

引文格式:宋敏,许悦,张吟龙.基于多模态结构感知的航空发动机叶片粗糙度测量[J].航空制造技术,2026,69(16):26010017.

SONG Min, XU Yue, ZHANG Yinlong. Aero-engine blades roughness measurement based on multimodal structure perception[J].

Aeronautical Manufacturing Technology, 2026, 69(16): 26010017.

基于多模态结构感知的航空发动机 叶片粗糙度测量

宋敏¹,许悦²,张吟龙³

(1. 沈阳工程学院计算机科学与技术学院, 沈阳 110136;

2. 东北大学计算机科学与工程学院, 沈阳 110819;

3. 中国科学院工业人工智能研究所, 南京 211135)

[摘要] 作为航空发动机的核心部件,叶片表面的粗糙度是评估发动机叶片性能的重要参数。然而传统方法受限于叶片复杂曲面的几何异质性与表面噪声干扰,易导致区域分割错误与测量结果失稳。针对上述问题,提出一种融合动态图神经网络与频域信号处理的测量方法。针对叶片复杂几何曲面导致的区域分割困难,设计了一种结构感知分割网络,该网络通过动态图卷积层自适应构建点云局部拓扑,并结合跨层级通道-空间注意力机制强化对关键区域的边界感知,实现部件级精准分割。在此基础上,提出基于均匀网格与上下文融合的粗糙度稳健量化方法。该方法通过将点云划分为均匀微元网格提取并融合微观几何特征,建模网格间的空间关联,自适应融合特征的同时抑制异常值干扰。评估结果表明,所提分割网络在叶片部件分割任务中的总体准确率(OA)达94.6%,测量结果与接触式轮廓仪对比,决定系数 R^2 达到0.97,绝对误差不超过 $0.18\text{ }\mu\text{m}$,重复性达 $\pm 0.05\text{ }\mu\text{m}$ 。所提方法实现了从区域分割到参数计算的全程稳健测量,为航空发动机叶片的在役检测、状态评估与寿命预测提供了可靠的技术支持。

关键词: 航空发动机叶片;多模态融合;点云分割;粗糙度测量;动态图卷积

中图分类号: V232.4

文献标志码: A

DOI: 10.16080/j.issn1671-833x.26010017



宋敏

副教授,研究方向为工业互联网优化、资源分配与调度。

航空工业作为国家高端装备制造业的战略制高点,集尖端技术、高密集度创新与完整产业链于一体,是体现国家综合国力与科技竞争力的关键领域^[1]。在航空发动机这一“心脏”部件中,涡轮叶片长期服役于极端高温、高压与腐蚀环境,其表面质量,尤其是表面粗糙度,直接决定了部件的空气动力学效率、疲劳寿命与整体可靠性^[2]。粗糙度超标会引发表面气流分离、阻力增加与噪声产

生,并成为应力集中点,加速疲劳裂纹萌生与扩展,严重威胁飞行安全与经济性。因此,实现叶片表面粗糙度的高精度控制与检测是保障航空发动机性能、安全与寿命的基础前提,具有重大的工程实际意义^[3-4]。

随着三维视觉与人工智能技术的快速发展,基于点云与图像融合的智能检测技术已在航空航天精密制造领域得到初步探索和应用^[5-6]。目前,针对叶片表面特征的提取与分

收稿日期: 2026-01-21; 退修日期: 2026-03-05; 录用日期: 2026-04-08

基金项目: 辽宁省自然科学基金联合基金面上项目(2023-MSLH-219)

通信作者: 宋敏,副教授。

张吟龙,研究员,研究方向为工业机器人多模态智能感知。

析,主要存在两个关键挑战:在区域分割方面,现有方法多依赖于固定几何先验或多模态特征的简单叠加,难以自适应地刻画叶片转接区、缘板等复杂曲面的拓扑结构与边界细节,导致在弱纹理、高曲率区域分割精度不足;在粗糙度量化方面,传统测量方法往往直接对全域点云进行统计,无法对表面信号中噪声、宏观形貌与微观纹理进行有效分离,在复杂曲面条件下易受异常点与区域异质性的干扰,影响测量的稳健性与重复性。

在此背景下,对叶片制造过程实施在线、实时、高精度的质量检测,以实现工艺闭环控制与全生命周期质量追溯,已成为智能制造体系的迫切需求。然而,叶片点云数据的精准分割是实现在线检测的首要步骤与关键前提。传统点云分割方法高度依赖于预设参数与理想几何假设,在面对复杂叶片、连续的异质曲面时,其分割边界往往模糊且不稳定,难以满足高精度工业检测对区域定义一致性的严苛要求。为突破传统方法的局限性,基于深度学习的点云分割技术通过数据驱动的方式,为复杂几何结构的分割提供了新的解决思路。RandLA-Net^[7]通过引入高效的随机采样策略与轻量化的局部特征聚合模块,提升了大规模分割处理速度与内存效率,保持了较强的特征表示能力。PointNeXt^[8]通过系统优化训练策略并引入倒置残差多层感知机(MLP)块与可分离MLP结构,实现精度与速度的双重突破。PointNAT^[9]通过结合改进的邻居聚合机制与基于关键点的轻量级Transformer,实现了在大规模点云语义分割任务中同时捕捉局部细节与全局依赖。尽管基于深度学习的点云分割方法通过数据驱动的方式提升了特征学习的灵活性,但在处理叶片这类具有平滑曲面与锐利边缘共存的复杂部件时,现有网络仍普遍面临几何结构建模能力不足的挑战。

这导致在叶身、榫头、缘板等关键区域的过渡处,容易出现欠分割或过分割现象。

为克服单一模态在纹理与几何信息上的局限性,多模态点云分割技术应运而生。IKD-Net^[10]通过构建解耦双流网络,并利用LiDAR点云作为强模态来引导优化航空影像的特征学习,提升了多模态土地覆盖语义分割的精度。TransFusion^[11]通过引入图像引导的查询初始化模块,提升对点云中稀疏或难以检测目标的召回率。PIF-Net^[12]通过引入层次化融合模块与双向特征交互机制,增强多层次、跨模态特征的充分融合与语义互补性。多模态通过融合二维图像丰富的纹理信息与三维点云精确的空间信息,以增强对复杂场景的理解。然而,现有融合方法多采用特征级联或简单加权的方式,未能深入挖掘不同模态在局部几何与语义上的内在关联与互补性,尤其在叶片表面弱纹理、高曲率区域,其分割精度与鲁棒性仍有较大提升空间。

传统的粗糙度检测方法,如接触式轮廓仪,存在效率低下、易损伤表面、难以集成于产线等固有局限,严重滞后于现代航空规模化、柔性化生产的要求。当前,约70%的叶片表面缺陷需要依赖返修解决,凸显了离线检测的被动性与高成本。Zhao等^[13]通过集成NX2212软件进行刀具路径规划与虚拟仿真、DEFORM-3D进行有限元物理场模拟,并结合白光干涉仪进行试验验证,构建从数字建模到物理加工的全流程分析预测。Giusti等^[14]通过将标准机器视觉相机与卷积神经网络(CNN)结合,实时分析实现对表面粗糙度的非接触式在线测量。机器视觉技术,特别是融合三维点云与图像信息的智能检测方法,为解决这一瓶颈提供了新的途径。Wu等^[15]提出了一种基于视觉图像与深度图多模态融合的智能检测框架,提升航空发动机叶片

损伤检测的准确率与自动化测量精度。然而,这些方法大多仍停留在实验室验证与特定工况下的应用阶段,在实际复杂、动态、多变的航空发动机制造与维护现场,仍面临环境适应性不足、系统集成度低、全流程闭环能力弱及工程化部署成本高昂等严峻挑战,实现规模化、智能化、高可靠性的工业级应用尚存差距。

针对上述现有方法存在的局限性,本文提出了一种面向叶片粗糙度在线测量的动态结构分割-网格稳健测量一体化框架。将动态图卷积网络与基于多尺度均匀网格上下文融合的稳健量化方法相结合,构建了一套从几何结构精准感知到表面纹理稳健量化的完整解决方案。通过融合能自适应推断拓扑连接关系的动态图构造模块与跨层级双维注意力机制,实现对叶片转接区、缘板等复杂结构的高精度、强鲁棒分割。将表面点云划分为均匀微元网格,在网格内融合高程统计与频率特征以增强有效纹理,在网格间引入图注意力机制建模上下文关系以抑制离群干扰,最终基于优化后的全局表面信号稳健计算粗糙度参数。该框架有效克服了传统方法在复杂曲面分割边界模糊、测量受宏观形状与异常点干扰严重的双重局限,在制造过程中实现在线、高精度质量检测与闭环工艺控制。

1 研究方法

1.1 总体框架

为实现叶片表面粗糙度的高精度在线检测,提出了一种动态结构分割-网格稳健测量一体化框架,该方法由两个核心阶段组成,形成“感知-测量”的闭环流程。

在第一阶段,实现动态结构感知分割,目标是精准识别叶片上待测的关键区域(如转接区、缘板等)。该阶段以从叶片表面采集的三维点云与对应的灰度图像作为输入,通过端

到端的动态结构感知分割网络进行处理。如图1所示,网络的核心是利用动态图卷积模块,自适应地推断点云中各点与其邻域的拓扑连接关系,替代了传统预定义、固定的邻接图,从而更好地建模复杂、非规则的叶片几何结构。在此基础上,网络进一步引入了跨层级通道-空间双维注意力机制。其中,空间注意力模块聚焦于局部邻域内不同空间位置的重要性差异,增强对边缘、转接等关键几何结构的响应。通道注意力模块则对不同语义特征通道进行重标定,筛选出与部件分割最相关的特征维度。两者的协同工作,实现了对叶片复杂结构边界的高精度、强鲁棒分割,为后续的测量提供了精确的区域掩码。

在第二阶段,实现网格上下文稳健量化,目标是对分割出的叶身区域进行表面粗糙度的稳健计算。如图2所示,该阶段以前一阶段的分割

结果为指导,摒弃传统的频域滤波思路,提出一种基于多尺度均匀网格与上下文融合的稳健量化方法。将叶身区域的表面点云划分为一系列多尺度的均匀微元网格。在每个网格单元内部,通过分析高程信号的统计分布与频率特性,自适应加权融合有效的表面纹理信号,抑制噪声。更重要的是,在网格单元之间,引入图注意力机制建模其空间上下文依赖关系,使信息能在相邻甚至非相邻的网格间得到有效传递与平滑,从而全局性地抑制因局部曲率突变或测量异常引起的离群干扰。最终,基于此优化和增强后的全局表面形貌信号,计算得到稳健的区域粗糙度参数。

1.2 基于动态图卷积的拓扑自适应模块

为实现对航空发动机叶片三维点云复杂几何与拓扑结构的高效、精准建模,提出一种基于动态图卷积的

拓扑自适应模块。该模块的核心在于摒弃了传统点云处理方法中静态、固定的邻域定义方式,引入一种能够根据高层语义特征动态演化的局部图结构构建机制。图3为叶片转接区、榫头、叶冠等具有明显几何过渡特征区域的针对性感知与表达,图注中对各区域的几何特点及它们对分割算法的挑战进行了说明。

点云数据作为一种非欧几里得域内的离散点集,需定义点与点之间有效的拓扑连接关系,以支撑卷积等特征提取操作。传统方法多依赖于在三维欧氏空间中基于固定半径(Ball query)或最近邻(KNN)搜索来静态定义每个点的局部邻域。然而,对于叶片这类具有复杂自由曲面和气动外形的精密部件,不同区域(如光滑吸力面与存在冷却气膜的缘板区)的局部几何尺度与特征分布差异明显。静态邻域难以自适应这




图1 多模态动态结构分割架构示意图

Fig.1 Schematic diagram of the multimodal dynamic structure segmentation architecture





图2 多尺度网格划分及处理示意图

Fig.2 Schematic diagram of multi-scale grid division and processing



- ①复杂齿状结构及尖锐边缘, 点云分布稀疏, 易导致局部特征丢失与分割边界模糊
- ②曲率变化剧烈且几何形状高度非规则, 过分割与欠分割的高发区
- ③表面曲率平缓面积大, 在保持全局一致性同时避免因特征相似性导致的区域粘连
- ④几何拓扑多变且常伴有微小特征, 对局部细节的捕捉能力要求极高
- ⑤特殊封严结构, 点云密度不均且边缘锐利, 需兼顾宏观形状与微观结构

图3 航空发动机叶片部件区域划分示意图

Fig.3 Schematic of aero-engine blade component region division

种几何变化: 若采用过大的固定半径, 在平缓区域会引入无关噪声; 若半径过小, 在复杂特征区则无法覆盖完整的局部结构, 导致关键几何上下文信息的丢失。

为解决此问题, 将局部图的构建从输入坐标空间迁移至逐层演化的特征空间。具体而言, 对于一个包含 N 个点的叶片点云 $P=\{p_1, p_2, \dots, p_n\} \in \mathbb{R}^3$ 及其在第 $l-1$ 层学习到的特征表示 $\mathbf{X}^{(l-1)} \in \mathbb{R}^{N \times D(l-1)}$, 将其形式化地建模为一个动态有向图序列 $\mathbf{G}^{(l)} = (\mathbf{V}, \mathbf{E}^{(l)})$ 。其中, 顶点集 $\mathbf{V}$ 与点集 P 一一对应, 而边集 $\mathbf{E}^{(l)}$ 则是在第 l 层动态生成的。

在网络的第 l 层, 对于每一个目标点 v_i (对应于点 p_i 及其特征 $\mathbf{x}_i^{(l-1)}$), 不再基于其原始的 (x, y, z) 坐标寻找邻居, 而是基于当前的特征表示 $\mathbf{x}_i^{(l-1)}$, 在整个点集的特征空间 $\mathbf{X}^{(l-1)}$ 中执行 K 最近邻 (KNN) 搜索。

$$N^{(l)}(i) = \text{KNN}(\mathbf{x}_i^{(l-1)}, \mathbf{X}^{(l-1)}, K) \quad (1)$$

式中, $N^{(l)}(i)$ 为顶点 v_i 在第 l 层的邻居索引集合; $\text{KNN}(\cdot)$ 为 K 最近邻搜索算法; $\mathbf{x}_i^{(l-1)}$ 为顶点 v_i 在第 $l-1$ 层的特征向量; $\mathbf{X}^{(l-1)}$ 为所有顶点在第 $l-1$ 层的特征矩阵; K 为预设的邻居数量。该操作返回与 $\mathbf{x}_i^{(l-1)}$ 在特征空间中最相似的 K 个邻近点的索引集合, 即 $N^{(l)}(i) = \{j_1, j_2, \dots, j_k\}$, 其中

j_k 为邻居顶点 v_{j_k} 的索引。

由此, 为每个中心点 v_i 动态定义了一个局部邻域 $N^{(l)}(i) = \text{KNN}(v_i, v_{j_1}, v_{j_2}, \dots, v_{j_k})$ 。随后, 构建从每个邻居点 v_{j_i} 向中心点 v_i 的有向边 $e_{ij}^{(l)} \in \mathbf{E}^{(l)}$, 表示信息从邻居流向中心的聚合路径。如图4所示, 这种动态构建的局部有向图结构直观地展示了网络是如何根据语义相似性, 而非单纯的几何接近性, 来定义局部上下文的。

在动态构建的局部有向图 $\mathbf{G}^{(l)}$ 上, 采用 EdgeConv 操作来显式地编码中心点与其每个动态邻居之间的几何关系, 并聚合这些信息以更新中心点的特征。对于中心点 v_i 与其动态邻点 $v_{j_i} \in N^{(l)}(i)$ 所构成的有向边 $e_{ij}^{(l)}$, 计算其边特征 $h_{ij}^{(l)}$ 。该边特征通过一个共享的 MLP 对两种信息的融合进行编码: 一是中心点自身的特征 $\mathbf{x}_i^{(l-1)}$, 提供了当前点的状态; 二是邻居点与中心点的特征差 $\mathbf{x}_{j_i}^{(l-1)} - \mathbf{x}_i^{(l-1)}$, 捕获了局部区域内特征的相对变化。其计算如下。

$$h_{ij}^{(l)} = \text{MLP}_{\Theta^{(l)}} [\mathbf{x}_i^{(l-1)} \oplus (\mathbf{x}_{j_i}^{(l-1)} - \mathbf{x}_i^{(l-1)})] \quad (2)$$

式中, $\oplus$ 表示向量拼接操作; $\text{MLP}_{\Theta^{(l)}}$ 代表在第 l 层共享的、参数为 $\Theta^{(l)}$ 的多层感知机。

为了将 K 个邻居所提供的局部信息聚合到中心点, 采用最大池化

(Max pooling) 操作, 即

$$\mathbf{x}_i^{(l)} = \text{Max}_{j \in N^{(l)}(i)} h_{ij}^{(l)} \quad (3)$$

式中, $\mathbf{x}_i^{(l)} \in \mathbb{R}^{D_l}$ 为中心点 v_i 在第 l 层更新后的特征向量。

最大池化函数具有置换不变性, 确保了网络对点云输入顺序的鲁棒性, 同时它能筛选出邻域内最显著的特征响应, 有助于突出关键的结构信息。通过堆叠多个动态图卷积层, 形成层次化的特征学习架构。每一层均在前一层的抽象特征基础上重新构建局部图并提取特征, 使得每个点的感受野能够指数级扩大, 并始终聚焦于语义相关的区域。

1.3 融合双维注意力的结构感知分割模块

动态图卷积拓扑自适应模块为叶片点云提供了几何与语义特征基础。然而, 分割精度取决于网络从




图4 构建的有向图图表

Fig.4 Diagram of the constructed directed graph

特征中精准鉴别出不同部件之间的细微边界,并对关键结构区域给予足够的“关注”。为此,在动态图卷积流中集成了通道-空间双维注意力机制(Channel-space dual attention mechanism, CAM+SAM),构建一个结构感知分割模块,如图5所示,旨在从特征通道和局部空间两个相互正交的维度,自主地、有区分地强化对分割决策至关重要的信息,同时抑制冗余或干扰信息。

通道注意力模块(CAM)目标是自适应地重新校准各特征通道的权重,使网络强化对当前分割上下文重要的特征通道。

给定由 EdgeConv 生成的、针对中心点 v_i 的边特征集合 $H_i = \{h_{i1}, h_{i2}, \dots, h_{iK}\} \in \mathbb{R}^{K \times C}$ (K 为邻居数, C 为通道数), CAM 首先通过全局平均池化(Global average pooling, GAP)沿空间维度(即 K 个邻居)进行压缩,聚合所有空间位置的信息,生成一个通道级的统计描述符 $z_i \in \mathbb{R}^C$ 。

$$z_{i,c} = \frac{1}{K} \sum_{j=1}^K h_{ij,c} \quad (4)$$

式中, $z_{i,c}$ 是第 c 个通道在所有邻居上的平均响应,概括该通道所编码特征的全局显著性。

为了捕获通道间的非线性依赖关系并生成紧凑的通道权重,将 z_i 输入一个具有瓶颈结构(Bottleneck)的两层全连接网络,并应用 Sigmoid 激活函数生成最终的通道注意力权重向量 $s_i \in \mathbb{R}^C$ 。

$$s_i = \sigma[W_2 \cdot \delta(W_1 \cdot z_i)] \quad (5)$$

式中, $W_1 \in \mathbb{R}^{C/\gamma \times C}$ 和 $W_2 \in \mathbb{R}^{C \times C/\gamma}$ 是可学习的权重矩阵, γ 是缩减率,用于降低模型复杂度并增强泛化能力; δ 表示 ReLU 激活函数, σ 表示 Sigmoid 函数,将输出限制在 (0,1) 区间,代表每个通道的重要性分数。

原始的边特征 H_i 通过与对应的通道权重进行逐通道(Element-wise)乘法计算得到重标定。

$$\tilde{H}_{i,c} = s_{i,c} \cdot H_{i,c} \quad (6)$$

式中, c 表示特征通道。这样使得对当前中心 v_i 的类别判别贡献大的特征通道被增强,贡献小的通道被抑制,实现特征通道层面的自适应

优化。

点云中心点的所有邻居并非同等重要。如在分割缘板与叶身的转接处,位于边界线上的邻居点所提供的几何对比信息,远比位于部件内部平滑区域的邻居点更为关键。空间注意力模块(SAM)的目的是量化局部邻域内每一个空间位置(即每一个邻居点)对中心点语义判断的重要性。

SAM 直接作用于经通道注意力初步校准后的边特征 $\tilde{H}_i$, 对于每一条边特征向量 $\tilde{h}_{ij} \in \mathbb{R}^C$, 通过一个轻量级的 MLP 将其映射为一个标量注意力分数 a_{ij} , 该分数表征了邻居点 v_{ij} 对判断中心点 v_i 类别的相对重要性。

$$a_{ij} = \text{MLP}_{\phi}(\tilde{h}_{ij}) \quad (7)$$

式中, $\text{MLP}_{\phi}(\cdot)$ 是一个参数共享的感知机,其输出为标量。

为了使得所有邻居点的注意力分数可比较且权重之和为 1, 对 K 个分数应用 Softmax 函数进行归一化, 得到最终的空间注意力权重 $\hat{a}_{ij}$, 其计算公式为




图5 通道与空间维度的注意力机制

Fig.5 Attention mechanism in terms of channel and spatial dimensions

$$\hat{\alpha}_{ij} = \frac{\exp(a_{ij})}{\sum_{k=1}^K \exp(a_{ik})} \quad (8)$$

利用 SAM 计算出的空间权重 $\hat{\alpha}_{ij}$ 对通道注意力加权后的边特征 $\tilde{h}_{ij}$ 进行聚合,得到一个初步聚合的中心点特征 u_i ,其计算公式为

$$u_i = \sum_{j=1}^K \tilde{\alpha}_{ij} \cdot \tilde{h}_{ij} \quad (9)$$

而后将 u_i 再次输入 CAM,进行最终的通道调整。

1.4 基于多尺度网格划分与上下文融合的粗糙度稳健量化方法

传统的接触式或基于整体点云的测量方法在面对航空发动机叶片复杂自由曲面、微小特征及不可避免的测量噪声时,常面临基准面拟合失真、异常值干扰严重、局部曲率影响大等挑战,导致测量结果波动大、可靠性低。

为解决上述问题,提出一种基于多尺度均匀网格划分与图注意力上下文融合的稳健量化方法。该方法的核心思想是“化整为零,协同优化”:将宏观连续曲面离散化为微观规则单元进行处理,再通过建模单元间的空间关系实现全局优化,从而在保留表面完整纹理信息的前提下,提升测量的抗干扰能力与准确性。最终输出的表面粗糙度参数,单位为微米(μm),符合国际标准(ISO 25178)及工业界惯例。

以分割掩码为引导,将目标区域的三维点云投影到其最小二乘拟合平面上建立二维参数域。在参数域内摒弃传统的固定尺寸网格,提出一种多尺度均匀网格划分策略。设点云在参数域内的包围盒为 Ω ,依据点云的局部密度与区域的几何复杂度,自适应确定一个基础网格尺寸 l_0 ,将 Ω 划分为一系列均匀的方形微元网格 $\{G_m\}, m=1,2, \dots, M$ 。每个网格 G_m 被视为一个独立的“局部特征单元”,其内部包含一组三维点 $P_m=\{p_k\} \subset \mathbb{R}^3$ 。

为直观展示多尺度网格划分策

略在复杂叶片表面上的具体实现与几何适应性,图 6 展示了两类典型低压叶片和一类高压叶片表面,采用不同分块单位(block_n=10,20,30)进行均等网格划分的效果对比。该方法将三维点云投影至参数域后,并非进行简单的固定尺寸划分,而是依据局部点云密度 ρ 和表面平均曲率 k 自适应调整网格尺寸,实现规则且可量化的网格离散化。具体而言,网格尺寸 L 由尺度函数确定,即

$$L = f(\rho, k) = \alpha \cdot \frac{1}{\rho} + \beta \cdot k + L_0 \quad (10)$$

式中, ρ 为局部点云密度(单位面积内的点数); k 为局部平均曲率; α 和 β 为权重系数; L_0 为基础网格尺寸常数。这使得在点云密集或曲率变化剧烈的区域,网格尺寸自动减小以捕捉细节;在点云稀疏或曲率平缓的区域,网格尺寸自动增大以保证统计稳健性。

图 6 清晰表明,通过调整分块数量,可系统性地控制网格的尺度:当 block_n=10 时,网格尺寸较大,侧重于捕获表面的整体起伏趋势与宏观形貌,适用于曲率变化平缓区域的快速表征;随着 block_n 增至 20 和 30,网格尺寸逐级细化,能够更精确地框

定局部微小特征,为后续提取高频表面纹理信号提供高分辨率的分析单元。在此基础上,为量化网格划分的自适应能力,采用网格搜索法在验证集上对尺度函数中的权重系数 α 和 β 进行试验标定。结果表明,上述权重系数组合能够有效平衡点云密度与局部曲率对网格尺寸的调节作用,从而增强方法对叶片不同几何特征区域的适应能力。所提出的可控的、均匀的多尺度网格划分既保证了全局处理的系统性,避免传统方法中因区域分割不当引入的边界效应,同时为后续每个独立网格单元内基于统计与频域的智能信号融合,以及基于图注意力的全局上下文优化,提供结构规整、空间关系明确的处理基础,从数据组织层面提升粗糙度测量流程鲁棒性。

多尺度表示为针对曲面变化平缓的区域,采用较大的网格尺寸以获取统计稳健性;对于曲率突变或特征丰富的区域(如转接区),则采用较小的网格尺寸以捕捉细节。网格尺寸的确定基于一个预定义的尺度函数 $S(\rho, k)$,该函数同时考虑局部点云密度 ρ 和平均曲率 k ,即

$$l_m = l_0 \cdot S(\rho_m, k_m) \quad (11)$$




图 6 叶身表面多尺度网格划分

Fig.6 Multi-scale grid division of blade body surfaces

式中, l_m 为网格 G_m 的最终边长, 确保测量分析单元与表面物理特征的适应性。

对于每个网格单元 G_m , 目标是从其内部包含噪声、异常点和真实表面形貌的点集 P_m 中, 提取出最能代表该区域微观纹理的“有效高度信号”。传统方法常直接采用统计量或阈值剔除, 但这些方法在信号与噪声混叠时容易失效。本方法通过分析网格内高程(Z 坐标)信号的统计分布与频率特性实现融合; 计算 P_m 的高程直方图, 通过峰值检测识别主模态, 该模态通常对应真实表面点。基于此, 计算一个稳健的加权中心 μ_m^{robust} ; 对网格内有序点的高程序列进行快速傅里叶变换(FFT), 分析其功率谱; 将频谱能量主要集中在中高频部分的成分识别为有效表面纹理信号, 而将过低频(可能反映残余宏观形状)和过高频(可能为随机噪声)的成分进行衰减。

结合统计权重 w_m^{stat} 和频域权重 w_m^{freq} , 为网格内每个点 p_k 分配一个综合置信度权重 η_k , 其计算公式为

$$\eta_k = w_m^{\text{stat}}(p_k) \cdot w_m^{\text{freq}}(p_k) \quad (12)$$

最终, 网格 G_m 的代表性高度值 h_m 由其内部所有点的高程加权平均得到, 即

$$h_m = \frac{\sum_{p_k \in P_m} \eta_k \cdot z_k}{\sum \eta_k} \quad (13)$$

式中, z_k 是点 p_k 的高程。此过程在网格单元级别上完成首次去噪与信号增强。

经网格内融合后, 获得一个初步的、离散化的表面高度图 $H=\{h_m\}$ 。然而, 孤立的网格处理仍可能受限于局部剧烈曲率或个别未能完全滤除的异常值。为此引入图注意力网络(GAT)来建模网格单元之间的空间上下文关系, 实现全局层面的特征平滑与优化。

将每个网格单元 G_m 视为图中的

一个节点。节点特征为高度值 h_m 及其位置、局部曲率等辅助信息。根据网格的邻接关系(如4邻域或8邻域)构建图结构, 边表示网格间的空间连接。对于目标节点 m , 利用图注意力机制计算其与所有邻居节点 $n \in N(m)$ 的注意力系数 α_{mn} 。

$$\alpha_{mn} = \frac{\exp\{\text{LeakyReLU}(\mathbf{a}^T[\mathbf{W}h_m \parallel \mathbf{W}h_n])\}}{\sum_{k \in N(m)} \exp\{\text{LeakyReLU}(\mathbf{a}^T[\mathbf{W}h_m \parallel \mathbf{W}h_k])\}} \quad (14)$$

式中, $\mathbf{W}$ 是共享权重矩阵; $\mathbf{a}$ 是注意力向量; $\parallel$ 表示拼接操作。 α_{mn} 量化了邻居 n 的信息对优化目标节点 m 的重要性。

目标节点 m 优化后, 特征 h'_m 是其所有邻居特征的加权和。

$$h'_m = \sigma \left(\sum_{n \in N(m)} \alpha_{mn} \mathbf{W}h_n \right) \quad (15)$$

此操作使高度信息能够在空间上传播。平滑的、正常的区域会强化一致信号, 而孤立的异常值(其高度与周围邻域高度不相关)则会被邻域的共识所抑制和修正, 相当于一种自适应的、非局部的智能滤波。最终, 得到一个优化后的、全局一致的高度矩阵 $\mathbf{H}'=\{h'_m\}$, 它最大程度地保留了真实的表面纹理, 并抑制了各种干扰。

基于优化后的高度矩阵 $\mathbf{H}'$ 计算表面粗糙度参数。所有参数的计算均以微米(μm)为单位。由于网格化处理已在局部抑制了宏观形状, 此

时可在整个测量区域 $\mathbf{H}'$ 上稳健地拟合一个最小二乘基准平面 S_{ref} 。优化后的信号使得基准面拟合不受异常点影响, 更为准确。计算每个网格单元优化高度 h'_m 到基准面 S_{ref} 的垂直偏差 δ_m , 得到最终算术平均高度 S_a , 其计算公式为

$$S_a = \frac{1}{M} \sum_{m=1}^M |\delta_m| \quad (16)$$

式中, M 为网格总数。该方法通过局部融合与全局优化相结合的策略, 确保了在复杂叶片曲面上 S_a 值测量的高精度。

2 试验结果与分析

2.1 试验平台

试验在一个自主搭建的数据采集与处理平台上进行, 整体结构如图7所示。该平台主要用于高质量点云数据的获取与实时分析。数据采集采用一台高精度3D结构光相机(Sizecator® S028360), 其分辨率为280万像素(1944×1472), 参考工作距离设定为1050 mm, 标准视场覆盖 $360 \text{ mm} \times 272.8 \text{ mm}$, 深度测量范围为 $\pm 90 \text{ mm}$ 。该相机能够捕捉物体表面的细微几何特征, 为后续分析提供丰富且精确的点云数据。

为保证采集质量, 平台集成了可独立调节的蓝色LED线性光源系统, 可在拍摄区域提供均匀且亮度可调的照明条件, 有效抑制环境光干扰并减少反光与阴影, 从而提升点云数




图7 试验平台

Fig.7 Experimental platform

据的清晰度和一致性。所有数据处理与分析均在配备高性能计算单元的平台完成。主机搭载 Intel Core i7-9700K 处理器(8 核心 16 线程,最高睿频 4.9 GHz),足以支持实时点云预处理与模型推理。系统内存为 16 GB DDR4,运行于 3200 MHz 双通道模式,确保大规模点云数据加载与复杂运算流畅进行。

为全面评价点云语义分割模型的性能,采用 3 项常用指标:平均交并比(mIoU)、平均精度(mAcc)及整体准确率(OA),用于衡量模型整体分割精度,提供对模型性能的多维度评估。

2.2 数据结果与分析

2.2.1 部件分割结果与性能分析

为全面评估所提动态结构感知分割网络的性能,在自建的航空发动机叶片点云数据集上进行训练与测试,并与多种主流点云分割方法进行了对比。数据集包含 3 个不同型号的叶片样本,每个样本通过高精度 3D 扫描获取,精确标注了榫头、叶身与叶冠关键部件。训练集、验证集与测试集的划分比例为 7:2:1。

对所提方法与其他点云分割方法在航空发动机叶片数据集上的性能进行了综合比较。如图 8 所示,对比方法在典型结构区域均实现了接近完美的分割效果,这表明现有方法对叶片主体这类特征明确、几何相对规则的区域已具备较强的识别能力。然而,在叶根过渡区与叶冠过渡区这两个几何形状复杂、曲率变化剧烈的关键区域,不同方法的性能表现呈现明显差异。所提方法在这两个挑战性区域中仍然保持了接近一致的分割精度。这一结果充分说明,所提方法通过动态图卷积自适应构建局部拓扑,并结合通道-空间双维注意力机制,增强了对复杂过渡区域细微几何特征与上下文关系的建模能力。相较于其他方法,所设计网络能够更清晰、更稳定地捕捉叶片转接区域的精确边界,有效缓解了传统方法在曲面剧烈变化处易出现的边界模糊或局部误分割问题,实现对叶片整体结构更高一致性的分割。

为系统验证所提方法的优势,使用定量指标与多模态融合基线进行比较,如表 1 所示。试验结果表明,所

提方法在所有评价指标上均取得了最优性能。具体而言,与表现次优的 MFFNet 相比,所提方法在 mIoU 上实现了 8.12% 的绝对提升,与 IKD-Net 相比,提升 21.4%。这一优势在 mAcc 和 OA 指标上也得以延续,OA 较 MFNet 提升了 6.1%。这些结果充分证明了所提将动态图卷积与通道-空间双维注意力深度融合的策略,在理解叶片复杂几何结构和语义上下文方面具有强大优势。动态图构建模块使网络能够超越固定欧氏距离,自适应地捕获与语义相关的局部拓扑。而双维注意力机制同时从特征通道和空间邻域两个维度筛选和强化关键信息,实现对部件边界的精准定位与分类。

为了进一步解析各组件对最终性能的具体贡献,设计了系统的消融试验,结果如表 2 所示。试验以仅包含动态图卷积的基础模型为起点,逐步引入 CAM 和 SAM。当仅加入 CAM 时, mIoU 提升 2.5 百分点,表明对特征通道的重要性进行重新校准能有效增强模型的判别力。而仅加入 SAM 也带来了明显的增益,验




图 8 部件分割定性比较

Fig.8 Qualitative comparison of component segmentation

证了空间聚焦的有效性。但 CAM 的增益更为突出,这凸显了在叶片分割任务中通道级特征优化比局部空间选择更为关键。最终,当动态图卷积、CAM 与 SAM 三者协同工作时,模型取得了最佳的 67.9%,清晰地表明每个模块均为整体性能带来正向增益,且空间注意力模块贡献了最大的单一模块性能提升。这验证了所提网络设计的有效性:动态图卷积提供了自适应的感受野基础,空间注意力实现了精细的局部结构感知,通道注意力完成高层次语义特征的提炼,共同促成最终分割精度。

2.2.2 表面粗糙度测量策略验证与分析

为系统验证所提多尺度网格融合量化方法的综合性能,将其与两种非接触式粗糙度测量方法进行了对比分析,具体结果如表 3 所示。其中,绝对误差用于评估测量值与真实值的偏差,反映方法的精度。测量重复

性衡量在相同条件下多次测量结果的一致性,反映方法的稳定性。结果表明,所提方法在关键指标上均优于最佳参考方法,绝对误差较最佳参考方法降低了 25%,重复性较最佳参考方法提升了 44.4%。

为定量评估所提方法测量结果与接触式轮廓仪真实值之间的一致性,采用决定系数 R^2 进行衡量。 R^2 的计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (17)$$

式中, y_i 为接触式轮廓仪测量的真实粗糙度, $\hat{y}_i$ 为所提方法测量的对应值, $\bar{y}$ 为真实值的均值。 R^2 越接近 1,表明测量结果与真实值的线性相关性越强,测量精度越高。

决定系数 R^2 由分区策略的 0.94 提高至所提方法的 0.97,表明测量结果与真实形貌的线性拟合优度得到进一步改善。这种综合性能的提升主要归因于所提方法对局部高曲率区域与异常点的自适应加权融合,以及通过图注意力实现的跨网格上下文优化,从而在复杂曲面条件下仍能保持高精度与稳定性的测量输出。

试验结果从分割精度和测量稳健性两个方面充分验证了所提“动

态结构分割-网格稳健测量”一体化框架的有效性。该框架为航空发动机叶片表面粗糙度的在线、高精度检测与量化评估提供了一套可靠的解决方案。

2.2.3 测量鲁棒性验证分析

为验证所提方法对点云噪声及异常点的鲁棒性,设计了不同强度的复合干扰试验,结果如表 4 所示。其中 σ 表示点云噪声, γ 表示异常点比例,方法 a 与 b 分别对应数字高程模型与分区策略。在无干扰条件下,三种方法测量值基本一致。随着干扰强度增加,对比方法的测量误差明显上升。为进一步定量评估各方法的抗干扰能力,引入相对误差作为评价指标,其计算公式为

$$E_{rel} = \frac{|S'_a - S_a|}{S_a} \quad (18)$$

式中, S_a 为对照组(无干扰条件下)的粗糙度测量值; S'_a 为施加干扰后的粗糙度测量值。该指标反映了干扰条件下测量值相对于基准值的偏离程度, E_{rel} 越小,表明方法对干扰的抵抗能力越强,鲁棒性越好。

试验结果表明,在重度干扰下,对比方法的相对误差分别达到 17.8% 和 20.5%,而所提方法的相对误差仅为 11.5%,明显优于对比方法。这表

表 1 所提方法与多模态分割方法的定量比较

Table 1 Quantitative comparison of the proposed method with multimodal segmentation methods

方法	mIoU/%	mAcc/%	OA/%
IKD-Net ^[10]	55.9	73.8	86.1
TransFusion ^[11]	56.3	74.4	86.8
PMNet ^[16]	58.4	75.3	87.4
MFNet ^[17]	60.1	74.2	89.1
MFFNet ^[18]	62.8	76.1	90.3
Ours	67.9	77.4	94.6

表 2 各组件对分割性能的影响

Table 2 Impact of each component on the segmentation performance

动态图卷积	CAM	SAM	mIoU/%
✓			64.7
✓	✓		67.2
✓		✓	66.6
✓	✓	✓	67.9

表 3 所提方法与非接触式测量方法的比较分析

Table 3 Comparison of the proposed method with non-contact measurement methods

方法	决定系数 R^2	绝对误差 / μm	重复性 / μm
数字高程模型 ^[19]	0.91	0.27	± 0.12
分区策略 ^[20]	0.94	0.24	± 0.09
Ours	0.97	0.18	± 0.05

表 4 复杂干扰下所提方法与对比方法测量比较

Table 4 Comparison of measurements between the proposed method and benchmark methods under composite interference

条件	方法 a 相对误差 /%	方法 b 相对误差 /%	所提方法相对误差 /%
$\sigma=0.01 \gamma=1\%$	4.8	6.7	1.9
$\sigma=0.03 \gamma=3\%$	12.4	16.2	5.8
$\sigma=0.05 \gamma=5\%$	17.8	20.5	11.5

明所提方法通过网格内加权融合与网格间图注意力机制,有效抑制了噪声和异常点的影响。

3 结论

(1) 本文提出了一种融合动态图卷积与双维注意力的结构感知分割网络,在航空发动机叶片部件分割任务中取得了优异的性能。该方法 mIoU 达到 67.9%, OA 高达 94.6%。消融试验表明,动态图卷积、CAM 与 SAM 模块均对性能有正向贡献,其中 CAM 模块的增益最为明显。该网络能精准识别叶根、叶冠等复杂过渡区域,有效解决传统方法在曲面剧烈变化处的边界模糊问题。

(2) 本文提出了一种基于多尺度网格划分与上下文融合的粗糙度稳健量化方法,实现了对分割后叶片表面的高精度、高稳定性测量。试验结果表明,相较于最佳参考方法,所提方法的绝对误差降低了 25%,重复性提升了 44.4%,验证了所提方法在抑制异常干扰、适应复杂曲面方面的明显优势,为叶片表面质量的在线检测与工艺控制提供了可靠的技术方案。

参考文献

- [1] 张祥春,彭文胜,楚峻溢,等.基于改进 Mask R-CNN 的航空铸件智能检测技术研究[J].航空制造技术,2025,68(23/24): 26-33.
- [2] ZHANG Xiangchun, PENG Wensheng, CHU Junyi, et al. Aviation casting intelligent detection technology based on improved Mask R-CNN[J]. Aeronautical Manufacturing Technology, 2025, 68(23/24): 26-33.
- [3] 朱慧宁,马小刚,程海东,等.磁针磁力研磨工艺对发动机涡轮叶片表面质量的试验研究[J].航空制造技术,2021,64(18): 62-68.
- [4] ZHU Huining, MA Xiaogang, CHENG Haidong, et al. Experimental study on surface quality of engine turbine blade by magnetic needle magnetic abrasive technology[J]. Aeronautical Manufacturing Technology, 2021, 64(18): 62-68.
- [5] 庄世宁,晏政,袁园,等.面向复杂曲面粗糙度测量的无干涉路径规划方法[J].组合机床与自动化加工技术,2025(11): 80-85.
- [6] ZHUANG Shining, YAN Zheng, YUAN Yuan, et al. Non interference path planning method for measuring roughness of complex surfaces[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2025(11): 80-85.
- [7] 张学仪,何小妹,王一璋,等.航空发动机叶片粗糙度测量方法研究[J].计测技术,2023,43(2): 35-43.
- [8] ZHANG Xueyi, HE Xiaomei, WANG Yizhang, et al. Research on measurement method of aeroengine blade roughness[J]. Metrology & Measurement Technology, 2023, 43(2): 35-43.
- [9] 黄文娟,金炜,倪博,等.叶片表面粗糙度测量三维和二维评价对比分析[J].中国测试,2025,51(8): 33-39.
- [10] HUANG Wenjuan, JIN Wei, NI Bo, et al. Comparison and analysis of 3D and 2D evaluation of blade surface roughness measurement[J]. China Measurement & Test, 2025, 51(8): 33-39.
- [11] 贾浩.基于数字孪生的复杂零件智能检测系统关键技术研究[D].长春:吉林大学,2025.
- [12] JIA Hao. Research on key technologies of an intelligent detection system for complex parts based on digital twin [D]. Changchun: Jilin University, 2025.
- [13] HU Q Y, YANG B, XIE L H, et al. RandLA-net: Efficient semantic segmentation of large-scale point clouds[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2020: 11105-11114.
- [14] QIAN G C, LI Y C, PENG H W, et al. PointNeXt: Revisiting PointNet++ with improved training and scaling strategies[C]//Advances in Neural Information Processing Systems. New York: NeurIPS, 2022: 23192-23204.
- [15] ZENG Z Y, QIU H, ZHOU J, et al. PointNAT: Large-scale point cloud semantic segmentation via neighbor aggregation with transformer[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5704618.
- [16] WANG Y M, WAN Y, ZHANG Y J, et al. Imbalance knowledge-driven multi-modal network for land-cover semantic segmentation using aerial images and LiDAR point clouds[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 202: 385-404.
- [17] BAI X Y, HU Z Y, ZHU X G, et al. TransFusion: Robust LiDAR-camera fusion for 3D object detection with transformers[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2022: 1080-1089.
- [18] GUO Z, XU R, FENG C C, et al. PIF-net: A deep point-image fusion network for multimodality semantic segmentation of very high-resolution imagery and aerial point cloud[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5700615.
- [19] ZHAO H Y, CAO Y, GUO J D, et al. Multi-axis CNC finishing and surface roughness prediction of TC11 titanium alloy open integral micro impeller[J]. Advances in Mechanical Engineering, 2024, 16(4): 16878132241244924.
- [20] GIUSTI A, DOTTA M, MARADIA U, et al. Image-based measurement of material roughness using machine learning techniques[J]. Procedia CIRP, 2020, 95: 377-382.
- [21] WU X, WEI X L, XU H J, et al. Aeroengine blades damage detection and measurement based on multimodality fusion learning[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5019315.
- [22] POLIYAPRAM V, WANG W M, NAKAMURA R. A point-wise LiDAR and image multimodal fusion network (PMNet) for aerial point cloud 3D semantic segmentation[J]. Remote Sensing, 2019, 11(24): 2961.
- [23] SUN Y J, FU Z L, SUN C X, et al. Deep multimodal fusion network for semantic segmentation using remote sensing image and LiDAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5404418.
- [24] REN D Y, LI J W, WU Z Y, et al. MFFNet: Multimodal feature fusion network for point cloud semantic segmentation[J]. The Visual Computer, 2024, 40(8): 5155-5167.
- [25] FAN L, ATKINSON P M. A new multi-resolution based method for estimating local surface roughness from point clouds[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2018, 144: 369-378.
- [26] KALAMI H, URBANIC J. Exploration of surface roughness measurement solutions for additive manufactured components built by multi-axis tool paths[J]. Additive Manufacturing, 2021, 38: 101822.

Aero-Engine Blades Roughness Measurement Based on Multimodal Structure Perception

SONG Min¹, XU Yue², ZHANG Yinlong³

(1. School of Computer Science and Technology, Shenyang Institute of Engineering, Shenyang 110136, China;

2. School of Computer Science and Engineering, Northeastern University, Shenyang 110819, China;

3. Institute of AI for Industries, Chinese Academy of Sciences, Nanjing 211135, China)

[ABSTRACT] As a core component of aero-engines, the surface roughness of blades is a critical parameter for evaluating blade performance. However, traditional methods are constrained by the geometric heterogeneity of complex blade surfaces and interference from surface noise, often leading to segmentation errors and unstable measurement results. To address these issues, this paper proposes a measurement method that integrates a dynamic graph neural network with frequency-domain signal processing. To overcome the difficulties in region segmentation caused by complex blade geometries, a structure-aware segmentation network is designed. This network adaptively constructs the local topology of point clouds through dynamic graph convolutional layers and enhances boundary perception of key regions via a cross-layer channel-spatial attention mechanism, achieving precise component-level segmentation. Building upon this, a robust roughness quantification method based on uniform grid division and contextual fusion is proposed. This method divides the point cloud into uniform micro-element grids to extract and fuse micro-geometric features, models the spatial correlations between grids, and adaptively fuses features while suppressing outlier interference. Evaluation results demonstrate that the proposed segmentation network achieves an overall accuracy (OA) of 94.6% in blade component segmentation tasks. Compared with contact profilometer measurements, the coefficient of determination (R^2) of the proposed method reaches 0.97, the absolute error is within 0.18 μm , and the repeatability is $\pm 0.05 \mu\text{m}$. The proposed method achieves robust measurement throughout the entire process from region segmentation to parameter calculation, providing reliable technical support for in-service inspection, condition assessment, and remaining life prediction of aero-engine blades.

Keywords: Aero-engine blade; Multimodal fusion; Point cloud segmentation; Roughness measurement; Dynamic graph convolution

(责编 青燕)