

基于扩散模型的航空发动机叶片损伤智能检测



商红兵,杨淇琇,孙闯,王诗彬

西安交通大学 航空动力系统与等离子体技术全国重点实验室, 陕西 西安 710049

摘要:高速旋转的多层阵列叶片作为涡轴发动机和涡桨发动机的重要组成部分,传统的孔探检查方法由于依赖人工经验和目视检查,存在人工成本高、检查效率低、误检和漏检时有发生等问题,难以满足航空发动机原位检查与地面维护对于实时性、高效性和准确性的需求。因此,本文提出一种基于扩散模型的航空发动机叶片损伤智能检测(DMBD)方法,将损伤检测任务分解成图像特征提取和损伤检测评估两部分,图像特征提取网络使用残差模块从输入图像中提取特征表示,损伤检测评估网络利用扩散过程将噪声框作为输入并预测损伤类别和坐标,从而实现直接从噪声候选框中生成目标框并用于损伤分类和定位,无须人工设置预定义候选框的参数,实现发动机叶片损伤的高精度智能识别。将DMbD方法应用于航空发动机叶片图像数据进行损伤检测评估。试验结果表明,本文所提方法能够快速、准确地识别航空发动机叶片损伤,检测均值平均准确率(mAP)为0.988。相比于传统方法和现有智能检测方法,本文所提方法避免了构建模型时预先人为设定候选框,能够从噪声分布中预测损伤边界框,实现航空发动机叶片损伤智能检测。

关键词:航空发动机叶片; 损伤检测; 扩散模型; 孔探检测

中图分类号:V232.4

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2025.02.002

多层阵列叶片是保证航空发动机正常、安全运行的关键。然而,其工作环境十分恶劣,高压转子的转速超过14000r/min,高压涡轮的进口温度可达2000K,在长期的运行过程中,航空发动机叶片极易发生打伤、裂纹、烧蚀等损伤,严重威胁航空发动机运行安全^[1-2]。因此,为了避免严重的经济或人员损失,有必要开展航空发动机叶片损伤检测研究。

航空发动机叶片损伤检测方法有磁粉检测、红外检测、超声检测、射线检测等,但上述方法常常需要将叶片从发动机上拆卸下来,故不能实现高效的航空发动机叶片原位检测。而最常用的原位检测方法是孔探检查。Yuan Zhongda^[3]指出孔探检查占航空发动机非计划性维护的90%。孔探检查是指通过人工操纵孔探仪经航空发动机表面预留的窥视孔进入发动机内部,孔探仪管道末端的镜头实时捕获并呈现内部腔体和多层阵列叶片的状态,检查人员通过观察孔探仪的屏幕并结合经验判断损伤类型和严重

程度。然而,人工检查成本高、效率低、易产生漏检和误检,并且检查人员培训耗时久、检查结果主观性强。因此,智能化孔探检查方法是发展趋势和新兴方向,是实现叶片智能检测的有效手段之一,主要涉及面向叶片损伤检测的孔探图像智能识别问题。

对于面向叶片损伤检测的孔探图像智能识别,其关键在于实现损伤的特征提取、模式分类、精确定位等。现有叶片损伤检测方法大多基于计算机视觉领域中的目标检测方法,主要分为以直接回归(YOLO)算法^[4]为代表的单阶段目标检测方法和以基于区域的卷积神经网络(R-CNN)算法^[5]为代表的两阶段目标检测方法。YOLO系列方法直接采用回归的策略获得损伤类别和坐标,使得检测速度大幅增加,但检测性能不尽如人意。R-CNN系列方法设计了候选框生成网络,并在预先定义的边界框上执行损伤分类和位置回归,获得了令人满意的检测性能。在R-CNN系列方法中,候选框生成网络在生成预定义边界框和执行初步损伤

收稿日期: 2024-06-17; 退修日期: 2024-10-15; 录用日期: 2024-12-18

基金项目: 航空科学基金(20200046070002)

引用格式: Shang Hongbing, Yang Qixiu, Sun Chuang, et al. Diffusion model-based intelligent damage detection of aero-engine blade[J]. Aeronautical Science & Technology, 2025, 36(02): 29-37. 商红兵, 杨淇琇, 孙闯, 等. 基于扩散模型的航空发动机叶片损伤智能检测[J]. 航空科学技术, 2025, 36(02): 29-37.

分类和定位方面发挥了重要作用。Tao Xian等^[6]将候选框生成网络引入他们的损伤检测模型中以提升计算候选框的效率。Su Binyi等^[7]提出一种融合通道注意力和空间注意力的候选框生成网络用于预测潜在的损伤位置。Shih等^[8]提出一种简化的候选框生成网络用于减少损伤检测网络的参数和提升检测准确率。此外,Song Chunhe等^[9]在候选框生成网络中设置多尺度的预定义框以适应不同尺寸的损伤。但上述研究不可避免地涉及基于经验的目标先验,即需要在设计候选框生成网络时确定预定义的候选框,并需要人为设定候选框数量、尺寸、尺度等超参数。

基于以上研究现状,本文在候选框生成网络部分提出采用扩散模型从噪声候选框中生成目标框,无须人工设置预定义候选框的参数。对于候选框生成网络的输出,需要送入检测解码器中进一步处理,以实现损伤的分类和定位,其重点在于如何在初步分类和定位的候选框的基础上实现损伤模式和位置的精确检测。为此,Cai Zhaowei等^[10]提出一种级联R-CNN,检测评估模块包含多个感兴趣区域阈值逐渐递增的检测器,从而获得高质量的候选框用于分类和定位。Sun Peize等^[11]利用级联的思想对输出的边界框进行处理,得到最终的损伤位置信息。Carion等^[12]基于注意力机制构建了并行检测解码网络,得到最终的候选框。受益于扩散模型的迭代降噪属性,为了进一步提升损伤检测性能,可设计多阶段检测解码模块以迭代的方式实现检测头的重用。因此,检测解码网络部分提出一种多阶段迭代评估模块,实现损伤模式和位置的精确检测。

综合区域提议网络和检测解码网络两部分内容,结合图像编码网络实现图像的特征提取,本文构建一种基于扩散模型的叶片损伤检测(DMbD)方法,首先采集获取孔探图像数据,将其输入图像编码器实现图像特征提取,基于扩散模型的候选框生成网络从随机噪声边界框中生成最终候选框,检测解码器将图像特征和候选框作为输入,并通过多阶段检测评估实现损伤模式分类和位置回归。相比于传统方法和现有智能检测方法,本文所提方法避免了构建模型时预先人为设定候选框,能够从噪声分布中预测损伤边界框,实现航空发动机叶片损伤智能检测。

1 叶片损伤检测

1.1 基于残差模块的特征提取网络

1.1.1 残差模块

图像特征提取在图像识别任务中发挥了关键作用,它用于提取特征和挖掘损伤信息,并服务于下游的分类和定

位任务。残差连接模块使用恒等映射 x 获得深层的输出 $\varphi(x)+x$,如图1所示,跳跃连接能让浅层信息直接传递到网络的深层^[13]。从理论上分析,越深的网络挖掘到图像的特征越多、特征的代表能力越强,对目标的检测能力越强。因此,不断堆叠残差模块可以构建深层的网络模型,从而获得更好的特征表示。




图1 残差模块

Fig.1 Residual block

1.1.2 基于残差模块的特征提取网络

在本文中利用卷积神经网络与残差模块,搭建基于残差网络的特征提取网络,其网络详细结构见表1(为了标识清晰,在表中省略了批正则化层和激活层)。该网络可分为5个卷积模块conv1、conv2、conv3、conv4、conv5。其中第1个卷积模块conv1包含卷积核尺寸为 7×7 、数量为64、步长为2的卷积层(下同);第2个卷积模块包含最大池化层和3个残差模块;第3~5个卷积模块包含不同数量的残差模块,且在第一个残差模块的恒等映射中,均包含一个下采样操作使得输出的特征图尺寸、通道数与上一卷积层输出的特征图保持一致,从而完成残差模块的加法操作;每个残差模块除了卷积核数量不同外,均由 1×1 和 3×3 的卷积层构成。

1.2 基于扩散模型的候选框生成网络

1.2.1 扩散模型

扩散模型通过逐渐向样本数据中添加噪声的方式定义了前向扩散过程,在此阶段 t 时刻的数据只与 $t-1$ 时刻的数据有关。因此,此过程也可视为马尔可夫过程。反向过程阶段是一个去噪过程,样本数据将以一种迭代的方式被重构,可实现从随机噪声到样本数据的目的^[14]。图2所示为扩散模型的基本结构,其中 q 是前向扩散过程, p 是反向去噪过程。本文的候选框生成网络利用扩散模型的去噪反向过程将噪声样本 x_T 逐步去噪,最终获得样本数据 x_0 。

具体来讲,前向扩散过程 q 将数据样本变换为噪声样

表1 基于残差网络的特征提取

Table 1 Residual module-based feature extraction

卷积模块	模块组成	模块结构
conv1	卷积层	7×7, 64, 步长=2
conv2	最大池化层	3×3, 步长=2
	残差模块×3	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix}$
conv3	残差模块×4	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix}$
conv4	残差模块×23	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix}$
conv5	残差模块×3	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix}$




图2 扩散模型结构

Fig.2 Structure of diffusion model

本,如式(1)所示。在模型训练阶段,候选框生成网络 f_θ 通过最小化损失函数从噪声候选框 z_t 预测最终候选框 z_0 。前向扩散过程 q 和损失函数分别如式(1)、式(2)所示

$$q(z_t|z_0) = \mathcal{N}(\sqrt{\bar{\alpha}_t} z_0, (1 - \bar{\alpha}_t) \mathbf{I}) \quad (1)$$

$$L_{\text{train}} = \frac{1}{2} \|f_\theta(z_t, t) - z_0\|^2 \quad (2)$$

式中, $\bar{\alpha}_t = \prod_{s=0}^t \alpha_s = \prod_{s=0}^t (1 - \beta_s)$, β_s 为噪声方差,式(1)表明当给定初始样本 z_0 时,其多次扩散中始终对应一个高斯分布,且当 β_s 足够小时,扩散过程的逆过程(反向去噪过程) $p(x_{t-1}|x_t)$ 近似符合高斯分布。 L_{train} 为训练时所用损失函数, $f_\theta(z_t, t)$ 为候选框生成网络, z_0 为样本标签, \mathbf{I} 为单位矩阵。

在推理阶段,噪声候选框 z_T 在网络 f_θ 中不断更新,并以一种迭代的方式重构出最终候选框 z_0 ,即 $z_T \rightarrow z_t \rightarrow z_{t-1} \rightarrow \dots \rightarrow z_0$ 。

1.2.2 基于扩散模型的候选框生成网络

损伤检测网络可以视为目标检测网络的一种真实场景体现,这一任务是指通过训练大量的图像-标签数据得到一个检测器能够准确分类和定位目标,即损伤。这一过程如式(3)、式(4)所示

$$\Theta = \arg \min_{\Theta} l(y_i, \hat{y}_i) \text{ s.t. } \hat{y}_i = \text{Objector}_{\text{train}}(x_i; \Theta) \quad (3)$$

$$z_i = \text{Objector}_{\text{test}}(x_i; \Theta) \quad (4)$$

式中, x_i 表示图像数据, y_i 为对应的标签, z_i 为推理结果,即损伤类别和坐标。Objector为带有可学习参数 Θ 的神经网络, Objector_{train}和 Objector_{test}分别表示训练和测试阶段的神经网络。

对于带有注释的叶片损伤图像数据集 $D = \{X, Y\}$,该数据集含有 N 对图像-标签,即 $X = \{x_1, x_2, \dots, x_N\}$ 且 $Y = \{y_1, y_2, \dots, y_N\}$,其中, X 和 Y 分别为图像和对应的标签, N 为数据集中样本的数量。每个 $y_i = \{l_1, l_2, \dots, l_K\}$ 表示其包含 K 个被定义的损伤实例,且第 i 个目标实例 $l_i = [c_i, x_i, y_i, w_i, h_i]$,其中, c_i 为损伤类别, x_i, y_i, w_i, h_i 分别为边界框的中心点坐标、宽度、高度。另外,考虑定义的损伤类别 $C = \{1, 2, \dots, M\} \subset \mathbb{N}^*$,其中, M 为损伤类别的数量。输入图片经过特征提取网络后,得到的特征图被送进候选框生成网络,提取最终用于位置回归的兴趣区域。

然而,在候选框生成网络中需要设置候选框的尺寸和长宽比例。为了避免经验性地人工设置候选框超参数,本文采用扩散模型实现候选框的生成,如图3所示。在训练阶段,通过向标注的边界框添加噪声构建前向扩散过程,并添加额外的边界框使训练时边界框的数量固定为 N_{train} ,训练模型实现反向去噪过程得到最终的候选框。推理阶段是一个从噪声框到候选框的去噪采样过程,模型开始于高斯分布噪声,并通过不断细化预测的边界框得到数量为 N_{test} 的最终边界框。




图3 基于扩散模型的候选框生成

Fig.3 Diffusion model-based bounding box generation

1.3 多阶段检测评估网络

1.3.1 候选框对齐操作

对于候选框生成网络的输出,需要到检测网络中进一步处理,以实现损伤的最终分类和定位。为了减小后续分类和定位的参数数量,提升模型对于不同尺寸输入的适应性,

对获得的候选框进行对齐操作。如图4所示,将深黄色区域分为4个网络,在网格中选择4个点,该点是4个相邻像素进行双线性插值的结果,最后在网格内执行最大池化以获得大小相同的特征图用于分类和定位。




图4 候选框对齐操作

Fig.4 The process of bounding box alignment

1.3.2 多阶段检测评估网络

如图5所示,受益于扩散模型的迭代降噪属性,多阶段检测评估网络包含6个阶段,每个阶段都以当前时刻的候选框作为输入,实现重复使用检测网络的目的,以迭代评估的方式输出更准确的边界框。在每次采样处理后,将不需要的预测框剔除,并使用从高斯分布中采样得到的随机框来替代,且随机框的数量和迭代次数没有要求。因此,训练和评估阶段的候选框不需要完全一致。

1.4 DMbD的整体框架

图6为本文提出的DMbD方法的整体框架。整体网络结构由特征提取网络、基于扩散模型的候选框生成网络、多阶段检测评估网络构成。特征提取网络采用残差网络提取




图5 多阶段检测评估网络

Fig.5 Multi-stage detection evaluation network

图像的多尺度特征,基于扩散模型的候选框生成网络从噪声分布中预测边界框,避免了预先经验设置的候选框。多阶段检测评估网络将特征提取网络输出的特征图和候选框生成网络输出的边界框作为输入,以迭代的方式实现检测器的多阶段重用,以获得更准确的检测结果。

2 试验验证

2.1 航空发动机叶片损伤检测试验

本文模型通过采用航空发动机叶片损伤检测试验加以验证。试验以某型发动机叶片为原型,采用三维扫描、3D打印、激光加工、相机拍摄、人工标记等流程构建航空发动机仿真叶片图像数据集,叶片图像数据实例如图7所示。数据集中损伤类型和数量见表2,所构建数据集共包含5类损伤和3000张损伤图像。

叶片损伤检测验证试验中,将DMbD与现有经典检测

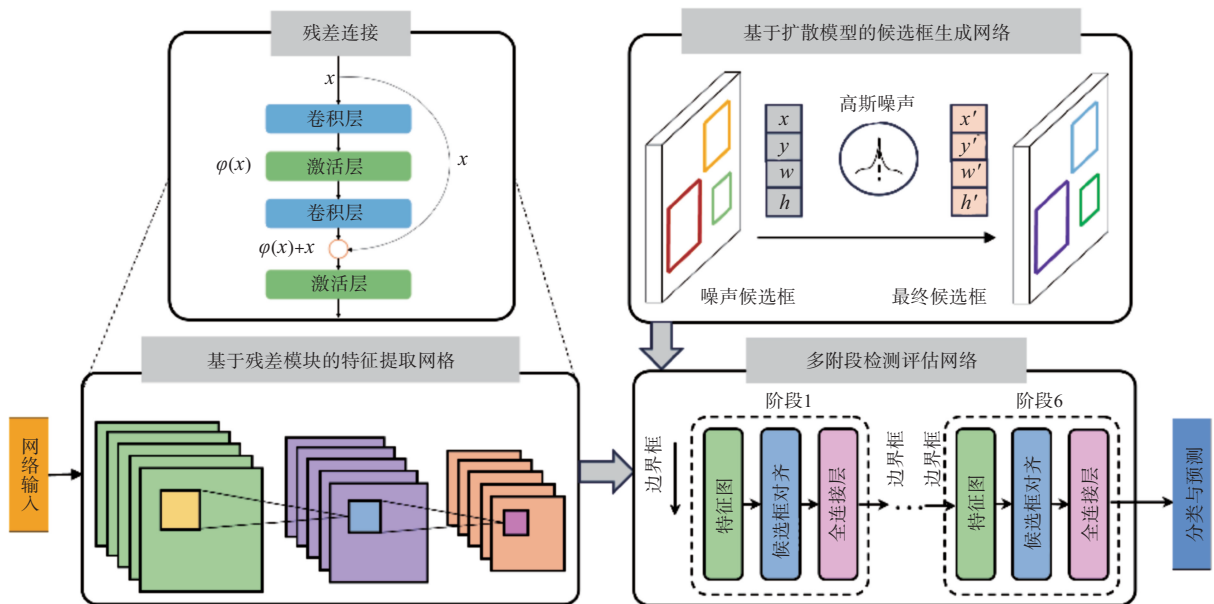


图6 DMbD的网络结构

Fig.6 The network structure of DMbD




图7 叶片图像实例

Fig.7 The instances of blade images

表2 损伤的类型和数量

Table 2 The types and number of damages

类型	数量
掉块	250
烧蚀	250
裂纹	750
刻口	250
涂层剥落	250
掉块+烧蚀	150
掉块+涂层剥落	100
裂纹+掉块	250
裂纹+烧蚀	250
裂纹+裂纹	250
裂纹+涂层剥落	250

方法(如更快的基于区域的卷积神经网络(Faster R-CNN)^[15]、稀疏的基于区域的卷积神经网络(Sparse R-CNN)^[11]、动态的基于区域的卷积神经网络(Dynamic R-CNN)^[16]、YOLOv3^[17]、基于聚焦损失的单阶段网络(RetinaNet)^[18])进行对比。采用MMDetection^[19]检测框架对不同模型进行测试,根据图像中的损伤对图像进行剪裁,共获得4250个带损伤的样本,按照9:1的比例随机划分训练集和验证集,获得3825个样本的训练集和425个样本的验证集。输入不同模型的图像尺寸均设置为896×896,训练阶段的批处理数量为2,所有模型均训练12个迭代周期,其余参数均为默认。

2.2 结果与分析

在试验验证中,两个重要的评估指标是准确率和召回率,分别用式(5)、式(6)表示。根据预测类别和预测边界框与标签对比判断是否检测准确,交并比用式(7)表示

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{IoU} = \frac{A_{\text{era}_{\text{in}}}}{A_{\text{era}_{\text{un}}}} \quad (7)$$

式中,Precision、Recall、IoU分别表示准确率、召回率、交并比。 $A_{\text{era}_{\text{in}}}$ 和 $A_{\text{era}_{\text{un}}}$ 分别表示交集和并集的面积。TP、FP、FN分别表示真正、假正、假负。

采用均值平均准确率(mAP)对不同的模型进行评估。如图8所示,在平面坐标系中,横轴的值代表召回率,纵轴的值代表准确率。对于每个召回率值,都会有多个精度,取准确率的最大值作为其对应的准确率。根据这个原理,将召回率和准确率的几个坐标对连接起来得到一条曲线,曲线和坐标轴围成的面积称为平均准确率(AP),所有类别的均值称为mAP。




图8 均值平均准确率示意图

Fig.8 The schematic diagram of mAP

按照3.1节所述的试验设置进行对比试验,研究在425个样本的验证集上的结果,不同方法的对比结果见表3,试验结果表明DMbD方法不仅获得了最好的试验结果,而且具有令人满意的推理速度。

表3 不同方法的对比结果

Table 3 The comparison results between different methods

模型	mAP	推理时间/s
Faster R-CNN	0.966	141
Sparse R-CNN	0.982	130
Dynamic R-CNN	0.982	116
Yolov3	0.795	124
RetinaNet	0.966	120
DMbD	0.988	165

表4对不同损伤进行分析。根据结果可以看出,DMbD在掉块、烧蚀、剥落、刻口4种损伤上均取得了最佳的性能,在裂纹检测上也取得了有竞争力的结果。综合分析,DMbD具有最佳的损伤检测能力。

表4 不同损伤的对比结果

Table 4 The results of different damage types

模型	裂纹	掉块	烧蚀	剥落	刻口
Faster R-CNN	0.93	0.97	0.962	0.967	1.0
Sparse R-CNN	0.969	0.974	0.999	0.967	1.0
Dynamic R-CNN	0.964	0.979	0.992	0.977	1.0
Yolov3	0.779	0.834	0.747	0.923	0.692
RetinaNet	0.878	0.975	0.996	0.979	1.0
DMbD	0.961	1.0	1.0	0.977	1.0

根据试验结果绘制混淆矩阵,如图9所示,综合5类损伤来看,DMbD综合检测准确率最高,且漏检和误检率最低,这表明DMbD具有良好的应用前景。

以训练过程中的迭代次数为横轴、以总损失为纵轴,通过绘制损失变化随迭代次数的变化的曲线图,可得图10所示的不同方法的损失函数曲线,表示无量纲的损失值随迭代次数的变化。由图10可知,相比于Sparse R-CNN和Dynamic R-CNN两种有竞争力的方法,DMbD能更快地收敛,且收敛效果更加稳定,这表明DMbD能够很好地适应数据并从数据中学习到有用的信息,也从另一个方面体现了所提出的DMbD方法的优越性。

3 结论

通过研究,可以得出以下结论:

(1) 本文提出DMbD方法,该方法避免了构建模型时预先人为设定候选框,能够从噪声分布中预测损伤边界框,实现航空发动机叶片损伤智能检测。

(2) 受益于扩散模型的迭代去噪属性,构建了多阶段检测评估网络,以迭代评估的方式提升了损伤的分类和定位的精度。

(3) 航空发动机叶片损伤检测试验的对比结果表明,该模型适用于航空发动机叶片检测任务,能有效识别损伤类型并进行准确定位。

AST

参考文献

[1] 张雅婷, 杨蒲, 孟宪锋, 等. 基于CNLS-MMD的孪生混合网络四旋翼飞行器故障诊断方法[J]. 航空科学技术, 2023, 34(12): 125-134.
Zhang Yating, Yang Pu, Meng Xianfeng, et al. Fault diagnosis method of siamese hybrid neural network quadrotor aircraft based on CNLS-MMD[J]. Aeronautical Science & Technology, 2023, 34(12): 125-134. (in Chinese)

[2] 李嘉欣, 吕帅帅, 杨宇, 等. 基于导波和知识迁移的结构损伤

识别方法研究[J]. 航空科学技术, 2023, 34(5): 54-60.

Li Jiaxin, Lyu Shuaishuai, Yang Yu, et al. Research on structure damage identification method based on guided wave and knowledge transfer [J]. Aeronautical Science & Technology, 2023, 34(5): 54-60. (in Chinese)

[3] Yuan Zhongda. Borescope inspection management for engine [J]. IOP Conference Series: Earth and Environmental Science. IOP Publishing, 2018, 128(1): 012013.

[4] Redmon J, Divvala S, Girshick R, et al. You only look once: Unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.

[5] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.

[6] Tao Xian, Zhang Dapeng, Wang Zihao, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2018, 50(4): 1486-1498.

[7] Su Binyi, Chen Haiyong, Chen Peng, et al. Deep learning-based solar-cell manufacturing defect detection with complementary attention network [J]. IEEE Transactions on Industrial Informatics, 2020, 17(6): 4084-4095.

[8] Shih K H, Chiu C T, Lin J A, et al. Real-time object detection with reduced region proposal network via multi-feature concatenation [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 31(6): 2164-2173.

[9] Song Chunhe, Xu Wenxiang, Han Guangjie, et al. A cloud edge collaborative intelligence method of insulator string defect detection for power IIoT [J]. IEEE Internet of Things Journal, 2020, 8(9): 7510-7520.

[10] Cai Zhaowei, Nuno V. Cascade R-CNN: Delving into high quality object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6154-6162.

[11] Sun Peize, Zhang Rufeng, Jiang Yi, et al. Sparse R-CNN: End-to-end object detection with learnable proposals [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 14454-14463.

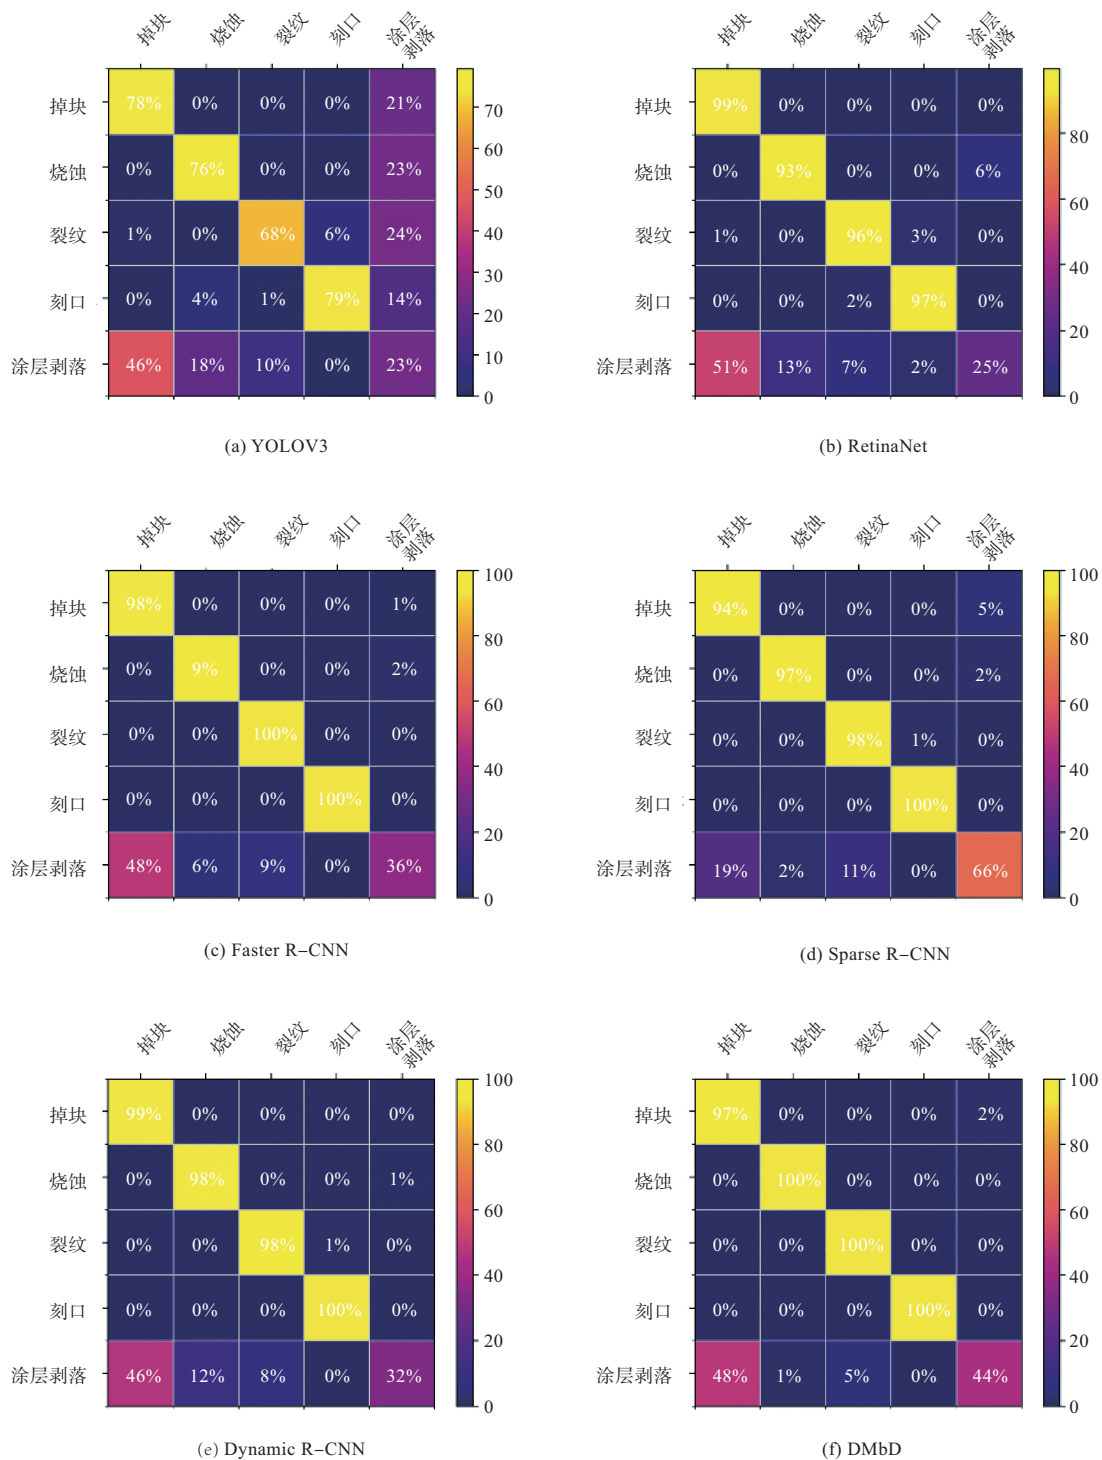


图9 不同方法的混淆矩阵

Fig.9 The confusion matrix of different methods

[12] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers [C]. European Conference on Computer Vision, 2020: 213-229.

[13] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,

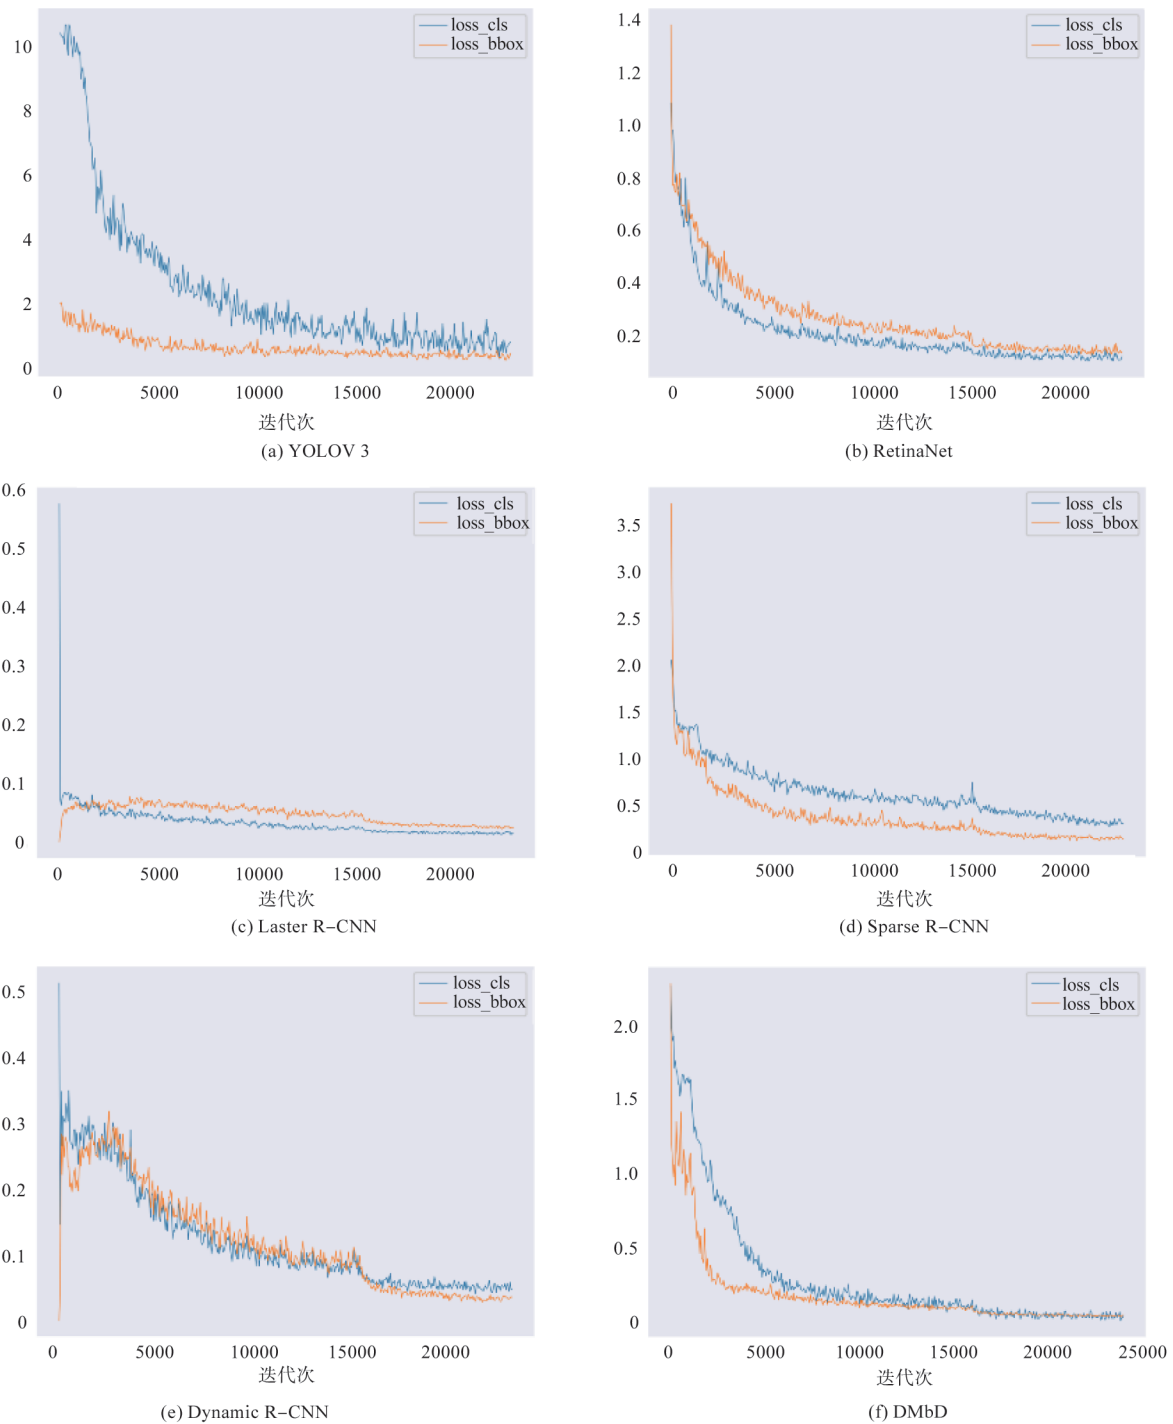


图10 不同方法的损失函数曲线

Fig.10 The loss function curve of different methods

2016: 770-778.

- [14] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models [J]. Advances in Neural Information Processing Systems, 2020, 33: 6840-6851.

- [15] Girshick R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.

- [16] Zhang Hongkai, Chang Hong, Ma Bingpeng, et al. Dynamic R-

- CNN: Towards high quality object detection via dynamic training [C]. Computer Vision ECCV 2020: 16th European Conference, 2020: 260-275.
- [17] Redmon J, Farhadi A. YOLOV3: An incremental improvement [J]. arXiv preprint arXiv:1804.02767, 2018.
- [18] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [19] Chen Kai, Wang Jiaqi, Pang Jiangmiao, et al. MMDetection: Open mmlab detection toolbox and benchmark [J]. arXiv preprint arXiv:1906.07155, 2019.

Diffusion Model-Based Intelligent Damage Detection of Aero-Engine Blade

Shang Hongbing, Yang Qixiu, Sun Chuang, Wang Shibin

National Key Lab of Aerospace Power System and Plasma Technology, Xi'an Jiaotong University, Xi'an 710049, China

Abstract: As an important component of turboshaft and turboprop engines, accurate, fast and reliable damage detection of high-speed rotating multi-layer array blades is of great significance to ensure the safety of aero-engine operation. Aero-engine blade damage is characterized by multiple types and multiple sizes. The traditional borescope inspection method relies on manual experience and visual inspection, which has high labor cost, low inspection efficiency. It is difficult to meet the real-time, high-efficiency and accuracy requirements of the in-situ inspection of aero-engine and maintenance. Existing intelligent detection algorithms usually rely on manually set predefined candidate bounding boxes, which require people to empirically set the number, size, scale and other hyperparameters. Therefore, this paper proposes a diffusion model-based detection (DMbD) method for intelligent damage detection of aero-engine blade, which decomposes the damage detection task into two parts: image feature extraction and damage detection and assessment, where the image feature extraction network uses the residual module to extract feature representations from the input image, and the damage detection and assessment network utilizes the diffusion process to take the noisy boxes as inputs and predict the damage categories and coordinates. Therefore, the network realizes the generation of object boxes directly from the noise candidate boxes and uses them for damage classification and localization, without the need to manually set the parameters of the predefined candidate boxes. DMbD method is applied to aero-engine blade image for damage detection and evaluation, and the experimental results show that this method can quickly and accurately recognize aero-engine blade damage, and the mean average precision (mAP) is 0.988. Compared with traditional methods and existing intelligent methods, the proposed model avoids the manual setting of bounding boxes, and can predict bounding boxes from noise distribution to achieve intelligent damage detection of aero-engine blade.

Key Words: aero-engine blade; damage detection; diffusion model; borescope inspection

Received: 2024-06-17; **Revised:** 2024-10-15; **Accepted:** 2024-12-18

Foundation item: Aeronautical Science Foundation of China (20200046070002)