复杂度,加强局部、全局信息交互,具有强大图像特征提取和建模能力,在处理高分辨率图像时展现出高效性和灵活性,能快速收敛模型,提升语义分割模型性能与泛化能力。其中:

1) 编码器采用 Swin-Transformer 模块。通过 Patch Partition 与 Linear Embedding 模块,尺寸为 $H \times W \times C$ 的输入图像被划分为 $N = (H \times W)/(P \times P)$ 个尺寸为 $P \times P \times C$ 的 Patch,经线性变换映射到低维嵌入空间,经过 Swin Transformer Block 提取局部、全局特征。Patch Merging 对特征图下采样,降低特征图分辨率,增加通道数,逐步提取图像的高层次语义信息^[17]。

2) 解码器也采用 Swin-Transformer 模块(同层 Patch 数量、尺寸与编码器相同)。通过 Patch Expanding 对特征图上采样,增加特征图分辨率,减少通道数,为后续恢复图像细节做准备。Skip Connection 与 Swin Transformer Block 将编码器对应层级特征图与当前层经过上采样特征图进行融合,完成高级语义特征与浅层特征相融合,改善上采样信息量,有效提升分割准确度。最后用 1×1 卷积的 Linear Projection 模块从特征维度映射到分割任务所需类别维度,获得分割结果^[18]。

2.2 副通道 Pure Convolutional 提取细节特征

主通道 Swin-Transformer 对于目标与背景相似特征学习能力差,ATB 表面缺陷中呈现细小树枝状裂纹缺陷等




图 3 面向缺陷语义分割 Swin-DCUnet 模型结构图

Fig. 3 Structural diagram of the Swin-DCUnet model oriented to defect semantic segmentation

细节信息难以捕捉,为此 Swin-DCUnet 模型主通道为

Swin-Transformer, 侧重提取高级语义特征、恢复图像空间分辨率, 副通道为 Pure Convolutional, 采用大卷积内核且无下采样、上采样, 保持原始分辨率对图像卷积, 有利于捕捉图像细节信息, 主副双通道优势互补, 提升图像分割准确性。图 4 为 Pure Convolutional 结构图, 它由 5 个串行连接、内核大小分别为 11、5、5、5、11 的残差块 (Residual Block) 和 1 个用于分类的 1×1 标准卷积层组成, 每个残差块由 2 个卷积层、2 个批量归一化层和 1 个残差连接构成, 提取输入图像的多层次特征, 输出分类结果。




图 4 Pure Convolutional Channel 结构图

Fig. 4 Architecture of the Pure Convolutional Channel

2.3 跨通道特征融合

记主通道 Swin-Transformer、副通道 Pure Convolutional 提取特征分别为 F_{main} 、 $F_{auxiliary}$, 将 F_{main} 与 $F_{auxiliary}$ 级联 $\parallel$, 通过卷积将多尺度级联特征展平成两个特征图 G_{main} 、 $G_{auxiliary}$, 即:

$$[G_{main}, G_{auxiliary}] = \text{Conv}(F_{main} \parallel F_{auxiliary}) \quad (1)$$

将 G_{main} 、 $G_{auxiliary}$ 通过 softmax 函数逐像素归一化, 得三维类别概率矩阵 A_{main} 、 $A_{auxiliary}$ 。令语义类别为 C , c 为 C 中某一类, 它们在图像坐标 (i, j) 处满足:

$$\sum_{c=1}^C A_{main}(i, j, c) = \sum_{c=1}^C A_{auxiliary}(i, j, c) = 1 \quad (2)$$

将 A_{main} 、 $A_{auxiliary}$ 逐类别相加 $\oplus$, 得到跨通道融合特征 M :

$$M(i, j, c) = \sum_{c=1}^C (A_{main}(i, j, c) \oplus A_{auxiliary}(i, j, c)) \quad (3)$$

这样完成跨通道特征融合。

2.4 $Loss_{Dice}$ 与 $Loss_{CE}$ 混合损失函数构建

ATB 裂纹缺陷占比少、背景多, 可采用 Dice 损失函数 $Loss_{Dice}$ 。令单类像素总数为 N , 第 i 个像素隶属第 c 类的预测概率为 $p_{c,i}$, 第 i 个像素的真实标签是否属于第 c 类的判别为 $g_{c,i}$, c 的类别权重为 w_c , 则相似度度量函数表示的 $Loss_{Dice}$ 为:

$$Dice = \frac{1}{\sum_{c=1}^C w_c} \left(\sum_{c=1}^C w_c \frac{2 \sum_{i=1}^N p_{c,i} g_{c,i} + smooth}{\sum_{i=1}^N p_{c,i} + \sum_{i=1}^N g_{c,i} + smooth + eps} \right) \quad (4)$$

$$Loss_{Dice} = 1 - Dice, Loss_{Dice} \in [0, 1] \quad (5)$$

$Loss_{Dice}$ 越接近 1, 分割精度越高。若 ATB 裂纹缺陷

过小, 不稳定的 $Loss_{Dice}$ 计算, 将导致训练过程的较大波动, 此时可使用交叉熵损失函数 $Loss_{CE}$ 。

交叉熵损失基于概率概念, 能衡量预测概率分布和真实标签之间差异, 其计算值是目标、背景区域中所有像素交叉熵, 令 batch 大小为 N_{batch} , 真实类别为 y_i , 第 i 个样本在真实类别 y_i 上的预测概率为 $p_{y_i,i}$, y_i 的类别权重为 w_{y_i} , 则 $Loss_{CE}$ 损失函数为:

$$Loss_{CE} = -\frac{1}{N_{batch}} \sum_{i=1}^{N_{batch}} w_{y_i} \log(p_{y_i,i}), Loss_{CE} \in [0, 1] \quad (6)$$

$Loss_{CE}$ 数值稳定性优异, 可在预测结果与真实标签完全不重叠时缓解 $Loss_{Dice}$ 可能出现的梯度爆炸, 但它更关注图像中占比大的类别, 可能忽视占比小的类别, 而 $Loss_{CE}$ 受类别不平衡影响较小。兼顾二者优劣, 本文提出一种 $Loss_{Dice}$ 与 $Loss_{CE}$ 混合损失函数, 采用权重影响因子 λ 改变两个损失函数比重, 构造 $Loss$ 如下:

$$Loss = \lambda Loss_{Dice} + (1 - \lambda) Loss_{CE}, \lambda \in [0, 1] \quad (7)$$

上面从面向缺陷语义分割的 Swin-DCUnet 网络结构、添加副通道 Pure Convolutional 实现细节特征提取、 $Loss_{Dice}$ 与 $Loss_{CE}$ 混合损失函数三个方面论述应用 Swin-DCUnet 的 ATB 表面缺陷分割方法, 具体效果如何, 下面将加以实验验证。

3 Swin-DCUnet 的 ATB 表面缺陷分割实验

3.1 缺陷数据集制作与参数设置

本文初始数据图像采自某航空发动机涡轮叶片维修公司, 随机选取含缺陷叶片并进行编号, 按照叶片编号将图像分成 2 批, 同一叶片所有图像严格划分至同一数据集, 保证训练集与测试集互不重叠, 由手持式成像装备装载双目内窥镜拍摄 ATB 表面缺陷 RGB 图像, 终端计算机收集获得共 287 张图像, 其中第 1 批叶片得到的 201 张缺陷图像是训练集, 第 2 批叶片得到的 86 张缺陷图像是测试集, 训练集和测试集比例为 7:3, 采用开源软件 Labelme 进行手动标记标签, 获得 mask 掩膜。由于双目内窥镜的运动特性, 可能产生图像拍摄方向、背景亮度变化等问题, 为模拟真实图像情况, 增强数据训练鲁棒性, 采用空间变换、随机亮度、对比度调整等数据增强方法获得图像共 861 张。

图 5 为部分数据集图像, 包含缺陷样例约 1 000 个, 标签为烧伤、裂纹与非目标共 3 类, 每张图像分辨率大小为 768×768 。

实验采用搭载 NVIDIA GeForce RTX 3090 的 Pytorch 网络框架^[19], 训练过程使用 AdamW 权重衰减优化器^[20]。设置初始学习率 Learning rate=0.001, 批量大小 Batchsize=2, 单轮迭代次数 steps_per_epoch=2 000, 训练轮数 Epoch=20, 总计迭代 40 000 次。



图 5 ATB 表面缺陷分割结果图

Fig. 5 Segmentation results of surface defects on ATB

3.2 算法性能评价指标

语义分割中通常使用像素精度 PixAcc (pixel accuracy, PixAcc)^[21] 及交并比 (intersection over union, IoU)^[22] 衡量算法精度, 本文使用平均召回率 (average recall, AR)^[23]、平均 F1 分数 (average F1 score, AF1)、平均交并比 (mean intersection over union, mIoU) 以及戴斯相似系数 (dice coefficient, Dice)^[24], 这些指标物理意义强调如下: 1) 平均召回率 AR 多适用于多分类, 关注漏检率, 数值越大, 则真实目标识别越全面、漏检越少; 2) 平均 F1 分数 AF1 对样本数量少类别较敏感, 数值越大, 则模型在各类别上表现越均衡, 即模型受类别失衡影响越小; 3) 平均交并比 mIoU 反应整体性能, 数值越大, 则模型在所有类别上平均分割效果越好, 即预测结果与真实标签交集占比高; 4) 戴斯相似系数 Dice 衡量预测结果与真实标签相似度, 数值越大, 则表示单个预测区域与真实标签重叠程度越高, 小目标区域预测越正确。

3.3 试验与结果分析

图 6 为损失函数 Loss 随迭代次数变化曲线, 横坐标为迭代次数, 纵坐标为损失函数 Loss。可以看出, 迭代次数增加, Loss 趋于减少, 在迭代次数接近 40 000 次时训练收敛, 图中折线存在上下波动现象, 可能是每次迭代使用小批量训练数据, 该数据不是全体训练数据的代表, 而且为防止陷入局部最优解, AdamW 优化器在特定迭代次数将自动重启, 学习率过大导致 Loss 波动, 但随着迭代次数增加, 特征学习更加稳定, 模型能更全面利用数据信息, 最终

各参数收敛, Loss 值达到最小值, AR、AF1、mIoU 和 Dice 分别为 92.18%、92.92%、87.44%、47.85%, 得到模型最优参数。




图 6 损失函数 Loss 随迭代次数变化曲线

Fig. 6 Curve of Loss function variation with iterations

下面设计消融实验, 采用消融研究来描述去除网络某些部分过程, 更好地理解网络行为与性能, 证明本文 Swin-DCUnet 的科学性、合理性、有效性。

消融实验用 2.1 节的数据集、参数配置, 对 U-net、Swin-Unet、Swin-DCUnet, Loss + Swin-Unet、Loss + Swin-DCUnet 等模型模块行为进行研究。

表 2 为消融实验性能结果表。可以看出, Swin-Unet 原始网络 AR、AF1、mIoU、Dice 分别为 85.81%、88.56%、81.48%、40.44%; Swin-DCUnet 将主通道 Swin-Transformer 与副通道 Pure Convolutional 融合, AR、AF1、mIoU、Dice 分别提高 0.28%、1.1%、1.26%、1.49%, 可见副通道 Pure Convolutional 融合可提升分割精度; Loss + Swin-Unet 引入混合损失函数 Loss, AR、AF1、mIoU、Dice 分别提高 5.75%、3.42%、4.54%、5.50%, Loss 不仅减轻类别失衡, 还弥补梯度爆炸, 优化不同目标分割结果; Loss + Swin-DCUnet 将原始网络、副通道 Pure Convolutional、混合损失函数 Loss 融合, 性能更优, AR、AF1、mIoU、Dice 分别为 92.18%、92.92%、87.44%、47.85%, 分别提升 6.37%、4.36%、5.96%、7.41%。由此说明, Loss + Swin-DCUnet 模型具有先进性, 总体检测精度, 局部检测精度达到较高水平。

表 2 消融实验性能结果

Table 2 Performance results of ablation experiments

模型名称	AR	AF1	mIoU	Dice
Swin-Unet	85.81±0.14	88.56±0.11	81.48±0.22	40.44±0.26
Swin-DCUnet	86.09±0.09	89.66±0.08	82.74±0.21	41.93±0.17
Loss+ Swin-Unet	91.56±0.11	91.98±0.08	86.02±0.17	45.94±0.18
Loss+Swin-DCUnet	92.18±0.04	92.92±0.06	87.44±0.13	47.85±0.14

下面与目前主流语义分割模型检测效果比较,验证本文模型 Swin-DCUnet 先进性、实用性。表 3 为对比实验性能结果,应用前面 2.1 节的数据集、参数配置对 U-net、Swin-Unet、TransUnet^[25]、UCTransnet^[26] 开展对比实验,分别获得 AR、AF1、mIoU 和 *Dice* 指标。可见 Swin-DCUnet 除 AR 指标略低 UCTransnet 外,该模型性能最优。

为直观体现不同模型分割效果,选取 4 幅图像进行定性结果分析,图 7 为不同模型可视化分割结果,其中(a)~(g)分别代表原始图像、标签图像、Swin-Unet 预测结果、U-net 预测结果、TransUnet 预测结果、UCTransnet 预测结果、Swin-DCUnet 预测结果。

由图 7 可看出,针对烧伤缺陷(掩膜图中灰色区域),Swin-DCUnet 能准确分割烧伤缺陷与非目标区域,较

表 3 对比实验性能结果

Table 3 Results of comparative study on model performance %				
模型名称	AR	AF1	mIoU	<i>Dice</i>
Swin-Unet	85.81	88.56	81.48	40.44
U-net	72.78	71.53	61.16	28.01
TransUnet	87.92	88.60	81.05	42.92
UCTransnet	93.04	92.69	87.08	47.55
Swin-DCUnet	92.18	92.92	87.44	47.85

Swin-Unet 细节特征提取更充分,而 U-net、TransUnet 存在错误判断缺陷类型情况,UCTransnet 烧伤缺陷分割效果良好;针对裂纹缺陷(掩膜图中白色区域),Swin-DCUnet 能更精确分割,U-net 存在错误判断缺陷类型情




图 7 不同模型可视化分割结果

Fig. 7 Visualized segmentation results of different models

况,TransUnet 裂纹缺陷分割效果良好,UCTransnet 与 Swin-Unet 裂纹缺陷细节特征提取较差。

从表 3 可以看出,UCTransNet、TransUnet 整体分割能力与本文网络相近,但是细节处理能力较本文网络差,体现在图 7。TransUnet 在图 7 第 5 行,第 1 列子图中,缺陷类型判断错误,在后续重建中容易导致错误评级,UCTransNet 在图 7 第 6 行,第 3 列子图中,分割裂纹缺陷粗糙,存在大量零散白色像素,后续三维重建可能将白色像素当做裂纹缺陷,提取裂纹点云三维特征(长度、宽度)虚高,故本文网络整体分割能力强,同时兼顾细节处理,更符合分割-重建-评级的任务。

4 缺陷分级评估

Swin-DCUnet 网络预测缺陷掩膜后,通过缺陷重建实现缺陷评估^[27]。ATB 表面缺陷可定级为“轻微损伤”、“一般损伤”、“严重损失”、“重大损伤”四类,其中“轻微损伤”不影响叶片正常工作;“一般损伤”不影响叶片正常工作,建议下次检修时对叶片进行打磨甚至返修;“严重损失”不影响叶片正常工作,但具有潜在安全隐患,越早更换越好;“重大损伤”影响叶片正常工作,存在重大安全隐患,建议立即更换。结合 ATB 裂纹缺陷与烧伤缺陷的特点,提出缺陷三维重建+最大外接圆柱法与三维重建+三角剖分法^[28]实现缺陷分级判断。

4.1 缺陷三维重建法

叶片三维空间结构复杂,简单二维特征无法准确衡量

叶片缺陷,需进行缺陷三维重建,记 B_{cam} 为双目相机基线长度, f_{cam} 为相机焦距, d_{px} 为视差(以像素为单位), (u_0, v_0) 为图像平面主点坐标,左图每个像素坐标为 (x, y) , $M(x, y)$ 为掩膜,三维空间坐标 (X_c, Y_c, Z_c) 和点云 P_c 满足:


$$X_c = \frac{B_{cam} f_{cam}}{d_{px}} (x - u_0), Y_c = \frac{B_{cam} f_{cam}}{d_{px}} (y - v_0) Z_c = \frac{B_{cam} f_{cam}}{d_{px}} \quad (8)$$

$$P_c = \{(X_c, Y_c, Z_c) \mid M(x, y) = c, c \in C\} \quad (9)$$


通过遍历双目左图中像素点,根据每个像素点坐标 (x, y) 以及对应掩膜值 $M(x, y)$,利用双目三维重建公式计算出其三维空间坐标 (X_c, Y_c, Z_c) ,并将具有相同掩膜值点归类到同一个点云 P_c 中,最终将掩膜值为 c 的点归类为一个点云。

4.2 最大外接圆柱法


若得到 ATB 裂纹缺陷点云,记最大长度为 L_{max} ,宽度为 W , $0 \text{ mm} < L_{max} \leq 1 \text{ mm}$,判定为“轻微损伤”, $L_{max} > 3 \text{ mm}$ 则判定为“重大损伤”, $1 \text{ mm} < L_{max} \leq 3 \text{ mm}$ 时,需考虑额外参数 W , $0 \text{ mm} < W \leq 2 \text{ mm}$,判定为“一般损伤”, $2 \text{ mm} < W \leq 3 \text{ mm}$ 则判定为“严重损失”。图 8 为裂纹缺陷评估结果示例,图 8(a)~(c)分别为裂纹缺陷示意图、裂纹缺陷三维重建示意图、裂纹缺陷评估结果示意图,图 8(a)细长白色像素条反映裂纹缺陷,图 8(c)可得出 L_{max} 为 7.26 mm 与 16.76 mm,判定为“重大损伤”。



(a) 裂纹缺陷示意图
(a) Schematic diagram of crack defect



(b) 裂纹缺陷三维重建示意图
(b) Three-dimensional reconstruction schematic of crack defect



(c) 裂纹缺陷评估结果示意图
(c) Evaluation result schematic of crack defect

图 8 裂纹缺陷评估结果示例

Fig. 8 Example of crack defect evaluation results

4.3 三角剖分法

三角剖分法是一种点云面积计算方法,它基于三点确定一平面,记 ATB 烧伤面积为 A_{burn} ,叶片总表面积为 A_{total} ,则烧伤面积占比 P_{burn} 为:

$$P_{burn} = \frac{A_{burn}}{A_{total}} \quad (10)$$

当 $0 < P_{burn} \leq 10\%$,判定为“轻微损伤”, $10\% < P_{burn} \leq$

15% ,判定为“一般损失”, $15\% < P_{burn} \leq 20\%$,判定为“严重损失”, $P_{burn} > 20\%$,判定为“重大损失”,图 9 为烧伤缺陷评估结果示例,图 9(a)~(c)分别为烧伤缺陷示意图、烧伤缺陷三维重建示意图、烧伤缺陷评估结果示意图,图 9(a)偏黑色像素块反映烧伤缺陷,图 9(c)可得 $A_{burn} = 698.00$, $A_{total} = 4111$,得 $P_{burn} = 16.979\%$,可判定为“严重损失”。




图 9 烧伤缺陷评估结果示例

Fig. 9 Example of burn defect evaluation results

5 结 论

ATB 表面裂纹、烧伤缺陷等 RGB 图像存在缺陷形态多样、裂纹缺陷细节信息难以提取特性,给高准确性语义分割带来难度,本文主要创新如下:

提出双通道融合 Swin-DCUnet 网络,主通道 Swin-Transformer、副通道 Pure Convolutional 分别关注高级语义与细节特征;引入 $Loss_{Dice}$ 与 $Loss_{CE}$ 混合损失函数缓解类别不平衡与梯度爆炸问题。

根据 ATB 裂纹缺陷与烧伤缺陷特点,分别提出三维重建+最大外接圆柱法、三维重建+三角剖分法,再根据评判依据,实现表面缺陷分级判断。

实验表明,Swin-DCUnet 语义分割网络在自制数据集上 $AR=92.18\%$ 、 $AF1=92.92\%$ 、 $mIoU=87.44\%$ 、 $Dice=47.85\%$,分割效果明显提升,方法具有准确性、科学性。

研究工作量较大,目前还处于实验室阶段,后续还需要做好现场部署以及可靠性实验工作。

参考文献

- [1] YASUDA Y D V, CAPPABIANCO F A M, MARTINS L E G, et al. Aircraft visual inspection: A systematic literature review [J]. Computers in Industry, 2022, 141: 103695.
- [2] AUST J, PONS D, MITROVIC A. Evaluation of influence factors on the visual inspection performance of aircraft engine blades [J]. Aerospace, 2021, 9(1): 18.
- [3] 汪灵姿,刘桂雄,张国才,等. 应用 VA-UNet 的 DR 图像缺陷分割与评定方法[J]. 电子测量技术, 2025, 48(6): 179-187.
WANG L Z, LIU G X, ZHANG G C, et al. Defect segmentation and evaluation method for DR images based on VA-UNet [J]. Electronic Measurement Technology, 2025, 48(6): 179-187.
- [4] 高泽铭,刘桂雄,陈国宇,等. 基于 ViT 燃气表外观零件识别与定位方法研究[J]. 电子测量技术, 2023, 46(11): 7-12.
GAO Z M, LIU G X, CHEN G Y, et al. Research on identification and localization method of gas meter appearance parts based on ViT [J]. Electronic Measurement Technology, 2023, 46(11): 7-12.
- [5] SHANG H, SUN C, LIU J, et al. Deep learning-based borescope image processing for aero-engine blade in-situ damage detection[J]. Aerospace Science and Technology, 2022, 123: 107473.
- [6] DIALAMEH M, RAJABZADEH H, SADEGHI-GOUGHARI M, et al. DualSwinUnet ++: An enhanced Swin-Unet architecture with dual decoders for PTMC segmentation[J]. Computers in Biology and Medicine, 2025, 196: 110716.
- [7] LIU Y, ZHU L, YE H, et al. BWFormer: Building wireframe reconstruction from airborne LiDAR point cloud with Transformer[C]. Computer Vision and Pattern Recognition Conference, 2025: 22215-22224.
- [8] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing And Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Springer International Publishing, 2015: 234-241.
- [10] WANG C, NING H, CHEN X, et al. Db-unet: Mlp based dual branch unet for accurate vessel segmentation in octa images [C]. 2023 IEEE International Conference on Acoustics, Speech and

- Signal Processing(ICASSP). IEEE, 2023: 1-5.
- [11] ZHAO R J, QIAN B Y, ZHANG X L, et al. Rethinking dice loss for medical image segmentation[C]. 2020 IEEE International Conference on Data Mining. Sorrento: IEEE, 2020: 851-860.
- [12] 李博, 刘会斌, 王胜辉, 等. 基于 GANR-UNet 的绝缘子红外图像分割及低零值故障诊断研究[J/OL]. 华北电力大学学报(自然科学版), 1-11[2025-09-29]. <https://link.cnki.net/urlid/13.1212.tm.20240115.1750.002>.
- LI B, LIU H B, WANG SH H, et al. Research on Infrared image segmentation of insulators and low Zero-Value fault diagnosis based on GANR-UNet[J/OL]. Journal of North China Electric Power University (Natural Science Edition), 1-11[2025-09-29]. <https://link.cnki.net/urlid/13.1212.tm.20240115.1750.002>.
- [13] ABDULRAHMAN Y, ELTOUM M A M, AYYAD A, et al. Aero-engine blade defect detection: A systematic review of deep learning models[J]. IEEE Access, 2023, 11: 53048-53061.
- [14] YIXUAN L, DONGBO W, JIAWEI L, et al. Aeroengine blade surface defect detection system based on improved faster RCNN[J]. International Journal of Intelligent Systems, 2023, 2023(1): 1992415.
- [15] JAEGER B E, SCHMID S, GROSSE C U, et al. Infrared thermal imaging-based turbine blade crack classification using deep learning [J]. Journal of Nondestructive Evaluation, 2022, 41(4): 74.
- [16] WANG D, XIAO H, WU D. Application of unsupervised adversarial learning in radiographic testing of aeroengine turbine blades[J]. NDT & E International, 2023, 134: 102766.
- [17] CAO H, WANG Y, CHEN J, et al. Swin-unet: Unet-like pure transformer for medical image segmentation[C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 205-218.
- [18] 李进, 刘立群. 基于残差 Swin Transformer 的 SAR 与可见光图像融合[J]. 计算机应用, 2025, 45(9): 2949-2956.
- LI J, LIU L Q. SAR and visible light image fusion based on Residual Swin Transformer[J]. Computer Applications, 2025, 45(9): 2949-2956.
- [19] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]. European Conference on Computer Vision (ECCV), 2018: 801-818.
- [20] LOSHCHIOV I, HUTTER F. Decoupled weight decay regularization [J]. ArXiv preprint arXiv: 1711.05101, 2017.
- [21] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [22] ZITNICK C L, DOLLAR P. Edge boxes: Locating object proposals from edges [C]. Computer Vision-ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part V 13. Springer International Publishing, 2014: 391-405.
- [23] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft coco: Common objects in context [C]. Computer Vision-ECCV 2014: 13th European Conference, 2014: 740-755.
- [24] MILLETARI F, NAVAB N, AHMADI S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation [C]. 2016 Fourth International Conference on 3D Vision(3DV). IEEE, 2016: 565-571.
- [25] CHEN J, LU Y, YU Q, et al. Transunet: Transformers make strong encoders for medical image segmentation [J]. ArXiv preprint arXiv: 2102.04306, 2021.
- [26] WANG H, CAO P, WANG J, et al. Uctransnet: Rethinking the skip connections in u-net from a channel-wise perspective with transformer[C]. AAAI Conference on Artificial Intelligence, 2022, 36(3): 2441-2449.
- [27] 曹国群, 刘桂雄. 基于双模态融合的线缆图像语义分割方法研究[J]. 电子测量技术, 2023, 46(10): 184-188.
- CAO G Q, LIU G X. Research on cable image semantic segmentation method based on bimodal fusion [J]. Electronic Measurement Technology, 2023, 46(10): 184-188.
- [28] FARHOOD H, MULLER S, BEHESHTI A. Surface area estimation using 3D point clouds and delaunay triangulation[C]. Second International Conference on Innovations in Computing Research(ICR'23). Cham: Springer Nature Switzerland, 2023: 28-39.

作者简介

何振华, 硕士研究生, 主要研究方向为 AI 与仪器仪表。

E-mail: hzh1668005@163.com

刘桂雄(通信作者), 博士, 教授, 博士生导师, 主要研究方向为现代传感与人工智能应用。

E-mail: megxliu@scut.edu.cn