

引文格式:张吟龙,吴振,徐永利,等.基于边缘方向感知的航空发动机旋转叶片计数方法[J].航空制造技术,2026,69(16):25010200.

ZHANG Yinlong, WU Zhen, XU Yongli, et al. Aero-engine blade counting method based on direction-aware edge modeling[J]. Aeronautical Manufacturing Technology, 2026, 69(16): 25010200.

# 基于边缘方向感知的航空发动机 旋转叶片计数方法

张吟龙<sup>1,2,3</sup>, 吴振<sup>1,3</sup>, 徐永利<sup>3</sup>, 张思超<sup>2,3</sup>, 宋纯贺<sup>2,3</sup>, 王楚<sup>2,3</sup>, 孙勇<sup>2,3</sup>, 孙乙铭<sup>2,3</sup>

(1. 沈阳工业大学, 沈阳 110870;  
2. 中国科学院工业人工智能研究所, 南京 211135;  
3. 中国科学院沈阳自动化研究所, 沈阳 110016)

**[摘要]** 航空发动机叶片是发动机的核心组件,对其检测与计数是航空发动机日常维护的关键环节。基于工业内窥镜的原位叶片视觉检测方式具有检测效率高、对设备影响小的优势,已成为旋转叶片检测和计数的主流。然而,叶片的反光、形态变化及姿态旋转等因素会导致现有视觉检测算法在边缘提取和方向感知上失效。针对上述问题,提出一种基于边缘方向感知建模(DEM)驱动的旋转叶片检测算法(DLE-DETR)。通过在DETRv2框架下引入DEM模块,对叶片边缘方向进行建模,实现对旋转叶片边缘的精细感知和准确表征,从而提升检测精度和边缘识别能力。此外,针对叶片在复杂运动状态下产生的漏记、误记问题,提出基于旋转角度时序建模(ROST)的航空发动机叶片计数方法,通过联合利用旋转角度变化趋势、轨迹连续性及ROI边界穿越关系,来保证旋转叶片计数的稳定性和准确性。本算法在搭建的航空发动机叶片计数平台上进行了大量的试验测试和分析。试验结果表明,所提DLE-DETR模型叶片检测精度( $AP_{50}$ )为93.8%,相较于其他同类规模的先进模型提升了2.08个百分点。此外,航空发动机叶片平均计数精度达到98.6%,比现有计数算法提升了24.49%,可满足航空发动机叶片计数需求。

**关键词:** 航空发动机叶片; 旋转叶片检测; 方向感知; 叶片边缘; 旋转角度时序建模(ROST)

中图分类号: V232.4

文献标志码: A

DOI: 10.16080/j.issn1671-833x.25010200



张吟龙

研究员,研究方向为工业机器人多模态智能感知。

航空发动机作为飞机的核心动力装置,其性能直接决定了飞机的安全性与经济性。涡轮叶片作为航空发动机的关键部件,在孔探检测过程中,叶片计数是评估叶片完整性、确认叶片是否缺失及辅助后续人工缺陷判读的重要基础环节,其结果直接影响维护人员对发动机状态的判断

及维修决策的可靠性<sup>[1]</sup>。若叶片未精准计数,将导致发动机性能衰退,甚至引发严重安全事故<sup>[2]</sup>。因此,开展高效准确的叶片计数是保障航空发动机安全运行的必要环节。目前,工业内窥镜检测是航空发动机叶片维护的主要手段。然而,该方法不仅工作负荷大、效率低下,而且容易因

收稿日期: 2025-12-25; 退修日期: 2026-01-22; 录用日期: 2026-02-27

基金项目: 国家自然科学基金(62273332, 62595791, 62273337, 62303449); 国家重点研发计划(2024YFB4711102); 辽宁省自然科学基金(2024JH3/10200029, 2024-MSBA-82); 辽宁省振兴人才计划(XLYC2203148); 江苏省自然科学基金(BK20252113); 江苏省工业人工智能重点实验室项目(E6420013G8、E6420006G8); 中国科学院沈阳自动化研究所基础研究计划(2023JC1K09)

通信作者: 徐永利, 研究员, 主要研究方向为产线自动化装配技术。

视觉疲劳导致漏检或误判。随着数字孪生技术在航空制造与运维领域的深入应用,构建全生命周期的数字映射已成为提升航空发动机管理水平的关键趋势<sup>[3-4]</sup>。在此背景下,基于深度学习的计算机视觉技术因其自动化程度高而逐渐成为研究热点。近年来,研究者们尝试利用增强现实智能巡检及改进的 Mask R-CNN 模型等技术来实现航空部件的自动化检测<sup>[5-6]</sup>。

为了实现航空发动机叶片的高精度检测与自动化计数,研究者们在目标检测、旋转目标感知及多目标跟踪计数等方面进行了广泛探索。现有方法主要可分为基于 Transformer 的通用目标检测、旋转目标检测及多目标跟踪计数方法。

在通用目标检测方面,Carion 等<sup>[7]</sup>提出的 DETR 架构通过引入 Transformer 将检测任务建模为集合预测问题,取消了对 Anchor 和 NMS 的依赖。随后,Zhu 等<sup>[8]</sup>提出的 Deformable DETR 通过多尺度可变形注意力机制解决了收敛慢和小目标检测难的问题。为了进一步提升性能,研究者们提出了一系列改进算法: Meng 等<sup>[9]</sup>的 Conditional DETR 模型和 Liu 等<sup>[10]</sup>的 DAB-DETR 模型通过优化 Query 的生成方式加速了收敛; Zhang 等<sup>[11]</sup>的 DINO 模型和 Li 等<sup>[12]</sup>的 DN-DETR 模型通过去噪锚框和查询去噪任务提高了检测精度。此外,针对视频流和密集场景的检测难题,He 等<sup>[13]</sup>提出的 TransVOD 模型和 Choi 等<sup>[14]</sup>提出的 Recurrent DETR 模型分别利用时空 Transformer 和循环机制优化了特征表达; Ye<sup>[15]</sup>和 Chen<sup>[16]</sup>等则在微小目标检测与域自适应方面做出了贡献。然而,这些方法主要针对自然场景下的水平目标设计,在面对航空发动机叶片这种大长径比、任意方向旋转且伴随强反光的复杂目标时,往往因缺乏对细长旋转特征的针对性建模而难以获得理想的检测效果。

针对叶片等具有方向性的目标,旋转目标检测( Oriented object detection )应运而生。Dang 等<sup>[17]</sup>提出的 RO<sup>2</sup>-DETR 模型通过旋转等变卷积增强了 Transformer 对方向的感知; Dai 等<sup>[18]</sup>的 Ao<sup>2</sup>-DETR 模型则进一步实现了任意方向的目标检测。在旋转框表示方面, Xu 等<sup>[19]</sup>提出的 Gliding Vertex 算法和 Yao 等<sup>[20]</sup>的改进边界框表示法为多方向目标检测提供了新的思路; Zand<sup>[21]</sup>和 Dang<sup>[22]</sup>等则分别利用定向边界框和极坐标表示解决了小目标与任意旋转目标的检测难题; Yang 等<sup>[23]</sup>通过高斯 Wasserstein 距离损失重新思考了旋转检测的优化过程; Nie 等<sup>[24]</sup>则针对航空图像提出了双水平矩形检测框架。

尽管旋转检测取得了进展,但叶片边缘作为区分本体与背景的关键特征,在上述方法中往往未被显式建模。传统的边缘检测与注意力机制在特征提取中扮演着重要角色,如 He 等<sup>[25]</sup>提出的双向级联网络和 Zhang 等<sup>[26]</sup>基于生物视觉机制的边缘检测网络。Wang 等<sup>[27]</sup>提出的 ECA-Net 模型通过高效通道注意力增强了 CNN 的表现,而 Liu<sup>[28]</sup>和 Cui<sup>[29]</sup>等则探索了将注意力机制应用于边缘检测,实现了从全局视图到局部焦点的关注。最新的研究如 DAE-Net 模型更是结合了双重注意力机制与边缘监督。然而,如何将边缘方向信息有效融入端到端的旋转检测网络中,仍是一个亟待解决的问题。

在叶片计数与跟踪方面,现有的多目标跟踪( MOT )领域已有大量研究。经典的 SORT 算法和 StrongSORT 算法确立了“检测-跟踪”范式<sup>[30-31]</sup>。Wang 等<sup>[32]</sup>结合 YOLOv8 算法与 ByteTrack 算法提升了跟踪性能, Liao 等<sup>[33]</sup>则增强了对运动状态的推断能力。Vaquero 等<sup>[34]</sup>致力于解决在线跟踪中的检测器失效问题, Nie 等<sup>[35]</sup>贡献了多模态跟踪数据集。Wong 等<sup>[36]</sup>使用 Mask R-CNN 模型实现叶片分

割,并基于边界框中心点实现时序跟踪,但在旋转视角变化大、叶片遮挡严重时仍面临检测框不稳定的问题。光流与统计方法方面, Wrangel 等<sup>[37]</sup>利用光流方向估计旋转方向,并构建统计模型进行计数,但由于叶片外观差异大、光照不稳定,该方法对模板一致性依赖强,泛化能力有限。然而,上述方法大多基于目标做线性或平滑运动的假设。在实际孔探检测中,航空发动机叶片往往伴随着转速不均、短暂悬停甚至旋转方向反转( Stop-reverse )等非线性运动状态。现有算法缺乏对这些复杂时序行为的建模能力,极易在叶片反转或抖动时产生漏计与误计。

针对上述现有方法存在的局限性,本文提出了一种边缘方向感知建模( Direction-aware edge modeling, DEM )驱动的旋转叶片检测算法( DLE-DETR )及基于旋转角度时序建模( ROST )的计数方法。首先,针对叶片反光及旋转姿态导致的边缘提取困难问题,在 DETRv2 框架下引入 DEM 模块,通过显式建模边缘方向信息,增强模型对旋转叶片边缘的精细感知与表征能力。其次,针对叶片运动状态复杂导致的计数难题,提出 ROST 计数方法,通过联合利用旋转角度变化趋势、轨迹连续性及状态机机制,实现了对“停止-反转-再旋转”等复杂工况下叶片的稳定、准确计数。

与现有旋转目标检测方法不同,本文关注的航空发动机叶片在工业内窥成像条件下呈现出高长径比、强反光、边缘模糊且姿态连续变化等显著特征,其检测难点并非仅来源于目标方向变化本身,而是源于旋转过程中边缘方向信息在特征提取阶段的退化与混叠。现有旋转目标检测方法主要从框级几何参数建模角度提升方向感知能力,但通常依赖于高质量的特征响应作为前提。当叶片表面存在强反光或局部遮挡时,其边缘

梯度分布会显著失真,导致旋转框回归不稳定。为此,本文提出的 DEM 并非替代现有旋转检测范式,而是在特征编码阶段显式注入边缘方向先验,通过对多方向边缘响应的分解、选择性增强与重组,使网络在执行全局自注意力建模之前,即具备对叶片真实几何走向的稳定感知能力。该设计从特征层方向建模的角度弥补了现有旋转检测方法在细长目标边缘感知方面的不足,是针对航空发动机叶片孔探场景的必要补充。

## 1 研究方法

### 1.1 DLE-DETR 模型结构

DLE-DETR 模型总体结构如图 1 所示,主要由主干网络(Backbone)、DEM 辅助分支、高分辨率侧分支(LHB)、旋转框检测头(Fusion+OBB head)4 部分构成。各模块之间通过分层特征连接、跨分支特征融合和方向性增强机制构成一个完整的多模态检测体系,使模型在复杂光照、强反光、模糊条件下仍能保持稳定、连

续、高精度的叶片检测。

本文提出的航空发动机叶片检测与计数模型整体建立在 DETRv2 目标检测框架之上。首先,Backbone 对输入图像进行多尺度特征提取。在此阶段,引入 LHB 增强机制,将 Backbone 的 Stage3 高分辨率特征直接引出并对齐,作为独立尺度输入至编码器,以保留旋转叶片的关键边缘与方向信息。同时,在特征编码阶段嵌入 DEM 模块,遵循“分解—增强—重组”原则,显式增强特征图中旋转叶片的方向性边缘表示。然后,将这些富含方向信息的多尺度特征送入 Deformable Transformer 编码器进行全局建模。最后,在解码器(Decoder)部分,引入边缘感知回归权重模块(EARW)嵌入至回归预测头之前,通过显式建模边缘显著性,引导回归分支聚焦于目标的真实几何轮廓,从而提升旋转框参数预测的稳定性与精度。

需要说明的是,本文中所提及的“形态变化”并非指叶片的结构形变

或损伤演化,而是指在孔探成像过程中,由视角变化、成像距离变化及透视效应引起的叶片轮廓在图像平面中的表现形态差异,例如边缘曲率、可见长度及局部轮廓形状的变化。

### 1.2 DEM 模块

本文在 DETRv2 框架下引入轻量级、即插即用的 DEM 模块,用于显式增强旋转叶片的方向性边缘表示。该模块可无缝嵌入至多尺度特征融合之前,不改变原有 Transformer 编解码结构,仅对中间特征进行方向性增强。该模块的整体设计遵循分解—增强—重组的原则,其结构示意图如图 2 所示。

首先对多方向的边缘特征进行分解,给定来自 Backbone 的输入特征图  $F_{in} \in \mathbb{R}^{C \times H \times W}$ ,使用一组方向可分离卷积来替代标准卷积,以显式地分解不同方向的边缘信息。本文定义了  $K$  个主要方向( $K=8$ ,覆盖  $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ$ ),方向数  $K$  用于刻画特征图中主要边缘走向。本文选取  $K=8$ ,对应  $0^\circ \sim 315^\circ$




图 1 DLE-DETR 模型示意图

Fig.1 Schematic diagram of the DLE-DETR model

的 8 个均匀分布方向,该设置在表达能力与计算复杂度之间取得平衡。较小的  $K$  值(如 4)难以充分覆盖叶片在连续旋转过程中的细粒度方向变化,而进一步增大  $K$  值对检测精度提升效果有限,却会引入额外计算负担。对于每个方向  $k$  ( $k$  表示 8 个主要方向中的其中一个方向),使用一个对应的参数化的方向性卷积核  $D_k$  (可视为学习式的方向滤波器)对输入特征进行滤波,即

$$E_k = D_k \times F_{in}, k=1,2,3 \cdots K \quad (1)$$

式中,  $E_k$  为方向  $k$  的边缘响应图。这一步将原始的混合特征分解为  $K$  个方向子空间,每个子空间强化了特定朝向的边缘梯度。

然后,对方向特征选择性增强,直接分解的特征可能存在噪声或响应不均。为此,引入了一个方向注意力模块,动态地评估并增强当前特征图上最重要的边缘方向。先对所有方向响应图  $\{E_k\}$  进行全局平均池化,得到一个  $K$  维的方向显著性向量  $v$ 。再通过一个小型全连接网络 (FC-ReLU-FC) 与 Softmax 函数,生成一个  $K$  维的方向注意力权重向量  $\alpha$ 。最后使用注意力权重对分解后的特征进行加权融合与增强。

$$F_{enhanced} = \sum_{k=1}^K \alpha_k \cdot (E_k + \gamma \cdot DWConv(E_k)) \quad (2)$$

其中,  $\gamma$  是一个可学习的缩放因子, DWConv 是一个深度可分离卷积,用于对增强后的方向特征进行微调。该机制使模块能自适应地聚焦于与当前场景和目标最相关的边缘方向。

最后,与原特征重组。为避免方向性信息引入的偏差并保留原始特征的完整性,将增强后的方向性特征  $F_{enhanced}$  与原始的输入特征  $F_{in}$  进行自适应融合,即

$$F_{out} = \beta \odot F_{enhanced} + (1 - \beta) \odot F_{in} \quad (3)$$

其中,  $\beta$  是一个由通道注意力机制生成的空间自适应权重图,控制着

每个位置从方向性特征中汲取信息的程度。最终输出的  $F_{out}$  既富含对方向敏感的边缘结构信息,又保留了原始的上下文语义信息,被送入后续的检测头进行预测。

通过将 DEM 模块嵌入 DETRv2 的特征编码阶段,本文构建了一个方向感知的 Transformer 检测框架。该设计使模型在执行全局自注意力建模之前,在局部特征中显式编码叶片的边缘信息,从而有效缓解 DETR 类模型在旋转目标检测中对细粒度边缘结构建模不足的问题。试验结果表明,该模块在不增加计算复杂度的前提下,提升了旋转叶片检测的定位精度与角度回归稳定性。

### 1.3 Lightweight HR Branch 模块

本文提出的面向 Deformable DETR 的 LHB 增强机制,其核心思想是在 Backbone 的早期阶段显式引入高分辨率特征通路,如图 3 所示,使其直接参与 Transformer 编码阶段的多尺度注意力建模,从而在全局语义

建模的同时保留旋转叶片的关键边缘与方向信息。具体而言,本文在 Backbone 的 Stage3 (1/8 分辨率) 引出高分辨率特征,并通过轻量化通道映射与位置编码对齐后,将其作为独立尺度输入至编码器,与原有的中低分辨率特征共同构成多尺度特征集合。

本文在 Backbone 的 Stage3 (1/8 分辨率) 引出旁路分支。这一阶段的选择基于以下考量。

(1) 信息完整性: 该阶段特征仍保留较为丰富的高频边缘与方向信息,叶片前缘与后缘结构尚未被全局注意力稀释。

(2) 语义基础: 经过浅层卷积特征提取后,特征图已具备初步的前景-背景区分能力,有助于抑制噪声干扰。

(3) 计算平衡: 1/8 分辨率在特征密度与 Transformer 计算复杂度之间取得良好平衡,避免高分辨率特征直接输入所带来的计算负担。




图 2 DEM 模块  
Fig.2 DEM module




图 3 LHB 模块  
Fig.3 LHB module

设 Backbone 在第  $S$  个阶段输出的特征图为  $F^s \in \mathbb{R}^{C_s \times H_s \times W_s}$ 。在标准 DETRv2 模型中,多尺度特征通常经过通道映射后统一送入编码器。本文在此基础上,额外引入一条高分辨率旁路分支,对选定阶段的特征进行轻量化处理后,作为独立尺度特征参与后续的多尺度注意力计算。本文选择在 Backbone 的 Stage3 (1/8 分辨率)引出高分辨率旁路特征,记该阶段输出为  $F_{HR} = F^3 \in \mathbb{R}^{C^3}$  该特征在进入编码器之前,首先通过一个轻量化通道映射层进行维度对齐,随后,为保证其与 Transformer 中的序列建模兼容,引入位置编码  $P_{HR}$ ,构成最终输入特征,即

$$\begin{cases} \widetilde{F}_{HR} = \mathcal{O}(F_{HR}) = \text{Conv}_{1 \times 1}(F_{HR}) \\ Z_{HR} = \widetilde{F}_{HR} + P_{HR} \end{cases} \quad (4)$$

其中,  $\mathcal{O}$  表示  $1 \times 1$  卷积映射操作,用于将通道数调整至与其他尺度特征一致。该高分辨率特征  $Z_{HR}$  被作为一个额外尺度层级,与原有的中低分辨率特征共同组成多尺度特征集合  $\{Z_i\}$ ,输入至 Deformable Transformer Encoder。

同时该高分辨率分支作为新增尺度参与 Deformable Attention 机制中,每个 Query 通过多尺度特征图上预测一组稀疏采样点来聚合信息。引入高分辨率旁路后,第 1 个尺度的注意力计算可表示为

$$\text{Attn}(q) = \sum_l \sum_{m=1}^M A_{l,m}(q) \cdot Z_l(\Delta p_{l,m}(q)) \quad (5)$$

式中,  $Z_l$  包含新增的高分辨率特征  $Z_{HR}$ ;  $\Delta p_{l,m}$  为采样偏移位置;  $A_{l,m}$  为对应的注意力权重。由于高分辨率旁路提供了更加密集且连续的空间采样候选点,注意力机制能够沿叶片长边方向形成更稳定的一致响应,从而增强模型对旋转方向、细长结构及边缘连续性的感知能力。

通过在 DETRv2 中引入高分辨率特征旁路增强机制,模型在保持

Transformer 全局建模优势的同时,有效缓解了高速旋转叶片在编码阶段的边缘退化问题。该模块为后续的 DEM 与旋转框回归提供了更稳定的几何基础,实现了高分辨率几何细节与高层语义信息的互补融合。

#### 1.4 EARW 模块

为充分挖掘叶片真实边界对几何回归的引导作用,本文提出一种边缘感知回归权重模块(Edge aware regression weight, EARW),并将其嵌入 DETRv2 解码器的回归预测头之前。该模块通过显式建模边缘显著性,引导回归分支在训练与推理过程中更加关注目标的真实几何轮廓区域,从而提升旋转框参数预测的稳定性与精度。

边缘提示生成器是模块的第一阶段,其任务是从回归特征中提取边缘存在的可能性信息。与传统的边缘检测算子不同,其设计了一个完全可学习的边缘感知层,能够适应叶片边缘的特殊性。本文设计了 8 个不同方向的边缘检测卷积核,分别对应  $0^\circ \sim 315^\circ$  的 8 个主要方向。这些卷积核在训练过程中学习如何最有效地响应叶片边缘的特定方向特征。采用轻量级并行卷积组(包含  $3 \times 3$  Sobel-like 卷积核与  $1 \times 1$  通道压缩卷积),分别捕获特征图在水平与垂直方向的梯度响应,即

$$E = \sigma \left( \text{Conv}_{1 \times 1} \left[ \text{Conv}_{\text{sobel}_x}(F); \text{Conv}_{\text{sobel}_y}(F) \right] \right) \quad (6)$$

式中,  $\sigma$  为 Sigmoid 函数;  $E$  为边缘概率图,其高值区域对应特征图中的潜在边缘位置。通过多方向卷积的并行处理,系统能够全面捕捉叶片边缘的各种走向,无论是水平方向的风机叶片,还是倾斜的螺旋桨叶片。每个方向的卷积输出表示该方向边缘的响应强度。将这些多方向的响应进行加权融合,形成一个综合的边缘概率图。这个概率图的每个像素值在 0~1 之间,直观表示该位置属于叶

片边缘的可能性大小。为了增强边缘提示的鲁棒性,本文还引入了一个小型上下文网络,利用局部邻域信息对原始边缘概率进行优化。

基于边缘提示生成器输出的概率图,边缘权重计算器负责生成最终的空间权重分布。这个过程不仅考虑单个位置的边缘概率,还综合考虑空间上下文关系,确保权重分布的合理性和连续性。首先,将基础边缘概率转换为初步权重,通过一个可调节的增强因子使边缘区域获得 2~3 倍的权重提升。这一步骤确保了边缘区域在后续的特征调制中获得足够的关注。然而,简单的点对点权重映射可能过于碎片化,特别是对于模糊或部分遮挡的边缘。因此引入空间平滑处理,使一个高权重的边缘点能够将其影响力适度扩散到邻近区域。空间连续权重计算为

$$W = \text{Normalize}(1 + \gamma \times (E * G_\sigma)) \quad (7)$$

式中,  $G_\sigma$  为高斯平滑核;  $\gamma$  控制边缘增强强度; Normalize 确保权重分布均衡;  $*$  表示卷积操作。最后对权重进行局部归一化处理,防止某些区域权重过高而其他区域权重过低,确保权重分布的平衡性。归一化过程在局部邻域内进行,保持了空间适应性。

特征加权调制器将计算得到的边缘权重应用于原始的回归特征。通过逐位置的乘法操作,边缘区域的特征值被增强,而非边缘区域的特征值相对减弱。这种调制操作相当于给网络提供了一个“注意力指南”,明确指出哪些特征对边界回归更为重要。为了保持训练的稳定性,信息的完整性,采用了残差连接设计。调制后的特征与原始特征按一定比例混合,这个混合比例在训练过程中可自适应学习。初始阶段,网络能更依赖原始特征;随着训练进行,边缘调制特征的重要性逐渐提高。这种渐进式学习策略避免了训练初期的

振荡和不稳定。

边缘感知回归权重模块通过引入空间自适应的边缘敏感机制,有效解决了旋转叶片检测中边缘区域回归精度不足的核心问题。该模块的智能权重分配使网络能够聚焦于真正决定边界位置的关键特征,提升了边界预测的准确性和稳定性。

### 1.5 计数方法

航空发动机叶片检测的计数部分聚焦于两大核心目标:预测旋转方向和计算叶片数量。在航空发动机内窥检测过程中,叶片通常处于连续旋转状态。其形态呈现出明显的细长结构与强方向性特征。需要指出的是,本文所述的“高速旋转”并非指发动机在额定工况下的真实转速水平,而是从视觉检测与图像分析角度出发,指叶片在相邻视频帧之间产生显著角位移,从而对目标检测、跟踪与计数算法构成挑战的旋转运动状态。在实际工况下,叶片可能存在转速变化、短暂停止及旋转方向反转等复杂运动状态,仅依赖目标的空间位移或检测框数量进行计数,极易产生漏计、误计等问题。为此,本文提出一种基于旋转角度时序建模(ROST)的航空发动机叶片计数方法,结构如图4所示,通过联合利用旋转角度变化趋势、轨迹连续性及ROI边界穿越关系,实现对旋转叶片的稳定、准确计数。

首先,在每一帧内窥图像中,采用旋转目标检测模型对叶片进行检

测,并以 DETRv2-OBb 变体中定向包围框(Oriented bounding box, OBb)对叶片进行几何建模。对于第  $t$  帧中检测到的第  $i$  个叶片,其 OBb 表示为  $B_i^t \in (x_i^t, y_i^t, w_i^t, h_i^t, \theta_i^t)$ 。其中,  $(x_i^t, y_i^t)$  表示检测框中心坐标,  $w_i^t$  与  $h_i^t$  分别表示框的宽度与高度,  $\theta_i^t \in [-\pi/2, \pi/2)$  表示叶片相对水平轴的旋转角度。相比水平检测框,OBb 能够更准确地贴合叶片边缘姿态,为后续旋转方向的预测提供可靠的几何基础。同时,为保证跨帧计数的一致性,采用基于检测框空间位置与几何特征相结合的多目标跟踪策略,将同一物理叶片在连续帧中的检测结果关联为一条轨迹。为了刻画叶片的旋转行为,引入离散角速度。考虑到检测噪声及运动模糊可能导致单帧角度波动,在轨迹级别上采用滑动窗口平均角速度  $\overline{\Delta\theta_k}$  来增强鲁棒性,具体公式为

$$\begin{cases} \theta_k = \{\theta_k^i, \theta_k^{i+1}, \dots, \theta_k^j\} \\ \Delta\theta_k^i = \theta_k^i - \theta_k^{i-1} \\ \overline{\Delta\theta_k} = \frac{1}{N-1} \sum_{j=2}^N (\theta_k^j - \theta_k^{j-1}) \end{cases} \quad (8)$$

式中,  $k$  为叶片轨迹;  $[t_1, t_2]$  为时间窗口;  $N$  为角度时间窗口长度。

然后,根据角度变化趋势,对航空发动机叶片的旋转状态进行判别,预先定义3个旋转状态:顺时针旋转(CW)、逆时针旋转(CCW)、短暂停止或者低速抖动(STATIC)。设定角度阈值  $\varepsilon$ ,3种状态的判别方式为

$$S_k = \begin{cases} \text{CW}, & \overline{\Delta\theta_k} > \varepsilon \\ \text{CCW}, & \overline{\Delta\theta_k} < -\varepsilon \\ \text{STATIC}, & |\overline{\Delta\theta_k}| \leq \varepsilon \end{cases} \quad (9)$$

在 ROST 状态机中,引入角度阈值  $\varepsilon$  用于区分有效旋转与短时抖动。该阈值根据试验平台中检测角度噪声分布进行经验设定,使得小于  $\varepsilon$  的角度变化被判定为静止或低速抖动状态。通过该设计,系统能够有效抑制由单帧角度预测误差引发的状态频繁切换,提高计数决策的时间一致性。试验中发现,在  $\varepsilon$  的合理区间内,计数结果对该参数变化不敏感,表明所设参数具有良好的稳定性。同时,为应对叶片在检测过程中可能出现的停止—反转—再旋转现象,引入基于轨迹的旋转状态有限状态机(Finite state machine, FSM)。状态转移规则如下:

- (1) 当  $\overline{\Delta\theta_k} \leq \varepsilon$  持续3帧时,轨迹进入 STATIC 状态;
- (2) 当轨迹由 STATIC 状态进入 CW 或 CCW 状态时,判定为旋转重新启动;
- (3) 当轨迹由 CW 状态切换至 CCW (或反之)时,判定为旋转方向反转。

该状态机使得系统能够在旋转方向发生变化时动态调整计数策略,从而避免误计或漏计。在完成旋转方向判别后,本文在预定义的感兴趣区域(Region of interest, ROI)内进




图4 ROST计数模型示意图  
Fig.4 Schematic diagram of the ROST counting model

行计数。对于轨迹  $k$ , 必须满足以下条件时触发一次计数:

(1) 轨迹长度大于最小帧数阈值;

(2) 当前旋转状态为 CW 或 CCW;

(3) 叶片边缘中心点从 ROI 区域的一侧边界穿越至另一侧边界, 且方向与旋转方向一致;

(4) 在当前旋转方向下尚未被计数。

当叶片边缘在检测过程中进入 STATIC 状态时, 系统暂停计数。若随后检测到旋转方向发生反转, 则清除该轨迹在新方向下的计数标记, 从而实现在反向旋转过程中再次被正确计数。该机制有效解决了传统方法在“停止一反转”场景下的重复计数或漏计问题

## 2 试验结果与讨论

### 2.1 试验平台

为系统性评估所提出方法在实际场景下的性能表现, 本文自主搭建了一套航空发动机叶片检测试验平台, 其具体结构与布局如图 5 所示。该平台的外形物理尺寸为  $120\text{ cm} \times 110\text{ cm} \times 90\text{ cm}$ , 平台内部高度还原了航空发动机的核心叶盘结构, 集成了涡轮叶片、压气机叶片及风扇叶片等典型内部组件, 所有叶片均按照实际装机标准安全、稳固地装配于专用转

轴之上, 确保其空间位置与运动状态贴合真实发动机的内部布局。平台配备了高精度驱动电动机, 可同步驱动多级叶片进行旋转运动, 支持顺时针与逆时针两种运转方向, 且各级叶片的旋转速度保持一致。同时, 该平台的转速具备灵活可调特性, 调节范围覆盖  $5^\circ/\text{s} \sim 20^\circ/\text{s}$ , 试验平台设置了慢速和快速两种运行模式。慢速模式下, 叶片在相邻帧之间的角位移较小, 检测目标在时间维度上变化平缓; 快速模式下, 叶片在相邻帧之间的旋转角度明显增大, 部分帧中相邻叶片的投影区域存在显著重叠, 对检测稳定性和计数准确性提出了更高要求。该平台能够模拟不同工况下叶片的动态转动状态, 为本文方法的鲁棒性测试提供多样化的运动场景支撑。

试验中所采用的视觉传感器为 SEESEM 公司生产的 S70 工业视频内窥镜, 其图像采集分辨率可达  $1920\text{ 像素} \times 1200\text{ 像素}$ , 能够提供高清晰度的叶片细节信息。该内窥镜的视场角 (FOV) 为  $120^\circ$ , 可覆盖较广的观测范围; 探头直径仅为  $6\text{ mm}$ , 能够适配针孔接口并灵活深入平台内部狭小空间。此外, 探头还内置了高亮度 LED 光源, 可在平台内部形成均匀稳定的照明环境, 有效缓解发动机内部光线不足、光照不均对图像质量的影响。内窥镜捕获的图像数据通过 4 层铝合金丝编织导管进行传输, 该

导管具备良好的柔韧性与抗干扰性, 可保障图像数据的稳定、无损传输。

为实现对平台内部叶片的视觉数据采集, 该试验平台在壳体对应位置预留了 4 个针孔接口, 用于部署内窥镜。该内窥镜探头支持多视角观测模式, 包含前视图、侧视图等观测角度, 且不同视角之间可通过操作界面实现快速、便捷地切换, 便于获取叶片不同方位的外观特征。同时, 操作员可通过专用电动操纵杆对探头进行精准控制, 实现探头的  $360^\circ$  全向自由旋转与转向调节。操纵系统还配备了锁定微调与步进调整功能, 能够对探头位置进行精细化校准, 并支持“快速”“慢速”两档控制速度切换, 可根据实际观测需求灵活调整探头的运动节奏, 确保高效、全面地采集到平台内部各类叶片的视觉数据, 为后续方法的性能评估提供丰富、可靠的试验样本。

### 2.2 航空发动机叶片数据集

为支撑所提方法的性能验证, 本文基于自主搭建的试验平台采集并构建了航空发动机叶片 (Aero-engine blade, AEB) 专用数据集。该数据集内的数据均由内窥镜采集, 涵盖了涡轮、压气机、风扇等典型航空发动机叶片的真实孔探视觉图像。原始数据集包含 5000 张叶片内窥镜图像, 为模拟实际检测场景中可能出现的复杂工况, 本文采用 Python 开源库




图 5 试验平台

Fig.5 Experimental platform

Imgaug 对原始图像进行数据增强处理,具体涵盖高亮度/低亮度光照模拟、局部反光干扰模拟、叶片旋转角度变换等场景扩充,经增强后数据集规模扩展至 17620 张图像。所有图像均通过 X-AnyLabeling-CPU 标注工具完成叶片目标的人工标注与信息注释,标注内容包含叶片的位置、边界框及类别信息。最终将该数据集按照 8:1:1 的比例随机划分为训练集、测试集与验证集,分别用于模型的训练优化、性能评估与参数调优,确保试验数据分布的合理性与评估结果的可靠性。

在模型训练阶段,初始学习率设置为 0.002,并采用余弦衰减策略逐步降低学习率,最终学习率衰减系数为 0.01。优化过程中引入动量参数 0.937 与权重衰减系数  $5 \times 10^{-4}$ ,以增强模型的泛化能力并抑制过拟合。为保证训练初期的稳定性,设置 3 个 warm-up epochs,并对学习率与动量参数进行线性预热。模型训练共进行 200 个 epoch,并设置 Early Stopping 机制,当验证集性能在 100 个 epoch 内不再提升时提前终止训练。在数据增强方面,引入适用于旋转目标检测的多种增强策略,包括随机旋转( $\pm 15^\circ$ )、尺度缩放、平移、剪切及 Mosaic、MixUp 和 Copy-Paste 等操作,以提升模型对叶片姿态变化和复杂背景条件的鲁棒性。同时,通过增强边界框回归相关损失项(Box Loss=10.0, DFL Loss=2.0),进一步强化模型对旋转边界框几何参数的回归精度。

## 2.3 航空发动机叶片边缘检测算法性能测试

### 2.3.1 评估指标

为全面评估所提方法在航空发动机叶片检测任务中的综合性能,本文从计算复杂度、检测速度与检测精度 3 个维度构建评估体系,在具体评估指标选取上:计算复杂度采用每秒千兆浮点运算数(GFLOPs)量化,表征模型的计算开销;检测速度以

帧率(帧/s)为单位,衡量模型的实时处理能力;检测精度则采用目标检测领域通用的平均精度(Average precision, AP)指标,具体选取  $AP_{50}$  与  $AP_{50-95}$  两项细分指标,其中  $AP_{50}$  代表交并比(IoU)阈值为 0.5 时的平均精度,  $AP_{50-95}$  代表 IoU 阈值在 0.50~0.95 区间内的平均精度,可全面反映模型在不同匹配精度要求下的检测性能。AP 计算公式为

$$\begin{cases} P_i = \frac{TP_i}{TP_i + FP_i}, R_i = \frac{TP_i}{N_{gt}} \\ P_{interp}(R_i) = \max_{\tilde{R} \geq R_i} P(\tilde{R}) \\ AP = \sum_{i=1}^{n-1} (R_{i+1} - R_i) P_{interp}(R_{i+1}) \end{cases} \quad (10)$$

式中,  $TP_i$  为在第  $i$  个预测阈值下,模型正确预测为正样本的数量;  $FP_i$  为模型错误预测为正样本的数量;  $N_{gt}$  为在数据集中真实标注的正样本总数;  $P_i$  为召回位置处的精确率;  $R_i$  为召回率;  $P(R)$  为在特定召回率  $R$  下的精确率;  $P_{interp}(R_i)$  为在召回率  $R_i$  处的单调插值精确率;  $\tilde{R}$  为所有不小于当前召回率  $R_i$  的召回率取值范围。针对航空发动机叶片缺陷检测场景,  $AP_{50}$  与  $AP_{50-95}$  指标能够全面反映模型在低照度、反光、多姿态等复杂检测条件下的精度与稳定性,同时可有效评估模型在不同 IoU 阈值下对叶片细微缺陷的检出能力。

### 2.3.2 叶片检测算法对比试验

为验证 DLE-DETR 模型的性能,本文将其与主流单阶段目标检测算法(DETR、YOLO 系列)及基于自注意力机制的实时编解码结构 RT-DETR 进行对比分析,选取 SSD300(VGG-16)、YOLOv11-OBB、YOLOX-OBB-L 及 RT-DETR-R50 4 种代表性模型开展对照试验。图 6 展示了各模型的检测效果对比,其中 SSD300(VGG-16)在本文叶片检测场景中表现最差,其采用的 VGG-16 特征提取网络深度有限,缺乏多尺度感受野与高层语义表达能力,难以在

复杂背景与反光干扰条件下提取叶片边缘细节和微小结构特征,导致误检与漏检现象明显增多。

相比之下,DLE-DETR 得益于在特征融合阶段引入 DEM 辅助特征增强模块,并在旋转框预测头中采用具有方向敏感性的可变形注意力机制,能够在低照度、反光、高噪声等孔探成像条件下稳健提取叶片轮廓、边缘走向、细节及微小结构特征,从而提升检测与计数精度。

各模型的定量试验结果如表 1 所示。可见,与当前表现最优的对比方法 YOLOv11-OBB 相比, DLE-DETR 的  $AP_{50}$  与  $AP_{50-95}$  指标分别提升 2.08 与 2.42 个百分点。同时,DLE-DETR 检测速率达到 40 帧/s,计算复杂度较 YOLOv11-OBB 降低 37.87%,实现了检测精度、计算效率与推理速度的全面优化。

### 2.3.3 消融试验

为定量分析各核心模块对模型性能提升的具体贡献,本文在统一训练策略与参数设置下,开展了系统性的消融试验。以 DETRv2-OBB 为基线模型,逐步引入 LHB 模块、DEM 模块及 EARW 模块,并对叶片检测精度( $AP_{50}$ )进行对比分析。试验结果如表 2 所示。

由表 2 可以看出, LHB 模块通过引入高分辨率特征旁路,有效缓解了旋转叶片在编码阶段的边缘信息退化问题,  $AP_{50}$  提升了 0.79 个百分点,为后续方向建模提供了稳定基础;在此基础上,引入 DEM 模块后,模型对旋转叶片边缘方向的感知能力显著增强,精度提升了 1.8 个百分点,验证了边缘方向显式建模在该任务中的有效性;最终, EARW 模块通过在回归阶段强化真实边界区域的特征响应,提升了旋转框参数预测的稳定性,使整体性能达到最优。上述结果表明,各模块在功能上具有明确分工,性能提升并非简单叠加,而是来源于对叶片几何特征的逐层强化




图6 不同模型检测结果

Fig.6 Detection results of different models

建模。

## 2.4 航空发动机叶片边缘检测算法性能测试

### 2.4.1 评估指标

在航空发动机叶片计数任务中,当前帧的计数结果需基于前一帧计数值进行累加更新,这导致计数误差具有帧间传递特性。此类误差会随帧数累积不断放大,进而持续影响后续帧的计数精度,最终导致整体计数结果出现明显偏差。

为定量评估所提出方法在航空发动机叶片计数任务中的准确性,本文采用计数准确率(Accuracy, Acc)作为主要评价指标。该指标可直接量化模型输出的叶片计数结果与真实叶片数量的吻合程度,以平均绝对误差(Mean absolute error, MAE)来衡量预测叶片数量与真实值之间的偏差。方向辨别准确率(Direction accuracy, D-Acc)来衡量系统正确识别CW、CCW和STATIC状态的帧数占比,其具体定义为

$$\text{Acc} = 1 - \frac{|N_{\text{pred}} - N_{\text{gt}}|}{N_{\text{gt}}} \quad (11)$$

$$\text{MAE} = \frac{1}{M} \sum_{i=1}^M |N_{\text{pred}}^{(i)} - N_{\text{gt}}^{(i)}| \quad (12)$$

式中,  $N_{\text{pred}}$  表示算法输出的叶片计数结果;  $N_{\text{gt}}$  表示人工标注的真实叶片数量。

表1 叶片边缘检测方法对比结果

Table 1 Comparison of blade edge detection methods

| 模型              | AP <sub>50</sub> /% | AP <sub>50-95</sub> /% | CFLOPs | 帧率/(帧/s) |
|-----------------|---------------------|------------------------|--------|----------|
| SSD300 (VGG-16) | 82.67               | 66.17                  | 36.1   | 41       |
| YOLOv11-OBB     | 91.72               | 72.47                  | 132    | 42       |
| YOLOX-OBB-L     | 86.75               | 68.28                  | 125    | 32       |
| RT-DETR-R50     | 88.45               | 69.08                  | 142    | 31       |
| DLE-DETR        | 93.80               | 74.89                  | 82     | 40       |

表2 模型消融试验结果

Table 2 Results of model ablation experiment

| 模型配置                     | LHB | DEM | EARW | AP <sub>50</sub> /% |
|--------------------------|-----|-----|------|---------------------|
| Baseline                 | ×   | ×   | ×    | 90.24               |
| +LHB                     | ✓   | ×   | ×    | 91.03               |
| +LHB+DEM                 | ✓   | ✓   | ×    | 92.83               |
| +LHB+DEM+EARW (DLE-DETR) | ✓   | ✓   | ✓    | 93.80               |

### 2.4.2 航空发动机叶片计数试验

为验证所提方法在叶片旋转转向切换场景下的计数稳定性及准确性,在航空发动机孔探视觉检测的真实工况中开展针对性测试,计数结果如图7所示。在146~201帧区间内,航空发动机叶片处于短暂静止状态;在201帧时,叶片旋转方向发生切换。在46~66帧区间,图像中叶片边缘特征点从绿色区域迁移至红色区域,触发ROST模型的状态转移,成功完成一次正向计数;201~221帧

期间,叶片边缘特征点由红色区域反向迁移至绿色区域,再次触发模型状态转移,实现一次反向计数。真实工况下的测试结果表明,计数准确率达100%,所提计数算法在叶片旋转方向切换及短暂静止的复杂场景中,仍能实现精准计数。

为验证所提方法在完整旋转周期内的计数准确性,本文在试验平台上进行了一整圈(360°)的叶片计数试验。试验设置如下:选取涡轮叶片级(叶片数为8片)、压气机叶片级




图 7 关键帧叶片计数过程

Fig.7 Keyframe blade counting process

(叶片数为 12 片)和风扇叶片级(叶片数为 22 片),分别在 5°/s 的慢速模式和 20°/s 的快速模式下进行完整旋转。在 5°/s 模式下,完成 360° 旋转需要 72 s;在 20°/s 模式下,完成 360° 旋转需要 18 s。

完整旋转周期计数结果如表 3 所示。试验结果表明,在慢速模式下,3 种叶片的计数准确率均达 100%;在快速模式下,由于叶片运动速度加快,相邻帧之间叶片的角位移增大,但所提 ROST 方法通过轨迹级角度时序建模与状态机机制,依然保持了 100% 的计数准确率。这充分验证了所提方法在完整旋转周期内具有良好的计数稳定性和准确性,能够满足实际航空发动机孔探检测中对叶片计数的精度要求。

为了评估所提出 ROST 方法在实际航空发动机叶片检测场景中的工程适用性,并验证其在叶片快速旋转(速度为 5°/s~20°/s)、短暂停止及反转等复杂工况下的计数稳定性,将 ROST 与传统的基于水平检测框(HBB)+质心位移计数的方法进行了对比。试验结果如表 4 所示。

试验结果表明,在常规匀速场景下,ROST 凭借 OBB 更精准的姿态描述,Acc 达到了 98.2%。而在更具挑战性的“停止一反转”场景下,传统方法由于无法感知方向变化,产生了大量的漏计,Acc 跌至 45.0%;而本文方法通过 FSM 状态机动态调整计数逻辑,依然保持了 95.5% 的高精

表 3 完整旋转周期叶片计数结果

Table 3 Blade counting results for complete rotation cycle

| 叶片类型  | 真实数量 / 片 | 5°/s 模式  |       | 20°/s 模式 |       |
|-------|----------|----------|-------|----------|-------|
|       |          | 计数结果 / 片 | Acc/% | 计数结果 / 片 | Acc/% |
| 涡轮叶片  | 8        | 8        | 100   | 8        | 100   |
| 压气机叶片 | 12       | 12       | 100   | 12       | 100   |
| 风扇叶片  | 22       | 22       | 100   | 22       | 100   |

表 4 ROST 与 HBB+ 位移计数方法对比

Table 4 Comparison of the ROST and HBB+ displacement counting methods

| 场景类型  | 方法        | MAE  | Acc/% | D-Acc/% |
|-------|-----------|------|-------|---------|
| 常规匀速  | HBB+ 位移计数 | 0.42 | 92.5  | —       |
|       | 本文方法      | 0.12 | 98.2  | 99.1    |
| 停止一反转 | HBB+ 位移计数 | 3.55 | 45.0  | —       |
|       | 本文方法      | 0.31 | 95.5  | 96.8    |

准率。

为了验证航空发动机叶片在不同场景下计数算法的鲁棒性,本文以试验平台的 3 种叶片为研究对象,将本文使用的叶片计数算法和现有的主流算法(基于 DeepSORT<sup>[31]</sup> 的越线计数算法、基于光流-统计<sup>[31]</sup> 的计数方法)在复杂反转工况(包含旋转—停止一反转)场景下进行了对比,试验中分别选用 SSD300 (VGG-16)、YOLOv11-OBB、YOLOX-OBB-L 及 RT-DETR-R50 作为叶片检测模型,计数结果如表 5 所示。

试验结果表明,本文方法优于 DeepSORT<sup>[31]</sup> 的越线计数算法、光流-统计计数<sup>[36]</sup> 方法。这两种主流

算法在反光场景、复杂背景和暗光场景下因环境因素干扰而导致计数不准确。对基于 ROI 区域越线计数时,边缘角度的动态变化也会使两种主流算法计数出现偏差。本文引入滑动窗口平均角速度来抑制单帧角度预测噪声,增强计数决策在短暂停止、方向反转及低信噪比条件下的时间一致性,从而避免由角度抖动引发的误计数与重复计数问题。此外,所提方法可高效提取叶片的边缘特征,有效解决了因叶片表面反光干扰与几何形态多变而引发的目标检测漏检率偏高的问题,相较于 YOLOv11-OBB、YOLOX-OBB-L 及 RT-DETR-R50,本文方法在叶片计

表5 计数结果  
Table 5 Counting results

| 方法                  | 涡轮叶片<br>计数结果 | 压气机叶片<br>计数结果 | 风扇叶片计<br>数结果 | MAE | Acc/% | D-Acc/% |
|---------------------|--------------|---------------|--------------|-----|-------|---------|
| DeepSORT 越线计数       | 21           | 32            | 34           | 8.5 | 79.2  | 72.5    |
| 光流-统计联合方法           | 18           | 30            | 31           | 6.8 | 83.5  | 76.5    |
| YOLOv11-OBB+FSM-OBB | 22           | 36            | 39           | 4.2 | 89.6  | 91.5    |
| YOLOX-OBB-L+FSM-OBB | 21           | 34            | 37           | 2.5 | 93.8  | 94.8    |
| RT-DETR-R50+FSM-OBB | 23           | 36            | 40           | 1.2 | 96.9  | 98.1    |
| 本文方法                | 23           | 38            | 42           | 0.5 | 98.6  | 99.4    |

数任务中表现优于其他主流目标检测器,平均计数精度达 98.6%。相较于 YOLOv11-OBB、YOLOX-OBB-L 及 RT-DETR-R50 等基于统计光流的检测方法,本文所提方法在涡轮、压缩机及风扇叶片的计数任务中,平均精度实现了提升,相较于 DeepSORT<sup>[31]</sup> 的越线计数算法提升幅度达 24.49%。

#### 2.4.3 复杂工况下的鲁棒性分析

在实际航空发动机孔探检测过程中,叶片的运动状态和成像条件往往更加复杂,除常规匀速旋转和停止-反转工况外,还可能存在叶片严重遮挡、部分出镜及多个叶片在短时间内连续或同时穿越 ROI 边界等情况。上述因素均会对基于单帧检测或简单位移统计的计数方法造成显著干扰,导致漏计或重复计数问题。

(1) 叶片严重遮挡。针对叶片严重遮挡场景,ROST 方法并不依赖单帧检测结果触发计数,而是基于轨迹级角度时间序列建模与最小轨迹长度约束进行决策。当叶片因短时遮挡导致检测中断时,其对应轨迹在有限帧内仍可维持连续性,系统不会立即触发计数或状态切换,从而有效避免由短时失检引发的误计数。

(2) 叶片部分出镜。对于叶片仅部分出现在视场中的情况,ROST 通过引入 ROI 边界穿越判据,并结合旋转方向一致性约束,仅当叶片

边缘中心点完整且单向地穿越 ROI 边界时才触发一次有效计数。该机制能够有效过滤由局部出镜或边缘短暂进入 ROI 区域所造成的伪触发问题。

(3) 多个叶片同时或连续穿越 ROI。在多个叶片同时或连续穿越 ROI 边界的复杂场景下,ROST 依托多目标跟踪所生成独立轨迹,并在轨迹层面结合旋转状态机进行判别。由于每一条物理叶片轨迹均维护独立的旋转方向与计数标记,即使多叶片在空间上存在交叠或时间上高度接近,系统仍可避免不同叶片之间的计数混淆或重复计数。

在试验平台采集的视频序列中,上述复杂工况均有出现。试验过程中未观察到因短时遮挡、部分出镜或多叶片同时穿越 ROI 边界而引发的累计计数漂移现象。结合前述定量试验结果可以看出,ROST 方法在真实孔探检测条件下具备良好的工程鲁棒性,能够满足航空发动机叶片计数任务对稳定性与可靠性的要求。后续工作中将进一步结合真实发动机孔探数据,对极端遮挡与高密度叶片场景进行系统化评估。

### 3 结论

(1) 本文提出的 DLE-DETR 模型在旋转叶片边缘检测任务中表现

出色。试验结果显示,相较于主流的 YOLOv11-OBB 模型,该模型核心指标提升:  $AP_{50}$  指标提升 2.08 个百分点,增强了对叶片边缘目标的基础识别准确性;  $AP_{50-95}$  指标提升 2.42 个百分点,证明其在不同精度要求下均具备稳定的检测鲁棒性。同时, DLE-DETR 模型实现了计算效率的优化,计算复杂度较 YOLOv11-OBB 降低 37.87%,为模型在工业实时检测场景及资源受限平台的部署奠定了基础。

(2) 基于 ROST 模型实现的航空发动机叶片计数任务取得优异效果,其计数准确率达到 98.6%,相较于现有主流计数算法提升幅度达 24.49%,优于现有方法,充分验证了 ROST 模型在航空发动机叶片计数场景中的有效性与优越性。

### 参考文献

- [1] 汪文虎,张西涛,杨丽娜,等. 航空发动机涡轮叶片精铸模具的现状与发展趋势[J]. 航空制造技术, 2005, 48(6): 26-29.  
WANG Wenhui, ZHANG Xitao, YANG Lina, et al. Present situation and development trend of precision casting mold for aero-engine turbine blades[J]. Aeronautical Manufacturing Technology, 2005, 48(6): 26-29.
- [2] 刘涵,刘勤明,叶春明,等. 基于深度学习和特征凝练的变工况航空发动机轴承智能故障诊断[J]. 计算机应用研究, 2025, 42(11): 3387-3396.  
LIU Han, LIU Qinming, YE Chunming, et al. Intelligent fault diagnosis of aero-engine bearings under variable operating conditions based on deep learning and feature condensation[J]. Application Research of Computers, 2025, 42(11): 3387-3396.
- [3] 曹增义,单继东,王昭阳,等. 面向航空发动机制造的数字孪生应用架构探索与实践[J]. 航空制造技术, 2022, 65(19): 40-49.  
CAO Zengyi, SHAN Jidong, WANG Zhaoyang, et al. Exploration and practice of digital twin architecture for aero-engine manufacturing[J]. Aeronautical Manufacturing Technology, 2022, 65(19): 40-49.
- [4] 陶飞,刘蔚然,张萌,等. 数字孪生五维模型及十大领域应用[J]. 计算机集成制造

系统, 2019, 25(1): 1–18.

TAO Fei, LIU Weiran, ZHANG Meng, et al. Five-dimension digital twin model and its ten applications[J]. Computer Integrated Manufacturing Systems, 2019, 25(1): 1–18.

[5] 程宇, 韩伟, 麻林森, 等. 基于深度学习的民航飞机增强现实智能巡检[J]. 航空制造技术, 2025, 68(23/24): 34–41, 49.

CHENG Yu, HAN Wei, MA Linsen, et al. Augmented reality intelligent inspection of civil aviation aircraft based on deep learning[J]. Aeronautical Manufacturing Technology, 2025, 68(23/24): 34–41, 49.

[6] 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.

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.

[7] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//Computer Vision–ECCV 2020. Cham: Springer, 2020: 213–229.

[8] ZHU X Z, SU W J, LU L W, et al. Deformable DETR: Deformable transformers for end-to-end object detection[PP/OL]. (2021–03–18)[2026–06–09]. <https://doi.org/10.48550/arXiv.2010.04159>.

[9] MENG D P, CHEN X K, FAN Z J, et al. Conditional DETR for fast training convergence[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2021: 3631–3640.

[10] LIU F L. DAB-DETR: Dynamic anchor boxes are better queries for DETR[C]//International Conference on Learning Representations (ICLR). Virtual, 2022.

[11] ZHANG H, LI F, LIU S L, et al. DINO: DETR with improved DeNoising anchor boxes for end-to-end object detection[PP/OL]. (2022–07–11)[2026–06–09]. <https://doi.org/10.48550/arXiv.2203.03605>.

[12] LI F, ZHANG H, LIU S L, et al. DN-DETR: Accelerate DETR training by introducing query DeNoising[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(4): 2239–2251.

[13] HE L, ZHOU Q Y, LI X T, et al. End-to-end video object detection with spatial-temporal transformers[C]//Proceedings of

the 29th ACM International Conference on Multimedia. Virtual Event China. New York: ACM, 2021: 1507–1516.

[14] CHOI H K, PAIK C K, KO H W, et al. Recurrent DETR: Transformer-based object detection for crowded scenes[J]. IEEE Access, 2023, 11: 78623–78643.

[15] YE T, QIN W Y, LI Y W, et al. Dense and small object detection in UAV-vision based on a global-local feature enhanced network[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2515513.

[16] CHEN Y H, LI W, SAKARIDIS C, et al. Domain adaptive faster R-CNN for object detection in the wild[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 3339–3348.

[17] DANG M, LIU G, KONG A W, et al. RO<sub>2</sub>-DETR: Rotation-equivariant oriented object detection transformer with 1D rotated convolution kernel[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2025, 228: 166–178.

[18] DAI L H, LIU H, TANG H, et al. AO<sub>2</sub>-DETR: Arbitrary-oriented object detection transformer[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(5): 2342–2356.

[19] XU Y C, FU M T, WANG Q M, et al. Gliding vertex on the horizontal bounding box for multi-oriented object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(4): 1452–1459.

[20] YAO Y Q, CHENG G, WANG G X, et al. On improving bounding box representations for oriented object detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5600111.

[21] ZAND M, ETEMAD A, GREENSPAN M. Oriented bounding boxes for small and freely rotated objects[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 4701715.

[22] DANG M, LIU G, LI H, et al. PRA-det: Anchor-free oriented object detection with polar radius representation[J]. IEEE Transactions on Multimedia, 2025, 27: 145–157.

[23] YANG X, YAN J C, MING Q, et al. Rethinking rotated object detection with Gaussian Wasserstein distance loss[C]//Proceedings of the 38th International Conference

on Machine Learning. San Jose, 2021.

[24] NIE G T, HUANG H. Multi-oriented object detection in aerial images with double horizontal rectangles[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(4): 4932–4944.

[25] HE J Z, ZHANG S L, YANG M, et al. Bi-directional cascade network for perceptual edge detection[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2019: 3823–3832.

[26] ZHANG Z G, LIN C, QIAO Y K, et al. Edge detection networks inspired by neural mechanisms of selective attention in biological visual cortex[J]. Frontiers in Neuroscience, 2022, 16: 1073484.

[27] 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). Piscataway, NJ: IEEE, 2020: 11531–11539.

[28] LIU H J, YANG Z Y, ZHANG H F, et al. Edge detection with attention: From global view to local focus[J]. Pattern Recognition Letters, 2022, 154: 99–109.

[29] CUI S G, CHEN X, MOU Z P, et al. Complex text detection algorithm based on edge attention mechanism[J]. Journal of Circuits, Systems and Computers, 2024, 33(3): 2450042.

[30] SHI C Y, WANG C Y, ZHOU X, et al. DAE-net: Dual attention mechanism and edge supervision network for image manipulation detection and localization[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5030317.

[31] DU Y H, ZHAO Z C, SONG Y, et al. StrongSORT: Make DeepSORT great again[J]. IEEE Transactions on Multimedia, 2023, 25: 8725–8737.

[32] WANG Y Y, MARIANO V Y. A multi object tracking framework based on YOLOv8s and bytetrack algorithm[J]. IEEE Access, 2024, 12: 120711–120719.

[33] LIAO P, YANG F, WU D, et al. Enhanced multi-object tracking: Inferring motion states of tracked objects[J]. ACM Transactions on Multimedia Computing, Communications, and Applications, 2025, 21(1): 1–25.

[34] VAQUERO L, XU Y H, ALAMEDA-PINEDA X, et al. Lost and Found:

Overcoming detector failures in Online multi-object tracking[C]//Computer Vision—ECCV 2024. Cham: Springer, 2025: 448–466.

[35] NIE Z H, XUE L Y, FANG Z Y, et al. M3OT: A multi-drone multi-modality dataset for multi-object tracking[J]. Scientific Data,

2025, 12: 1927.

[36] WONG C Y, SESHADRI P, PARKS G T. Automatic borescope damage assessments for gas turbine blades *via* deep learning[C]//AIAA Scitech 2021 Forum. Reston, Virginia: AIAA, 2021: 1488.

[37] WRANGEL M V, KÄSTNER M, REITHMEIER E. Robust counting of engine blades in aircraft engine video endoscopy[C]//Dimensional Optical Metrology and Inspection for Practical Applications XI. San Diego: SPIE, 2022: 83–90.

## Aero-Engine Blade Counting Method Based on Direction-Aware Edge Modeling

ZHANG Yinlong<sup>1,2,3</sup>, WU Zhen<sup>1,3</sup>, XU Yongli<sup>3</sup>, ZHANG Sichao<sup>2,3</sup>, SONG Chunhe<sup>2,3</sup>,  
WANG Chu<sup>2,3</sup>, SUN Yong<sup>2,3</sup>, SUN Yiming<sup>2,3</sup>

(1. Shenyang University of Technology, Shenyang 110870, China;

2. Institute of AI for Industries, Chinese Academy of Sciences, Nanjing 211135, China;

3. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China)

**[ABSTRACT]** As aero-engine blades are core components, inspecting and counting them are critical procedures in routine maintenance. Industrial endoscopic inspection has become the mainstream method for these tasks due to its high efficiency and minimal invasiveness. However, factors such as blade reflectivity, morphological variations, and complex rotational postures often cause existing visual algorithms to fail in edge extraction and orientation estimation. To address these challenges, this paper proposes a rotating blade detection algorithm, DLE–DETR, driven by direction-aware edge modeling (DEM). By integrating the DEM module into the DETRv2 framework, the proposed algorithm explicitly models blade edge directions, achieving fine-grained perception and accurate representation of rotating edges, thereby significantly enhancing detection accuracy and edge recognition capabilities. Furthermore, to mitigate missed or erroneous counts caused by complex blade motions, an aero-engine blade counting method based on rotational angle time-series modeling (ROST) is introduced. By integrating the trends of rotational angle changes, trajectory continuity, and Region of Interest (ROI) boundary crossing relationships, this method ensures robust and accurate counting. Extensive experiments conducted on a developed aero-engine blade counting platform demonstrate the effectiveness of the proposed approach. The results indicate that the DLE–DETR model achieves a detection accuracy ( $AP_{50}$ ) of 93.8%, outperforming comparable advanced models by 2.08 percentage points. Moreover, the average counting accuracy reaches 98.6%, representing a 24.49% improvement over that of existing algorithms and fully meeting the practical requirements for aero-engine blade counting.

**Keywords:** Aero-engine blade; Rotating blade inspection; Direction-aware; Blade edge; Rotation angle time-series modeling (ROST)

(责编 阳光)