



基于序列化匹配和历史经验迁移的航空发动机缺陷检测方法

吴佩树^{1,2}, 曾念寅¹, 刘钦源², 陈亮¹, 程泽睿¹, 腾达^{1*}

1. 厦门大学航空航天学院, 厦门 361102

2. 同济大学计算机科学与技术学院, 上海 201804

* E-mail: tengda@xmu.edu.cn

收稿日期: 2025-11-23; 接受日期: 2026-01-29; 网络版发表日期: 2026-03-04

福建省杰出青年科学基金(编号: 2023J06010)、中国航发集团自主创新基金(编号: ZZCX-2023-005)、国家重点研发计划(编号: 2024YFC3407000)、中央高校基本科研业务费专项资金(编号: 20720250125)和厦门大学大学生创新训练计划项目(编号: APSR-202517)资助项目

摘要 针对孔探成像中强反光、油污等干扰与弱对比度微小细长缺陷, 以及探头微扰引发的跨层重匹配和收敛不稳定问题, 本文提出一种基于序列化匹配与历史经验迁移的端到端航空发动机缺陷检测框架。基于Align-DETR, 设计了从特征侧、匹配侧到优化侧的三项互补机制, 包括设计自适应历史信息引导的交叉注意力机制, 稳定跨尺度信息汇聚与目标对准; 提出自适应上下文引导的偏置方法并在指派阶段加入滞回奖励, 提高改配门槛并抑制重匹配; 构建匹配一致性损失并以末层分布为锚进行深度加权对齐, 以约束层间一致性。上述方法将隐性的层间依赖关系显式化和可微化, 降低指派抖动与梯度冲突, 促进边界框单调细化与稳定收敛。在多个航空发动机缺陷数据集上的实验表明, 本方法在检测精度和缺陷召回等能力上显著优于强基线与主流对比模型。如在AE-SD6上, 本方法相比Align-DETR的mAP@50:95提升5%, 并验证了本方法在训练早期就显著提高了匹配一致性, 达到等损失阈值的迭代次数最高减少59%, 并收敛至更低且更平稳的损失平台。结果验证了所提方法在复杂场景下的鲁棒性与泛化性, 为航空发动机缺陷智能检测提供了可扩展的工程化方案。

关键词 航空发动机, 缺陷视觉检测, 序列化匹配, 历史先验引导, 收敛稳定性

1 引言

航空发动机作为飞行器的核心动力装置, 其涡轮、燃烧室、压气机等关键部件长期服役于高温高压、高速旋转及颗粒冲蚀等极端工况, 易产生各类缺陷, 因此对其进行精准高效的无损检测和健康管理具

有重要意义^[1]。然而, 现行以孔探或射线成像为主的视觉检测流程仍高度依赖人工判读, 流程繁琐、效率偏低且主观性强、一致性不足, 难以支撑复杂构型与多工况场景下的快速及准确运维需求。为突破上述瓶颈, 近年来深度学习驱动的端到端目标检测方法在工业质检应用中受到广泛关注^[2]。该类方法通过联合学习缺

引用格式: 吴佩树, 曾念寅, 刘钦源, 等. 基于序列化匹配和历史经验迁移的航空发动机缺陷检测方法. 中国科学: 技术科学, 2026, 56: 772–789
Wu P S, Zeng N Y, Liu Q Y, et al. An aero-engine defect detection method via sequential matching and historical experience-guided transfer (in Chinese). Sci Sin Tech, 2026, 56: 772–789, doi: [10.1360/SST-2025-0371](https://doi.org/10.1360/SST-2025-0371)

陷类别、位置与尺度等空间几何参数,可在复杂背景中实现自动化的缺陷识别和定位.检测器按照输出建模与去重机制可划分为基于非极大值抑制的密集预测范式,如一阶段的YOLO系列算法^[3~5]和二阶段的RCNN系列方法^[6,7]等;以及基于查询-匹配的集合预测范式,如DEtection TRansformer(DETR)及其结合动态锚框查询、协同分配、可变形注意力、查询筛选、去噪训练与分类-定位对齐等改进模型^[8~14].

基于上述目标检测范式,面向航空发动机叶片等关键部件缺陷在复杂背景噪声、细长与微小损伤并存以及目标拥挤形变等条件下的检测需求,已有研究主要沿以下几条技术路线展开.一是面向高分辨率与微小缺陷的效率和精度性能平衡,有研究者通过由粗到细的两阶段流程,先在低分辨率上进行候选区域定位,再对高分辨率局部补丁作精细检测与边界修正,以兼顾检出率与计算开销^[15],为利用结构化区域关系提升复杂背景下缺陷定位与识别效果,还有研究者将叶片图像以超像素为基本单元构建图结构,用图神经网络进行特征传播,并结合超像素感知的区域提议生成候选框完成缺陷检测^[16].二是面向弱对比与复杂纹理干扰的表征增强,有研究者通过通道注意力与空间特征融合等机制强化细节表征,提升微缺陷在强纹理背景下的可分性与鲁棒性^[17],同时也有工作从数据增强、特征感知与损失设计等角度改进卷积检测器,以提升整体检测精度与稳定性,但在强干扰与微小目标场景下仍面临挑战^[18].三是面向工程部署的轻量化与应用挑战,有研究者针对实时性与算力受限的矛盾,利用知识图谱驱动的网络结构搜索构建轻量模型,以支持产线级自动化部署^[19].四是面向复杂场景泛化与多模态融合问题,有工作通过全局结构上下文、语义关系等先验提升复杂背景下的感知精度与检测鲁棒性^[20,21],并进一步结合多模态信息以增强对裂纹等特定缺陷的可靠量化能力^[22].

上述工作从分辨率策略、特征表征、模型效率、先验和多模态信息等方面提升航空发动机缺陷检测性能,但大多聚焦于单次预测或特征层面的稳健性增强,对于端到端集合预测检测器在解码过程中可能出现的跨层匹配不一致与由此引发的训练震荡问题,仍缺乏面向指派稳定性与收敛动力学的专门建模与约束.特别是在实际孔探作业下航空发动机缺陷检测存在诸多瓶颈,首先是成像物理约束削弱类间可分性,如高反光

金属内壁易引起过曝与暗噪,鱼眼畸变与浅景深进一步带来几何失真.其次,航空发动机缺陷形态复杂导致定位更敏感,尤其是细长微小缺陷,像素级偏移即可显著降低交并比(intersection over union, IoU).此外,探头位姿与工作距离的微小扰动会引发候选漂移,使标注匹配不稳定,并进一步造成正负样本分配抖动.因此,面向航空发动机缺陷检测的方法亟需同时提升特征稳健性、几何敏感建模能力与跨层稳定分配机制.

通过上述分析可知,通用端到端目标检测器在航空发动机孔探缺陷检测任务中,容易出现匹配震荡与收敛不稳.例如,Align-DETR即便通过特征和查询对齐增强了鲁棒性^[14],但解码器各层仍独立执行匈牙利匹配,会产生跨层重匹配现象,即同一查询在相邻层对应不同标注或从前景转为背景.如图1所示,左侧的轨迹演示了同一查询在相邻层间发生前景、背景或类别切换,右侧置信度热力图则示意了中间层目标与背景置信度的局部反转是直接诱因.跨层重匹配的成因首先源于成本矩阵具有明显的非平稳性,即分类项对强反光与油污等伪前景高度敏感,导致得分波动.其次,回归项对细长微小缺陷的像素级偏移存在放大效应,使几何代价对微小扰动极其敏感.此外,层间分辨率与感受差异也会改变候选排序,从而在相邻层触发配对反转.因此,在一对一约束与近邻多目标条件下,轻微代价波动即可引起监督目标跳变,并造成梯度冲突与收敛震荡.

为解决上述航空发动机缺陷检测中由跨层重匹配引发的梯度冲突与收敛迟滞问题,本文提出序列化匹配与历史经验迁移框架,从特征侧、匹配侧和优化目标侧进行协同设计.从特征建模、指派匹配和优化约束层面建立对应的解决方法:(1)针对成像物理约束导致的伪前景与弱对比使类间可分性下降,在特征侧提出自适应历史引导的交叉注意力(adaptive history-guided cross-attention, AHG-CA),通过历史区域与质量先验引导跨尺度交叉注意力的采样与权重分配,抑制反光或油污等噪声诱发的注意力漂移并增强有效区域聚焦;(2)针对细长或微小等难例缺陷对几何定位极敏感、易在层间产生候选排序反转,在匹配侧构建自适应上下文引导偏置(adaptive context-guided bias, ACGB)方法,在匈牙利代价中注入自适应滞后奖励,提高改配门槛并促成边界框的单调细化;(3)针对探头位姿扰动等不可控因素间接引发的跨层重匹配与训




图 1 (网络版彩图)跨层匹配不一致的三种情形

Figure 1 (Color online) Three situations of inconsistent cross layer matching.

练震荡, 在优化侧设计匹配一致性损失(matching consistency loss, MCL), 以最终层分布为锚对中间层进行深度加权的Kullback-Leibler(KL)散度对齐, 显式约束层间一致性以缓解梯度冲突并稳定收敛. 三者共同将原本隐含的层间依赖显式化、可微化, 实现对复杂航空发动机孔探检测场景下的缺陷可分性、稳定指派和收敛优化能力提升. 本文主要工作和贡献总结如下.

(1) 分析阐释了在航空发动机孔探检测场景中, 反光、油污等伪前景会导致分类代价波动, 细长微小缺陷对像素级位移敏感会放大回归代价, 使得解码器相邻层匹配容易触发跨层改配与前景-背景翻转, 进而造成监督目标跳变、梯度冲突与收敛震荡问题.

(2) 本文工作的核心增量在于, 在序列化解码框架下显式建模跨层历史依赖, 将上一层的可靠预测与指派结果作为先验注入下一层训练流程, 并在特征、匹配和损失层面形成互补约束.

(3) 提出的AHG-CA在特征侧利用历史区域与质量先验引导采样与聚合以稳定目标对准; ACGB在匹配侧为上一层续配边引入自适应滞回奖励以抬升改配门槛; MCL在优化侧以末层分布为锚, 对中间层施加深度加权一致性对齐以统一层间训练信号.

2 基于序列化匹配和历史经验迁移的检测Transformer方法

2.1 总体设计

本节先回顾Align-DETR的关键设计, 再说明本文

的设计动机. 首先, Align-DETR的核心思想是对齐分类与定位质量, 使分类分数能够反映定位精度, 即定位越准分数越高. 为此, 它采用质量感知的软目标训练分类头, 并用同源质量权重统一回归分支的样本重要性, 从而维持两分支一致的优化方向. 如式(1)所示, 质量感知分类损失用来将分类置信度与定位质量对齐, 其中 p_i^l 为第 l 层第 i 个正样本query对其匹配类别的预测概率, γ 为调制因子, 用于抑制易样本、强调难样本, $t_i^l \in [0, 1]$ 为质量感知的“软目标”, 由分类和定位质量共同影响:

$$L_{cls}^l = -t_i^l(1 - p_i^l)^\gamma \log p_i^l - (1 - t_i^l)(p_i^l)^\gamma \log(1 - p_i^l). \quad (1)$$

其次, 为提升中间层监督密度, Align-DETR引入一对多混合匹配, 并将联合质量指标映射为平滑软目标(如式(2)和(3)), 以缓解监督跳变. 通过联合质量指标 q , 对同一真实标注(ground truth, GT)的候选进行排序, 得到名次 r , 再以指数退火将 (q, r) 映射为平滑软目标:

$$q = p^\alpha u^{(1-\alpha)}, \quad (2)$$

$$t_i^l = e^{-\frac{r}{\tau} q}, \quad (3)$$

其中, u 为IoU, τ 是指数退火的衰减系数, α 用于控制分类与定位的权重. 该机制可缓解因层间微小改配引发的监督跳变, 提升训练稳定性.

然而, 由于各层仍独立执行匈牙利匹配, 模型在噪声与几何微扰下依然可能触发跨层重匹配. 因此, 本文在序列化解码框架下显式建模层间依赖, 并从特征、

指派与优化三个层面协同稳定训练过程. 为此, 本研究设计了基于序列化匹配和历史经验迁移的检测Transformer方法, 整体框架如图2所示, 形成特征抽取、层级解码和跨层反馈的方法流程, 并在特征、指派和损失三处分别设计AHG-CA, ACGB与MCL.

首先, 输入的航空发动机孔探检测图像经骨干网络和编码器得到多尺度特征 $\{F\}$, 作为后续解码的语义与几何基础. 其次, 解码器按层数 $l = 1 \rightarrow L$ 递进, 每层用 $\{F\}$ 与查询 Q_{l-1} 产生预测 (p_l, b_l) , 并与标注作匈牙利匹配得到配 π_l . 进一步地, 将上一层的匹配与预测 $[\pi_p(p_l, b_l)]$ 作为先验输入下一层.

具体地, 特征侧的AHG-CA利用上一层预测的几何与质量先验, 动态引导本层交叉注意力的采样与聚合, 稳定特征对准, 抑制噪声干扰. 匹配侧的ACGB在匈牙利匹配代价中为上一层的成功配对引入自适应滞后奖励, 抬高改配门槛, 促进边界框单调细化, 减少ID切换(即降低同一query在相邻层匹配到不同GT的概率). 优化侧的MCL以解码器最终层输出为锚点, 通过深度加权的KL散度损失约束中间层预测分布, 显式强

制层间一致性, 缓解梯度冲突.

2.2 自适应历史信息引导的交叉注意力

在序列化解码中提升跨尺度注意力的聚焦性与稳定性, 对高IoU敏感的航空发动机叶片上的细长或微小缺陷十分重要. 所设计的AHG-CA由历史匹配区域加权采样(history-weighted sampling, HWS)、质量引导注意力偏置(quality-guided attention bias, QGAB)与上下文相关的历史查询融合(context-aware history query fusion, CHQF)三个模块组成. 其核心思想是将上一层或历史时刻已确证的几何和语义线索选择性注入当前层的可变形交叉注意力, 抑制表征漂移并强化目标区域聚焦.

本文所述“历史”指解码器跨层历史, 即在第 l 层解码时, 使用上一层 $l-1$ 的输出作为先验信号. 具体而言, 对于第 l 层的第 i 个查询 $q^i \in \mathbf{R}^d$, 其历史信息包括历史匹配区域(即上一层预测框 b^{l-1} 映射到各尺度特征图上得到的区域 $R_s(b^{l-1})$, 用于指示“更可能包含目标的空间窗口”)、历史质量先验(由上一层分类置信度与定位质量组合得到的匹配质量 Q_i^{prev} , 用于衡量“该历史区




图2 (网络版彩图)所提出的基于序列化匹配和历史经验迁移的DETR方法

Figure 2 (Color online) The proposed DETR method based on sequential matching and historical experience transfer.

域或语义是否可靠”)以及历史查询集合(由该查询在前若干解码层的查询表征构成的集合 $Q^{\text{hist}} = \{q^l\}_{l=1}^R$, 用于提供更稳定的语义记忆). AHG-CA通过门控系数 h_i , q_i , $G_i \in [0, 1]$ 将上述历史信息注入当前层交叉注意力:

$$h_i = \sigma[F_h(Q_i^{\text{prev}})], \quad (4)$$

$$q_i = \sigma[F_q(Q_i^{\text{prev}})], \quad (5)$$

$$G_i = \sigma[F_g(Q_i^{\text{prev}}, q_i)], \quad (6)$$

其中, Q_i^{prev} 由上一层对同一查询的分类置信与定位质量构成, 用于统一调节采样、注意力偏置与语义融合这三类历史注入强度. 当 Q_i^{prev} 较低或上一层未形成可靠配对时, 门控趋近于0, 使模块退化为标准交叉注意力, 从而避免错误历史带来的训练不稳定.

如图3所示, HWS用于提升历史区域的采样密度, QGAB放大其注意力占比, CHQF在查询语义上施加门控式历史迁移. 具体地, HWS在可变形注意力的采样logit上叠加历史区域偏置, 提高 $R_s(b^{l-1})$ 的内候选的被采样概率:

$$s_{s,k} \leftarrow s_{s,k}^{(0)} + \lambda_h h_i \mathbf{1}[x_{s,k} \in R_s(b^{l-1})], \quad (7)$$

其中, $s_{s,k}^{(0)}$ 和 $s_{s,k}$ 分别为原始和加入历史偏置后的采样logit, $\lambda_h > 0$ 控制采样侧的历史注入强度, 用于提升历史窗口内采样密度.

在连续采样形式下, 可将高斯采样中心和方差向

历史框中心收缩:

$$\mu' = (1 - \eta_h h_i) \mu + \eta_h h_i c(b^{l-1}), \quad \sigma' = (1 - \eta_h h_i) \sigma, \quad (8)$$

其中, μ, σ 为高斯采样均值与标准差, 而 μ', σ' 为加历史约束后的更新值; $c(b^{l-1})$ 为上一层预测框的中心点, η_h 为连续采样中向历史框中心收缩的权重; 约束采样均值和方差用于提升对齐能力, 但过大可能降低纠偏能力.

从图3(a)可直观看出, HWS以上一层预测框映射得到的历史匹配区域 $R_s(b^{l-1})$ 作为空间先验, 从采样源头提升对历史可靠区域的覆盖. 具体地, 对落入该区域的候选采样点, 在采样logit上叠加偏置 $\lambda_h h_i$ (或在连续采样中将高斯采样中心向历史框中心收缩并减小方差), 从而提高其被抽中的概率. 其中, h_i 由上一层匹配质量 Q_i^{prev} 门控得到, 质量越高偏置越强. 由此可知, HWS的作用是能优先在历史可信窗口内取样, 稳定跨层注意力, 减少表征漂移与重匹配.

QGAB在注意力打分阶段, 对位于历史匹配区域 $R_s(b^{l-1})$ 内的键向量引入与质量相关的加性偏置, 其幅度由 q_i 自适应调节, 从而提升可信目标区域的注意力占比. 具体地, 查询 q^l 对采样位置 $x_{s,k}$ 的匹配分数 $L_{i,s,k}$ 为

$$L_{i,s,k} = \frac{q^l W_Q [K_s(x_{s,k}) W_K]^T}{\sqrt{d_k}} + \beta q_i \mathbf{1}[x_{s,k} \in R_s(b^{l-1})], \quad (9)$$

其中, W_Q, W_K 为查询和键线性投影, d_k 为缩放常数,




图3 (网络版彩图) HWS, QGAB和CHQF三个模块作用机制示意图. (a) HWS; (b) QGAB; (c) CHQF

Figure 3 (Color online) The schematic diagram of HWS, QGAB, and CHQF modules. (a) HWS; (b) QGAB; (c) CHQF.

$K_s(x_{s,k})$ 为尺度 s 上位置 $x_{s,k}$ 的键向量, β_q 用于提升历史区域注意力占比. 从图3(b)可直观看出, 历史区域内的键的logit被加上质量门控偏置(橙色加粗箭头), 使注意力更集中于历史可信目标方向, 抑制噪声导致的注意力漂移并减少跨层重匹配.

CHQF旨在利用历史查询集合 $Q^{\text{hist}} = \{q^r\}_{r=1}^R$ 提供语义记忆, 先对历史查询进行上下文相关的加权聚合形成历史语义 $\bar{q}$, 再由门控系数 G 决定注入强度, 以实现语义层面的稳定迁移. 具体地, CHQF先对 $\{q^r\}_{r=1}^R$ 进行自适应加权聚合, 并以门控残差注入当前查询. $\bar{q}$ 及其注意力权重 α_r 的计算方式为

$$\bar{q} = \sum_{r=1}^R \alpha_r q^r, \alpha_r = \text{softmax}_r \{g_s([q^l q^r])\}. \quad (10)$$

随后通过融合映射网络 Φ 生成残差, 并由门控 G 控制注入, 得到更新查询:

$$\tilde{q}^l \leftarrow q^l + G\Phi([q^l \bar{q}]). \quad (11)$$

当历史先验不可靠时, $G \rightarrow 0$, 融合近似退化为恒等映射, 有利于训练稳定. 如图3(c)所示, CHQF从上一层选取一组历史查询(蓝色圆圈), 与当前查询进行上下文打分得到权重 α_r , 聚合形成历史语义 $\bar{q}$, 再经门控注入得到更新查询 $\tilde{q}^l$.

2.3 自适应上下文引导的偏置方法

为刻画跨层匹配不一致, 将第 l 层的匹配建模为线性求和指派. 设有 Q 个查询和 G 个GT, 指派矩阵 $X \in \{0, 1\}^{Q \times G}$ 满足行或列至多为1, 目标为

$$\min_{X \in \{0, 1\}^{Q \times G}} \langle C^l, X \rangle, \text{ s.t. } X\mathbf{1} \leq \mathbf{1}, \mathbf{1}^T X \leq \mathbf{1}^T, \quad (12)$$

其中, C^l 为当前层的分类和回归加权代价; 由于各层独立求解, 相邻两层匈牙利匹配对同一查询 i 的指派易出现不一致: $\pi^{l-1}(i) \neq \pi^l(i)$, 进而引发梯度冲突与非单调的边界框细化.

ACGB对与上一层保持同一配对 (i, j) 的边给予滞后偏置 B^l , 等价于在代价矩阵中做减法:

$$\tilde{C}_{ij}^l \leftarrow C_{ij}^l - B_{ij}^l \cdot \mathbf{1}[\pi^{l-1}(i) = j]. \quad (13)$$

记 $H_{ij}^{l-1} = \mathbf{1}[\pi^{l-1}(i) = j]$, 则优化目标变为

$$\arg\max_X \left\{ \langle B^l \odot H^{l-1}, X \rangle - \langle C^l, X \rangle \right\}. \quad (14)$$

其表示延续上层配对可获得奖励, 优先被保留. 从概率视角分析, 将代价视为能量, 则

$$P_{ij}^l \propto e^{-\frac{C_{ij}^l - B_{ij}^l}{T}} = e^{\frac{B_{ij}^l}{T}} e^{-\frac{C_{ij}^l}{T}}, \quad (15)$$

其中 $T > 0$ 为温度系数, 偏置项 B/T 在对数域充当先验, 放大续配概率.

为实现自适应滞后阈值, 将偏置 B_{ij}^l 分解为上层质量先验 Q_{prev} 、深度因子 $D(l)$ 和本层自信门控 $S_{i \rightarrow j}^l$ 因子乘积, $\lambda_{\text{base}} > 0$ 为滞后奖励基准尺度, 用于与代价量纲对齐并整体调节续配奖励强度:

$$B_{ij}^l = \lambda_{\text{base}} Q_{\text{prev}}(i, j) D(l) S_{i \rightarrow j}^l, \quad (16)$$

其中 $S_{i \rightarrow j}^l \in [0, 1]$ 用来调节偏置强度, 以避免在本层证据不足时过度强化续配. 当本层分类与定位几何判别一致时, $S_{i \rightarrow j}^l$ 较大, 续配偏置被放大以抬升改配门槛并抑制后期重匹配. 反之, $S_{i \rightarrow j}^l$ 较小, 偏置自动衰减以避免错误锁定并保留必要的改配自由度. Q_{prev} 随上一层分类置信度 $p_{i \rightarrow j}^{l-1}$ 与定位吻合度 $\text{IoU}^{l-1}(b_i, g_j)$ 单调增大, α 用于控制历史质量先验中各任务的占比:

$$Q_{\text{prev}}(i, j) = (p_{i \rightarrow j}^{l-1})^\alpha [\text{IoU}^{l-1}(b_i, g_j)]^{1-\alpha}, \alpha \in [0, 1]. \quad (17)$$

$D(l)$ 随着层数 l 单调递增, 设计动机是浅层预测通常仍处于粗定位阶段, 候选与GT的几何误差较大, 允许更自由的改配有辅助完成全局纠偏, 因此偏置应较小以避免过早锁定. 而深层预测已接近收敛, 边界框主要进行细粒度微调, 此时层间重匹配往往由噪声或微小代价波动触发, 带来的收益有限, 却会引入监督目标跳变与梯度冲突. 其中, L_{tot} 为解码器总层数, β 用于控制随深度增长的陡峭度, 其值较大意味着更强的后层续配偏置, 以抑制后期改配:

$$D(l) = \left(\frac{l}{L_{\text{tot}}} \right)^\beta, \beta > 0. \quad (18)$$

如图4所示, ACGB将上一层配对作为先验, 在当前层对续配边施加偏置 B , 等价于为续配提供一项先验奖励, 从而提高改配门槛. 记 ΔC 为改配相对续配的




图 4 (网络版彩图) ACGB的决策面与参数敏感性

Figure 4 (Color online) Decision surface and parameter sensitivity of ACGB.

代价优势, 续配概率记为 P 。在左图的二维决策面中, $\Delta C = B$ 构成临界边界(对应 $P = 0.5$), 当 $\Delta C < B$ 时处于续配主导区($P > 0.5$), 当 $\Delta C \geq B$ 时进入改配主导区($P \leq 0.5$)。因此, 在固定 ΔC 下增大 B 会扩大续配区域; 而在固定 B 下增大 ΔC 则更易触发改配。右侧的参数敏感性进一步验证该规律, 各曲线随 ΔC 单调下降, 并在 $\Delta C = B$ 时穿越0.5; 增大 B 会使整条曲线整体右移, 意味着只有当改配的代价优势超过更高阈值时才会发生改配。综合来看, B 可视为可调的滞回阈值或先验奖励, 用于稳定跨层匹配。

2.4 匹配一致性损失

在AHG-CA稳定跨尺度注意力, 以及ACGB对指派过程施加先验约束的基础上, MCL进一步在优化阶段作为后验一致性正则, 约束各解码层对同一查询的匹配分布与最终层决策对齐, 以抑制跨层ID切换并促成单调细化。解码器总层数为 L_{tot} , 最终参照层 $l^* = L_{\text{tot}} - 1$ 。对于第 l 层的第 i 个查询 q_i , 其在 $K = G + 1$ 个候选目标(G 个GT和背景类)的匹配倾向记作概率分布 $M_l(p_i) \in \Delta^K$, 可由两种等价视角构造:

$$M_l(q_i)[j] = \frac{\exp\left(-\frac{C_{i,j}^l}{T_{\text{mcl}}}\right)}{\sum_{k=0}^{K-1} \exp\left(-\frac{C_{i,k}^l}{T_{\text{mcl}}}\right)}, \quad (19)$$

$j = 0, \dots, K-1$ (质量视角),

$$M_l(p_i) = \text{softmax}\left(\frac{z_{i,0:K-1}^l}{T_{\text{mcl}}}\right) \quad (\text{成本视角}), \quad (20)$$

其中, $C_{i,j}^l$ 为该层配对代价, $z_{i,j}^l$ 则表示该层对于 K 个类别的输出得分或对数几率; $T_{\text{mcl}} > 0$ 为温度系数, 用于软化匹配分布的熵水平, 影响KL对齐的梯度尺度。

MCL的目标分布被设定为最终层经过平滑处理且停止梯度的分布:

$$\tilde{M}_*(p_i) = (1 - \varepsilon)M_{l^*}(p_i) + \varepsilon \frac{1}{K}. \quad (21)$$

为抑制对数为零与过尖锐目标引发的梯度爆炸, 引入均匀分布为 $1/K$ 的平滑系数 $\varepsilon > 0$, 用于缓解过尖分布导致的梯度不稳定; 同时对 $\tilde{M}_*$ 施加梯度停止策略使其在反向传播中为常量, 因此MCL仅单向地将各前置层分布 M_l 拉向该固定参照 $\tilde{M}_*$ 。此外, 各层损失的权重 w_l 采用了深度加权策略, 而 γ 更大时, 更强调靠后层的一致性牵引:

$$w_l = \left(\frac{l+1}{L_{\text{tot}}}\right)^\gamma, \quad \gamma > 0, \quad (22)$$

$$L_{\text{MCL}} = \frac{1}{Z} \sum_{l=0}^{L_{\text{tot}}-2} \sum_{i=1}^{N_{\text{query}}} w_l D_{\text{KL}}\{M_l(p_i) \parallel \text{sg}[\tilde{M}_*(p_i)]\}, \quad (23)$$

其中 Z 为归一化因子, $D_{\text{KL}}(\cdot)$ 表示KL散度。

L_{MCL} 的梯度作用是将各中间层分布 M_l 拉向目标分布 $\tilde{M}_*$ 。当最终层偏向目标 g_j 时, 前置层在 j 维增权、

其余维度降权, 进而提升跨层指派一致性并抑制ID切换。

如图5所示, 将各层匹配分布 M_l 视为概率单纯形上的点, 并以 $D_{KL}(M_l|M^*)$ 的等值线刻画其到最终参照分布 M^* 的偏离程度。首先, 折线 $L0 \rightarrow L4 \rightarrow L^*$ 表示在MCL作用下的跨层演化轨迹。各步沿 $-\nabla D_{KL}$ 的最陡下降方向更新, 使 M_l 逐层逼近 M^* 。其次, 箭头长度随局部散度增大及层权重 w_l 提升而增大, 反映偏离越大或层越深, 牵引越强的规律。此外, 概率重分配显示目标类概率随层数上升, 而其他类与背景概率相应下降。因此, MCL通过深度加权的KL对齐约束中间层分布向最终层决策收敛, 进而提升跨层指派一致性和抑制ID切换, 并促进边界框单调细化与稳定收敛。为量化所提出跨层一致性约束在指派稳定性层面的效果, 本文在3.4节引入匹配一致性指标, 用于统计同一GT在各解码层与最终层匹配结果保持一致的比例。其有助于刻画跨层重匹配或ID切换频率, 并与后续收敛性分析形成对应关系。

特别地, 面向弱对比、小尺度与细长航空发动机部件缺陷等高IoU敏感场景, 如算法1所示逐层序列化解码中各机制形成递进互补关系。每层先利用上一层输出构建历史先验, 并通过AHG-CA稳定跨尺度注意力与目标对准。随后通过ACGB在匈牙利指派中注入滞后偏置抬升改配门槛, 抑制跨层ID切换并提升高阈值定位稳定性。最后以末层分布为锚施加深度加权MCL的KL对齐, 统一层间训练信号, 缓解梯度冲突, 促进边界框单调细化与稳定收敛。

3 实验结果与分析

该部分在航空发动机缺陷检测任务的多数据集与多场景下评估所提出方法的有效性与泛化性, 并给出评测设定和结果讨论。

3.1 数据集与实验设置

为评估所提出的基于序列化匹配与历史经验迁移的航空发动机缺陷检测方法的性能, 主要在公共的AE-SD4(aero-engine surface defect dataset with 4




图5 (网络版彩图) MCL的跨层匹配分布的一致性约束示意图

Figure 5 (Color online) The schematic diagram of consistency constraint for cross layer matching distribution of MCL.

classes)¹⁾, 以及两个自建数据集AE-SD6与AE-SD5孔探数据集上进行了测试验证^[23]。三者用于检测的模型性能各有侧重。AE-SD4以浅表纹理异常为主(如细划痕、斑点), 适用于检验弱对比与小目标场景的鲁棒性。AE-SD6更侧重结构或几何损伤(如裂纹、材料缺失、过热变形), 适用于评估复杂形态建模能力。AE-SD5混合表面与结构缺陷, 用于大规模、类不均衡与混合场景的综合评测。如表1所示, 训练与测试集的划分策略遵循小数据更偏训练、大数据兼顾验证。其中AE-SD4/6分别采用8:2与9:1, 以保障稀有类别的有效学习; AE-SD5采用8:2, 以保证充足训练样本与可靠的泛化评测。

所有实验均基于MMDetection框架实现^[24], 训练硬件为NVIDIA RTX 4070 Ti SUPER(CUDA 11.8), 优化器使用AdamW, 初始学习率设定为 1×10^{-4} , 采用step学习率衰减, 在预设里程碑处按0.1比例下降, 以满足前期快速收敛, 后期稳健微调的需求。此外, 检测评估利用平均精度均值(mean average precision, mAP)等指标, 在不同IoU下计算各类AP, 即精确率-召回率(precision-recall, PR)曲线并作宏平均。

1) <https://www.youtube.com/rviltremotevisualinspect2187/videos>.

算法1: 基于序列化匹配与历史经验迁移的逐层解码与训练流程

Input 多尺度特征 F , 初始查询 Q^0 , 标注集合 $G = \{g_j\}_{j=1}^{N_{gr}}$, 解码器层数 L

- 1 初始化: 设上一层匹配 $\pi^0 = \emptyset$, 上一层预测 $(p^0, b^0) = \emptyset$
- 2 **for** $l = 1, 2, \dots, L$ **do**(逐层解码)
- 3 构建历史先验(来自第 $l-1$ 层)
- 4 若 $l > 1$, 根据上一层预测框 b^{l-1} 在各尺度特征上得到历史区域 $R_s(b^{l-1})$
- 5 由上一层分类置信与定位质量组合得到历史质量先验 Q_{prev}
- 6 汇集先前层查询得到历史查询集合 Q_{hist}
- 7 特征侧: 调用AHG-CA(HWS+QGAB+CHQF)
- 8 利用 Q_{prev} 计算门控系数 (h_i, q_i, G_i)
- 9 HWS: 利用式(7)和(8)提升 $R_s(b^{l-1})$ 内的采样密度
- 10 QGAB: 基于式(9)提高历史区域内键的注意力权重
- 11 CHQF: 基于式(10)和(11)将 Q_{hist} 聚合门控注入查询
- 12 由解码器第 l 层输出当前层分类与回归预测 (p^l, b^l)
- 13 匹配侧: 通过ACGB求解指派
- 14 计算基础代价矩阵 C^l (分类项+回归项)
- 15 若 $l > 1$, 根据式(16)~(18), 由 Q_{prev} 、深度因子 $D(l)$ 与本层自信门控 $S_{i \rightarrow j}^l$ 构造滞回偏置 B^l
- 16 由式(13)对上一层“续配边”进行代价修正
- 17 用匈牙利算法在 $\tilde{C}_{i,j}^l$ 上求解得到匹配 π^l
- 18 缓存用于一致性约束的信息, 根据式(19)和(20), 由代价或logits得到该层匹配分布 M_l , 并保存
- 19 计算优化侧一致性MCL(跨层后验正则)
- 20 以最终参照层 l^* 的分布构造目标分布 $\tilde{M}_*$, 并作平滑处理且停止梯度(对应式(21))
- 21 由式(23)对所有中间层计算深度加权KL对齐和 L_{MCL}
- 22 输出总损失

Return 总损失 L_{total} (训练)或最终层预测结果(推理)

3.2 航空发动机缺陷目标检测对比实验

为保证可比性, 所有方法在统一数据划分、标注版本、增强策略与推理规程下评测, 初始化采用相应的预训练权重. 对比方法涵盖单阶段、双阶段与Transformer系列, 其中Align-DETR为对比基线. 图表中给出的数值均为百分数.

表2给出了各方法在纹理型浅表异常AE-SD4数据集上的测试结果, 本方法在Precision, Recall, F1上实现协同提升, 分别为93.5%、81.4%、87.0%, 定位指标mAP@50/50:95为85.5%/40.2%, 较Align-DETR基线分别提升2.9%/3.0%. 同时在保持精确率的前提下, 召回

率提升1.3%. 这表明在弱对比与伪纹理干扰下, 本方法有效降低了航空发动机缺陷的漏检率. 性能提升与历史先验的稳定聚焦机制相吻合, 说明注意力分配更集中于有效区域, 并促进缺陷定位的可靠性稳定提升.

表3展现了在AE-SD6上的结构或几何性损伤为主的测试结果, 本方法在各个指标上均取得最优结果. 对比RT-DETR, mAP@50:95和mAP@50分别提升0.9%和2.7%, 表明在更严格IoU下的定位提升更显著. 相较强基线Align-DETR, 在mAP@50:95, mAP@50, F1指标上分别提升5.0%、3.8%、2.2%, 进一步说明跨层匹配与收敛稳定性显著改善. 这与ACGB抑制跨层重匹配及

表 1 所用的航空发动机缺陷检测数据集信息

Table 1 Information on the aero-engine defect detection datasets

数据集	样本数	类别数	划分	任务侧重	代表类别
AE-SD4	291	4	8:2	弱对比、伪纹理干扰小尺度为主, 细小纹理异常	<i>crease, damage, dot, scratch</i>
AE-SD6	285	6	9:1	几何形变、边界敏感, 存在细长裂纹、缺口等复杂缺陷	<i>crack, curl, dent, material_miss, nick, overheated</i>
AE-SD5	3258	5	8:2	较大规模、多类别混合、类不平衡且多尺度混合	<i>burned, broken, crack, dent, nick</i>

表 2 在数据集AE-SD4上各方法性能对比

Table 2 Performance comparison of various methods on AE-SD4 dataset

对比方法	Precision	Recall	F1-score	mAP@50	mAP@50:95
YOLOv5 ^[3]	89.5	59.6	71.6	69.2	35.7
YOLOv8 ^[4]	88.9	69.1	77.8	74.6	36.3
YOLOv11 ^[5]	88.7	62.4	73.3	79.3	36.1
RetinaNet ^[6]	66.3	74.9	70.4	78.5	39.5
TOOD ^[25]	77.0	70.0	73.3	81.0	38.8
Faster R-CNN ^[7]	75.3	67.2	71.0	70.4	35.0
DETR ^[8]	74.1	72.3	73.2	76.9	37.2
DAB-DETR ^[9]	90.3	77.1	83.2	77.1	36.4
CO-DETR ^[10]	85.9	78.2	81.9	77.5	37.8
Deformable DETR ^[11]	89.7	79.6	84.4	80.1	38.1
RT-DETR ^[12]	90.1	78.4	83.8	81.4	36.8
DINO ^[13]	88.3	79.6	83.7	83.1	39.0
Align-DETR ^[14]	93.5	80.1	86.3	82.6	37.2
本方法	93.5	81.4	87.0	85.5	40.2

表 3 在数据集AE-SD6上各方法性能对比

Table 3 Performance comparison of various methods on AE-SD6 dataset

对比方法	Precision	Recall	F1-score	mAP@50	mAP@50:95
YOLOv5 ^[3]	80.8	79.0	79.9	82.5	51.3
YOLOv8 ^[4]	86.4	75.7	80.7	81.2	51.7
YOLOv11 ^[5]	83.6	74.4	78.7	80.4	49.8
RetinaNet ^[6]	60.6	59.1	59.8	61.7	34.4
TOOD ^[25]	69.5	70.1	69.8	75.9	48.5
Faster R-CNN ^[7]	79.8	74.3	77.0	75.9	41.3
DETR ^[8]	77.2	75.4	76.3	76.7	48.4
DAB-DETR ^[9]	87.9	83.8	85.8	81.9	53.1
CO-DETR ^[10]	78.4	84.5	81.3	83.4	52.8
Deformable DETR ^[11]	87.9	81.8	84.7	82.5	53.1
RT-DETR ^[12]	88.3	81.3	84.7	84.5	54.2
DINO ^[13]	89.4	83.1	86.1	84.1	53.4
Align-DETR ^[14]	88.7	82.8	85.6	83.4	50.1
本方法	91.2	84.6	87.8	87.2	55.1

MCL的层间分布对齐相契合, 尤其对裂纹、材料缺失等几何敏感目标的优势更为明显, 体现为更高 $mAP@50:95$ 。如图6所示, 展现了各方法在精确度和召回率上的性能权衡关系, 并用气泡大小刻画 $mAP@50:95$ 的值。可见, 右上角且气泡更大对应缺陷检出更全、误报更少且定位更准的较优解。其中, 在AE-SD4上, 本方法在保持Precision与最强基线同水平时, 实现Recall增加1.3%, 同时气泡更大, 说明不仅降低漏检, 还在高IoU阈值平均下获得更高的整体缺陷定位能力。在AE-SD6上, 本方法也处于图的右上角位置, 表现为Precision的显著提高且Recall稳定, 同时气泡最大, 意味着在几何或结构损伤的航空发动机数据上, 本方法体现出更强的几何敏感缺陷目标建模能力与鲁棒性。此外, 图7为避免只相对单一基线的偏置, 直接刻画在当前最优水平上的净提升幅度。结果显示, 在AE-SD4上, 本方法在Precision与最优持平的前提下, Recall, F1, $mAP@50$ 与 $mAP@50:95$ 仍取得较大增益, 说明改进并非通过牺牲精确率换取召回, 而是同步提升缺陷检出完整性与定位质量。在AE-SD6上各指标均同样优异, 表明方法在抑制误检的同时强化了边界回归, 并在 $mAP@50:95$ 上保持稳定提升, 进一步验证其对严格IoU条件下缺陷精细定位能力的有效增强。

如图8所示, 在规模更大且类别不均衡、更贴近航

空质检工程实际的AE-SD5上, 本方法在Precision, Recall, F1分数以及 $mAP@50$, $mAP@75$, $mAP@50:95$ 与不同尺度目标的平均检测精度等指标上整体位于雷达图外缘, 如Precision为87.3%, Recall为87.2%, $mAP@50:95$ 为54.4%, mAP_s 为43.2%, 表明其在兼顾检出完整性与误报抑制的同时, 能够稳定提升严格IoU条件下的定位质量, 并对小尺度缺陷保持显著优势。该结果进一步验证了所提出方法在序列化解码中的协同有效性及可扩展性, AHG-CA以历史区域和质量先验稳定跨尺度注意力与目标对准, ACGB通过滞回奖励抑制跨层重匹配并促进边界框单调细化, MCL以末层分布为锚施加深度加权一致性约束, 从而在复杂航空发动机缺陷检测场景下实现鲁棒性更强的匹配稳定化与收敛优化。

3.3 消融实验和可视化分析

以Align-DETR为基线逐步叠加ACGB(M1), MCL(M2)与AHG-CA(M3), 消融实验结果见表4、5和图9。在AE-SD4上, M1主要提升Recall并带动 $mAP@50/50:95$ 上升, 但Precision略降; 叠加M2后高IoU指标与Precision回升; 加入M3后Precision恢复且 $mAP@50$, $mAP@75$, $mAP@50:95$ 分别较基线提升2.9%、3.4%和3.0%, 体现了模型性能从缺陷召回提升、高阈值定位




图6 (网络版彩图)在AE-SD4和AE-SD6上不同方法的精确度和召回率权衡(气泡大小表示 $mAP@50:95$). (a) AE-SD4; (b) AE-SD6

Figure 6 (Color online) The trade-off between precision and recall for different methods on AE-SD4 and AE-SD6 (bubble size indicates $mAP@50:95$). (a) AE-SD4; (b) AE-SD6.




图 7 (网络版彩图)在AE-SD4和AE-SD6上相对于最强基线的性能提升分析

Figure 7 (Color online) Performance improvement analysis relative to the strongest baseline on AE-SD4 and AE-SD6.




图 8 (网络版彩图)在AE-SD5上不同方法的指标性能雷达图. (a) Precision; (b) Recall; (c) F1-score; (d) mAP@50; (e) mAP@50-95; (f) mAP@75; (g) mAP_s; (h) mAP_m; (i) mAP_l

Figure 8 (Color online) Radar chart of performance metrics for different methods on the AE-SD5 dataset. (a) Precision; (b) Recall; (c) F1-score; (d) mAP@50; (e) mAP@50-95; (f) mAP@75; (g) mAP_s; (h) mAP_m; (i) mAP_l.

表 4 在AE-SD4上的消融实验结果

Table 4 Results of ablation studies on AE-SD4 dataset

方法	Precision	Recall	F1-score	mAP@50	mAP@75	mAP@50:95
Baseline	93.5	80.1	86.3	82.6	30.9	37.2
Baseline+M1	91.2	82.6	86.6	83.1	31.0	38.7
Baseline+M1+M2	92.1	82.4	87.0	84.6	33.0	39.9
Baseline+M1+M2+M3	93.5	81.4	87.0	85.5	34.3	40.2

表 5 在AE-SD6上的消融实验结果

Table 5 Results of ablation studies on AE-SD6 dataset

方法	Precision	Recall	F1-score	mAP@50	mAP@75	mAP@50:95
Baseline	88.7	82.8	85.6	83.4	52.1	50.1
Baseline+M1	89.3	83.2	86.1	85.9	52.1	52.6
Baseline+M1+M2	90.1	82.7	86.2	86.3	53.0	53.4
Baseline+M1+M2+M3	91.2	84.6	87.8	87.2	53.6	55.1




图 9 (网络版彩图)在AE-SD5上的消融实验结果. (a) F1-score逐步增益; (b) mAP@50:95逐步增益; (c) 相对Baseline优势

Figure 9 (Color online) Results of ablation studies on AE-SD5 dataset. (a) F1-score stepwise gain; (b) mAP@50:95 stepwise gain; (c) advantage over the Baseline.

能力增强到精确率回补的性能递进优势. 在AE-SD6上, 同样呈现M1提升几何敏感缺陷覆盖、M2强化高IoU下的损伤定位、M3进一步稳健聚焦而获得最优综合性能的趋势. 与此同时, 在规模更大、类别更不均衡的AE-SD5上, 上述增益仍能稳定保持, 表明所设计的3个模块的匹配稳定化、跨层一致性约束与历史引导聚焦具有良好的可扩展性与泛化性.

此外, 图10给出了航空发动机叶片缺陷测试样例的可视化结果, 左侧对比展示了GT与不同方法的检测框, 最右侧给出了本文方法在解码器最后一层的可变

形cross-attention采样点分布(颜色由冷到暖表示注意力权重由低到高). 可以观察到, 高权重采样点主要密集分布在缺陷邻域, 并沿细长裂纹的走向呈带状连续覆盖, 且对端点、拐折等几何关键位置具有更高的采样密度. 对于局部缺口、边缘损伤类目标, 采样点则围绕缺陷边界形成集中簇. 与此同时, 远离缺陷的平坦背景区域仅出现少量或离散的低权重点, 表明注意力在解码后期能够稳定聚焦于结构性区域与真实缺陷特征, 从而抑制反光、油污与纹理噪声等诱发的关注漂移并提升高IoU阈值下的定位稳定性.




图 10 (网络版彩图)本方法在航空发动机缺陷检测测试样本上的可视化

Figure 10 (Color online) Visualization results of our model on aero-engine defect detection test samples.

从原理设计上分析, 三项机制分别作用于指派、优化与特征聚焦, 并形成递进互补. 首先, M1(ACGB)在匈牙利指派中注入上一层配对先验的滞回偏置, 优先稳定续配并扩大训练早期的正样本覆盖, 因此主要带来缺陷召回率和精度的提升. 其次, M2(MCL)以最终层匹配分布为锚, 对中间层施加跨层KL一致性约束, 抑制配对在层间的切换与抖动, 从而改善高IoU阈值下的定位精度并促进边界框单调细化. 此外, M3(AHG-CA)通过历史区域加权采样与质量引导偏置, 将可靠的“历史记忆”投射到跨尺度交叉注意力中, 强化了空间聚焦并抑制伪前景干扰.

3.4 匹配一致性测试分析

为有效刻画DETR系列模型因各层独立匈牙利匹配而易发生ID切换的问题, 设计匹配一致性(matching

consistency, MC)指标. 设解码器层数为 L , $\pi^{(l)}(j)$ 表示第 l 层对第 j 个GT的匹配结果(返回其匹配的query索引, 未匹配记为-1), 对当前batch跨层一致的GT数量 N_{con} 和MC的计算方式如下:

$$N_{\text{con}} = \sum_{j=1}^{N_{\text{gt}}} \mathbf{1}[\forall l \in \{1, \dots, L-1\}, \pi^{(l)}(j) = \pi^{(L)}(j)], \quad (24)$$

$$MC = \frac{N_{\text{con}}}{N_{\text{gt}}} \in [0, 1], \quad (25)$$

其中, N_{gt} 为该batch中GT的总数, 若任一中间层将该GT改配为其他GT或丢配为背景, 则都会判为“不一致”. 例如, 设解码器层数 $L = 4$, 对某个GT g_j 记最终层匹配为 $\pi_j^{(4)} = 12$. 当且仅当 $\forall l \in \{1, 2, 3\}, \pi_j^{(l)} = \pi_j^{(4)}$ 时

g_j 被判为“一致”. 若任一中间层发生改配(如 $\pi_j^{(2)} = 7$)或丢配为背景(如 $\pi_j^{(3)} = -1$), 则 $\exists l$ 使 $\pi_j^{(l)} \neq \pi_j^{(4)}$, 该 g_j 不计入 N_{con} , 从而使MC值相应降低.

如图11所示, 本文方法的匹配一致性MC在训练早期提升更快, 并在相同训练进度下取得更高的一致匹配比例. 以epoch为20附近为例, AE-SD4, AE-SD6, AE-SD5上MC分别提升至0.903、0.899和0.934. 这表明所提出的序列化匹配与跨层约束能够更早抑制指派抖动与ID切换, 加速由不稳定到稳态的一致配对形成. 进入中后期, 本文方法的MC曲线整体优于基线且波动更小, 说明在稳态阶段仍能维持更高的跨层指派一致性与更低的训练方差.

特别地, 从模型计算效率和应用上分析, ACGB仅介入训练阶段的指派求解, 推理时不进行匹配与滞回偏置计算, 因此不增加部署侧的推理开销与额外依赖. MCL属于训练期的一致性正则, 通过反向传播牵引中间层分布向末层对齐; 推理阶段不计算该项, 输出接口与基线保持一致. AHG-CA在解码器内部以质量门控

方式注入跨层历史区域, 不改变模型输入输出. 当历史信号不可靠时门控自动减弱并退化为标准交叉注意力, 从而提升复杂工况下推理的稳健性. 在面向孔探质检的图像或视频帧检测时, 能够准确快速输出航空发动机部件的缺陷类别、置信度与边界框, 可直接用于质检界面的可视化与报告生成, 且便于以检测模块方式集成.

3.5 模型收敛性分析

为刻画优化动力学, 进一步跟踪训练损失随迭代的演化, 并与前述MC指标联合分析. 如图12所示, 本文方法在3个数据集上均呈现前期下降更快、后期平台更低且更平滑的稳定优势. 在AE-SD4上, 本方法初段下降更陡. 以图中给定损失阈值为参照, 达到该阈值所需迭代由2022降至1674(减少约17%), 且稳态阶段波动幅度更小. 在AE-SD6上, 两者自早期即明显分离并保持差距, 阈值到达迭代由4405降至1822, 显示出显著的收敛加速与更低的损失平台. 在训练更长的AE-SD5上, 同样获得稳定加速, 阈值到达迭代减少约9%, 并最




图 11 (网络版彩图) Baseline与改进方法在跨解码层的匹配一致性对比. (a) AE-SD4; (b) AE-SD6; (c) AE-SD5

Figure 11 (Color online) Comparison of matching consistency between baseline and the improved method across decoding layers. (a) AE-SD4; (b) AE-SD6; (c) AE-SD5.




图 12 (网络版彩图)模型改进前后在不同数据集训练的损失函数迭代曲线变化. (a) AE-SD4; (b) AE-SD6; (c) AE-SD5

Figure 12 (Color online) The iterative curves of loss functions trained on different datasets before and after model improvement. (a) AE-SD4; (b) AE-SD6; (c) AE-SD5.

终收敛至更低和更平稳的损失区间。

这些收敛特征与前面所示的MC提升相一致。更高的MC表明跨层匹配更稳定、ID切换更少,从而减弱层间监督目标的频繁跳变与由此诱发的梯度不相干,降低训练过程中的梯度方差。最终体现为损失曲线下降更平滑,在相同阈值下收敛更快并收敛到更低的平台。与所提出的三项机制对应,ACGB在指派阶段提高改配门槛以抑制重匹配,MCL以末层分布为参照约束中间层预测一致性,AHG-CA通过历史区域与质量先验稳定跨尺度注意力,三者共同促进航空发动机缺陷检测任务中的跨层一致性与优化稳定性提升。

4 结论

本文面向基于孔探的航空发动机缺陷检测中强反光、油污噪声、细长微小缺陷与位姿扰动导致的检测

不稳与跨层改配难题,提出序列化匹配与历史经验迁移框架。在Align-DETR基线上从特征侧、匹配侧与优化目标侧协同设计了AHG-CA,ACGB和MCL,系统提升跨层一致性与训练稳定性。在多个航空发动机缺陷检测数据上的实验结果表明,所提方法在弱对比与伪前景干扰场景下提高检出完整性且不牺牲精确率。在结构和几何损伤场景下提升严格IoU阈值下的定位精度,并在类别不均衡的缺陷数据上保持稳定泛化。同时,MC指标与损失曲线结果显示其跨层指派更早趋于稳定,训练收敛更快且最终损失更低和更平滑。在未来工作中,将结合序列孔探视频与探头位姿信息,构建时空一致的解码与匹配机制,进一步实现航发缺陷的时序稳定检出与跟踪、跨帧或跨视图配准及三维定位与演化分析。同时,探索面向边缘部署的模型轻量化与推理加速,在保证高阈值IoU定位精度的前提下降低检测延迟与算力开销。

参考文献

- Chen X F, Wang S B, Yang Z B, et al. Aeroengine health management: Progress and future trends (in Chinese). *Sci Sin-Tech*, 2025, 55: 1255–1280 [陈雪峰, 王诗彬, 杨志勃, 等. 航空发动机健康管理研究进展及展望. 中国科学: 技术科学, 2025, 55: 1255–1280]
- Zeng N, Wu P, Wang Z, et al. A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection. *IEEE Trans Instrum Meas*, 2022, 71: 1–14
- Khanam R, Hussain M. What is YOLOv5: A deep look into the internal features of the popular object detector, arXiv: [2407.20892](https://arxiv.org/abs/2407.20892)
- Varghese R, M S. YOLOv8: A novel object detection algorithm with enhanced performance and robustness. In: *Proceedings of the 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems*. 2024. 1–6
- Khanam R, Hussain M. YOLOv11: An overview of the key architectural enhancements, arXiv: [2410.17725](https://arxiv.org/abs/2410.17725)
- Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection. *IEEE Trans Pattern Anal Mach Intell*, 2020, 42: 318–327
- Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39: 1137–1149
- Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers. In: *Proceedings of the European Conference on Computer Vision*. 2020. 213–229
- Liu S, Li F, Zhang H, et al. DAB-DETR: Dynamic anchor boxes are better queries for DETR. In: *Proceedings of the International Conference on Learning Representations (ICLR)*. 2022. 1–19
- Zong Z, Song G, Liu Y. DETRs with collaborative hybrid assignments training. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2023. 6748–6758
- Zhu X, Su W, Lu L, et al. Deformable DETR: Deformable transformers for end-to-end object detection. In: *Proceedings of the International Conference on Learning Representations (ICLR)*. 2021. 1–16
- Zhao Y, Lv W, Xu S, et al. DETRs beat YOLOs on real-time object detection. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024. 16965–16974
- Zhang H, Li F, Liu S, et al. DINO: DETR with improved denoising anchor boxes for end-to-end object detection. In: *Proceedings of the International Conference on Learning Representations (ICLR)*. 2023. 1–23
- Cai Z, Liu S, Wang G, et al. Align-DETR: Enhancing end-to-end object detection with aligned loss. In: *Proceedings of the 35th British Machine*

- Vision Conference 2024. 2024. 1–14
- 15 Li D, Li Y, Xie Q, et al. Tiny defect detection in high-resolution aero-engine blade images via a coarse-to-fine framework. *IEEE Trans Instrum Meas*, 2021, 70: 1–12
 - 16 Shang H, Yang Q, Sun C, et al. Superpixel perception graph neural network for intelligent defect detection of aero-engine blade. *J Manufacturing Syst*, 2024, 77: 112–126
 - 17 Liu P, Yuan X, Han Q, et al. Micro-defect Varifocal Network: Channel attention and spatial feature fusion for turbine blade surface micro-defect detection. *Eng Appl Artif Intelligence*, 2024, 133: 108075
 - 18 Li S, Yu J, Wang H. Damages detection of aeroengine blades via deep learning algorithms. *IEEE Trans Instrum Meas*, 2023, 72: 1–11
 - 19 Cheng X H, Meng X F, Liu M, et al. Neural architecture search-based detection method and system for aero-engine blade surface defects (in Chinese). *Sci Sin Inf*, 2025, 55: 1657–1672 [程曦航, 孟翔飞, 刘敏, 等. 基于网络架构搜索的航发叶片表面缺陷检测方法及系统. *中国科学: 信息科学*, 2025, 55: 1657–1672]
 - 20 Shang H, Wu J, Sun C, et al. Global prior transformer network in intelligent borescope inspection for surface damage detection of aeroengine blade. *IEEE Trans Ind Inf*, 2023, 19: 8865–8877
 - 21 Ma Y, Liu M, Zhang Y, et al. SPDP-Net: A semantic prior guided defect perception network for automated aero-engine blades surface visual inspection. *IEEE Trans Automat Sci Eng*, 2025, 22: 2724–2733
 - 22 Wu X, Wei X, Xu H, et al. Aeroengine blades damage detection and measurement based on multimodality fusion learning. *IEEE Trans Instrum Meas*, 2024, 73: 1–15
 - 23 Chen H, Wu P, Wen W, et al. DLA-Net: A dynamically learnable attention network for intelligent surface visual inspection of aero-engine blades. *IEEE Trans Instrum Meas*, 2025, 74: 1–14
 - 24 Chen K, Wang J, Pang J, et al. MMDetection: OpenMMLab detection toolbox and benchmark, arXiv: [1906.07155](https://arxiv.org/abs/1906.07155)
 - 25 Feng C, Zhong Y, Gao Y, et al. TOOD: Task-aligned one-stage object detection. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*. 2021. 3490–3499

An aero-engine defect detection method via sequential matching and historical experience-guided transfer

WU PeiShu^{1,2}, ZENG NianYin¹, LIU QinYuan², CHEN Liang¹, CHENG ZeRui¹ & TENG Da¹

¹ School of Aerospace Engineering, Xiamen University, Xiamen 361102, China

² School of Computer Science and Technology, Tongji University, Shanghai 201804, China

Borescope imaging of aero-engines often suffers from specular highlights, oil contamination, low-contrast micro-defects or elongated defects, and probe perturbations, which induce cross-layer reassignment and unstable convergence in end-to-end detectors. We propose an end-to-end aero-engine defect detection framework based on sequential matching and history-guided transfer. Building on Align-DETR, the framework designs three complementary mechanisms spanning features, assignment, and optimization: (1) adaptive history-guided cross-attention leverages historical regions and quality priors to stabilize cross-scale information aggregation and target alignment; (2) adaptive context-guided bias injects a hysteresis term into the linear assignment stage, raising the reassignment threshold and suppressing rematching; (3) matching consistency loss anchors intermediate layers to the final-layer distribution via depth-weighted KL-divergence alignment, enforcing cross-layer consistency. These designs render the originally implicit inter-layer dependencies explicit and differentiable, reducing assignment jitter and gradient conflicts, and promoting monotonic box refinement with stable convergence. Extensive experiments on three aero-engine defect datasets demonstrate consistent gains in detection precision and recall over strong baselines and mainstream competitors. On AE-SD6, our method improves mAP@50:95 over Align-DETR by 5.0%, markedly increases early-stage matching consistency, reduces the number of iterations required to reach a given loss threshold by up to 59%, and converges to a lower and smoother loss plateau. The results verify robustness and generalization under challenging conditions and provide a scalable, engineering-ready solution for intelligent aero-engine defect inspection.

aero-engine, visual defect detection, sequential matching, history-prior guidance, convergence stability

doi: [10.1360/SST-2025-0371](https://doi.org/10.1360/SST-2025-0371)