

doi: 10.11823/j.issn.1674-5795.2025.01.07

基于改进 Mask R-CNN 的航空发动机保险丝实例分割方法

张凤飞, 孙军华*

(北京航空航天大学 仪器科学与光电工程学院, 北京 100191)

摘要: 针对成像背景复杂、光照不均、目标区域占比小等因素导致的航空发动机保险丝识别精度低的问题, 提出一种改进的基于掩模区域的卷积神经网络(Mask Region-based Convolutional Neural Network, Mask R-CNN)保险丝实例分割模型。首先分别对保险丝图像的 R、G、B 三个通道进行不同程度的伽马校正, 转化得到伪彩色图像, 同时增强对比度; 然后, 针对保险丝的细长曲线几何特征, 将动态蛇形卷积融入 Mask R-CNN 的骨干网络 Resnet 中, 使得网络在特征提取时自适应地聚焦细长弯曲的局部结构; 最后在特征融合阶段引入卷积注意力模块(Convolution Block Attention Module, CBAM), 保留小目标浅层特征, 从而提高网络对小目标的感知能力。实验结果表明, 改进后的模型掩码 A_{AP50} 达到了 82.54%, 较基础模型提升了 5.83%, 为航空发动机保险丝数字化、智能化检测提供了有力支撑。

关键词: 航空发动机保险丝; 基于掩模区域的卷积神经网络; 实例分割; 动态蛇形卷积; 特征提取; 卷积注意力模块; 深度学习

中图分类号: TB9; V232; TM563 文献标志码: A 文章编号: 1674-5795 (2025) 01-0096-09

Aero-engine lockwire instance segmentation method based on improved Mask R-CNN

ZHANG Fengfei, SUN Junhua*

(School of Instrument Science and Opto-electronics Engineering,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: In order to solve the problem of low recognition accuracy of aero-engine lockwire caused by factors of the complex background, uneven illumination and small percentage of the target region, this paper proposes an improved mask region-based convolutional neural network (Mask R-CNN) model for lockwire instance segmentation. Firstly, the gamma corrections of R, G and B channels with different degrees were carried out to transform the lockwire image into pseudo-color image and enhance the contrast. Then, the dynamic snake-shaped convolution was incorporated into Resnet, the backbone network of Mask R-CNN, to make the network to adaptively focus on the slender and curved local structure during feature extraction. Then, based on the geometric features of the fuse's slender curve, dynamic snake convolution was integrated into the backbone network Resnet of Mask R-CNN, allowing the network to adaptively focus on the local

收稿日期: 2024-12-01; 修回日期: 2024-12-05

基金项目: 中国航空发动机集团产学研合作项目(HFZL2022CX020)

引用格式: 张凤飞, 孙军华. 基于改进 Mask R-CNN 的航空发动机保险丝实例分割方法[J]. 计测技术, 2025, 45(1): 96-104.

Citation: ZHANG F F, SUN J H. Aero-engine lockwire instance segmentation method based on improved Mask R-CNN[J]. Metrology & Measurement Technology, 2025, 45(1): 96-104.



structure of the slender curve during feature extraction. Finally, the CBAM attention mechanism was introduced in the feature fusion phase to retain the shallow features of small target, so as to improve the perception ability of the network on small target. The experimental results showed that the A_{AP50} of the improved module mask reached 82.54%, which was improved by 5.83% compared to basic mode. This study provides strong support for digital and intelligent detection of aero-engine lockwire.

Key words: aero-engine lockwire; Mask R-CNN; instance segmentation; dynamic snake-shaped convolution; feature extraction; CBAM; deep learning

0 引言

保险丝是航空发动机的机械防松装置,正确装配保险丝能够有效防止紧固件松动,对于保障航空发动机的可靠连接和运行安全至关重要^[1]。航空发动机局部保险丝图像如图1所示。由于航空发动机装配工艺复杂^[2],零件数量众多,保险丝漏装、错装时有发生,保险丝自动检测是航空制造业的重点研究方向。

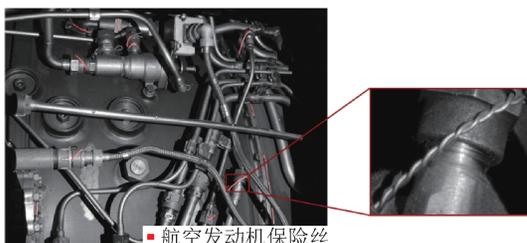


图1 航空发动机局部保险丝图像

Fig.1 Aero-engine local lockwire image

目前,航空制造业针对保险丝的检测主要采用人工目视方法,存在检测效率低、标准不一致、易出现漏检和误检等情况,无法满足航空发动机的高可靠性需求^[3]。利用图像处理技术实现保险丝自动化检测具有重要意义。

传统的图像分割方法如阈值分割^[4]、区域生长法^[5]、边缘分割^[6]、K-Means^[7]聚类等在许多场合取得了良好的应用效果。然而,航空发动机保险丝图像成像场景复杂、背景与目标灰度相近且保险丝内部灰度差异大,采用传统的分割算法难以获得理想的分割结果。

近年来,随着计算机硬件的发展与深度学习的兴起,基于卷积神经网络的目标分割算法受到了研究人员的广泛关注^[8]。其中,实例分割作为一种能够同时完成检测、分类和分割的多任务架构

网络,已被广泛应用于工业视觉、遥感监测等领域^[9]。目前,实例分割方法主要包括双阶段方法及单阶段方法两大类。典型的双阶段方法包括Mask R-CNN^[10]、RefineMask^[11]、Mask-Transfuser^[12]等;典型的单阶段方法包括YOLACT^[13]、YOLACT++^[14]、TensorMask^[15]等。WU J等人^[16]将注意力机制与改进特征融合网络融入YOLACT模型,实现了绝缘子缺陷的精确提取。XU Y等人^[17]提出了改进的Mask R-CNN算法,该算法在隧道表面缺陷检测中展现出良好的预测性能。

与传统方法相比,深度学习模型能够更好地应对图像中的光照、角度和尺度变化等因素,在复杂场景下具有更高的鲁棒性^[18]。但基于卷积神经网络的目标分割方法依赖于大数据训练,而航空发动机保险丝检测样本量少,不存在公开可用的数据集。此外,航空发动机保险丝体积小、图像像素占比小,采用卷积和池化等操作捕获图像中的高级语义特征时,图像及特征的分辨率逐渐降低,图像中的小目标信息易丢失,极易造成保险丝漏检、误检。

针对上述问题,本文提出基于改进Mask R-CNN的航空发动机保险丝实例分割方法。通过混合随机数据增强对保险丝数据集进行扩充,解决样本数量匮乏问题;分别对保险丝图像的R、G、B通道进行不同程度的伽马校正,增强图像对比度;针对保险丝细长且不规则的特性,引入动态蛇形卷积(Dynamic Snake Convolution, DSConv)^[19],通过自适应地关注细长弯曲的局部结构,加强对保险丝的特征提取能力;引入CBAM^[20],在提升小目标特征保留的同时达到选择性地抑制背景的目的。开展AL31F航空发动机保险丝检测实验,对基于改进Mask R-CNN的航空发动机保险丝分割方法的应用效果进行验证。

1 Mask R-CNN

1.1 Mask R-CNN 模型结构

Mask R-CNN^[10]是一个通用的实例分割架构，该网络在Faster R-CNN的基础上增加了一个Mask预测分支，同时具备目标检测与语义分割功能，在工业检测、自动驾驶、医疗影像分析、遥感图像翻译等领域展现出卓越的性能。选择Mask R-CNN作为基本模型，其模型结构如图2所示，主要包括主干网络(backbone)、区域建议网络(Region Proposal Network, RPN)和ROI Align部分。

主干网络由Resnet和特征金字塔网络(Feature Pyramid Network, FPN)共同构成，其中Resnet网络采用了残差学习机制和特殊的网格结构，通过对原图像进行卷积和池化，得到5个阶段的特征图；FPN通过自顶向下进行上采样及横向连接将各个层级的特征图进行融合，使其同时具有强语义信息和空间信息；RPN在特征图上生成先验的候选区域，并对这些区域进行类别预测和边框回归；ROI Align将候选区域映射到特征图上，取消量化操作，使用双线性内插方法计算像素值，提取固定大小的特征块作为全连接层和全卷积网络的输入，最终输出每个目标的类别、边界框以及对应的分割掩码。

1.2 损失函数

Mask R-CNN训练期间，对每个感兴趣区域定义一个多任务损失函数 L ，即

$$L = L_{cls} + L_{box} + L_{mask} \tag{1}$$

式中： L_{cls} 为分类损失，采用交叉熵损失进行计算； L_{box} 为回归框损失，采用平滑 L_1 损失进行计算，该损失函数结合了绝对值损失和平方损失，有助于

模型收敛和防止梯度爆炸； L_{mask} 为掩码损失，采用二元交叉熵损失衡量每个像素预测值与真实值之间的差异。

2 改进Mask R-CNN

2.1 Gamma校正图像预处理

航空发动机保险丝图像存在光照不均导致的一些细节偏亮或偏暗、对比度低等问题，通过Gamma校正可以调节这些区域的亮度，增强图像的整体视觉效果。计算公式为

$$V_{out} = AV_{in}^\gamma \tag{2}$$

式中： A 为常量， V_{in} 为输入图像， V_{out} 为输出图像， γ 为伽马系数。使用不同的 γ 将产生不同的增强效果。

航空发动机保险丝图像为灰度图像，通常表现出单一的亮度信息。在训练过程中，读入图像时，分别对R、G、B通道进行 γ 为1.2、1.0、0.8的Gamma校正，独立地调整每个通道的亮度关系，转化得到伪彩色图像，从而有效改善图像的对比度、色彩平衡和细节表现，更好地适应深度学习任务。

2.2 动态蛇形卷积

航空发动机保险丝图像背景复杂，保险丝呈现出细长弯曲的不规则管状结构，然而传统的卷积核形状固定，很大程度上限制了卷积操作的特征提取能力。

针对此问题，在Mask R-CNN主干网络的Resnet中引入DSCConv，动态地调整卷积核的形状和大小，以适应保险丝的几何形状特征。DSCConv作用示意图如图3所示。

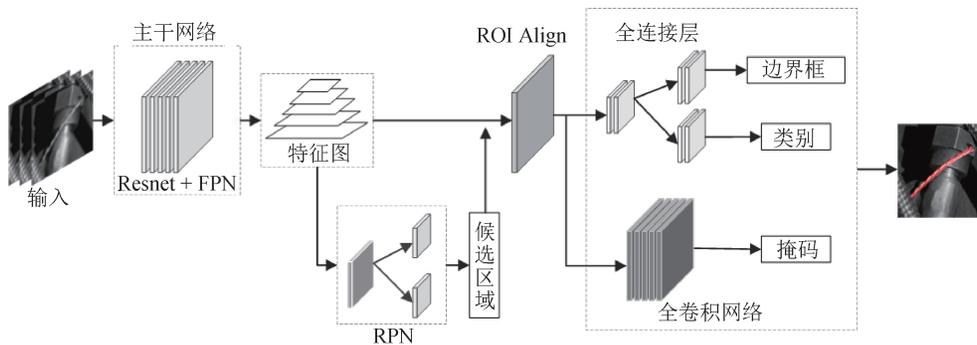


图2 Mask R-CNN 模型结构

Fig.2 Structure of Mask R-CNN model

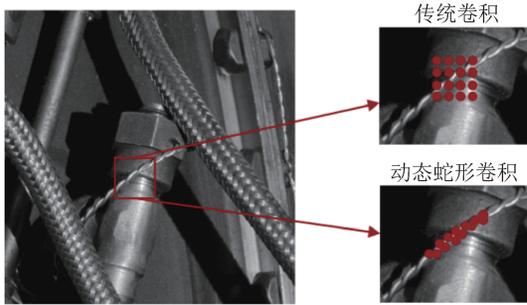


图3 DSConv作用示意图

Fig.3 Illustration of the effect of DSConv

2.2.1 DSConv

DSConv^[19]通过引入变形偏移动态地调整卷积核, 采用迭代策略依次对目标的下一个位置进行预测, 从而保持注意力的连续性, 避免产生相对较大的偏移量, 使得网络能够自适应地聚焦细长弯曲的局部特征。

在DSConv中, 卷积核在X轴和Y轴方向均进行了线性化。如图4所示, 以3×3卷积核的X轴方向为例, 每个网格位置 $K_{i±c}$ 的选择是一个累积过程。从中心位置 K_i 开始, 每一个网格的移动均以前一个位置为基准, K_{i+1} 相对 K_i 增加了偏移量 $\Delta = \{\delta | \delta \in [-1, 1]\}$ 。偏移累加操作使得变形后的卷积核符合线性形态结构。

偏移量学习过程中, X轴方向的变化为

$$K_{i±c} = \begin{cases} (x_{i+c}, y_{i+c}) = (x_i + c, y_i + \sum_{i}^{i+c} \Delta y) \\ (x_{i-c}, y_{i-c}) = (x_i - c, y_i + \sum_{i-c}^i \Delta y) \end{cases} \quad (3)$$

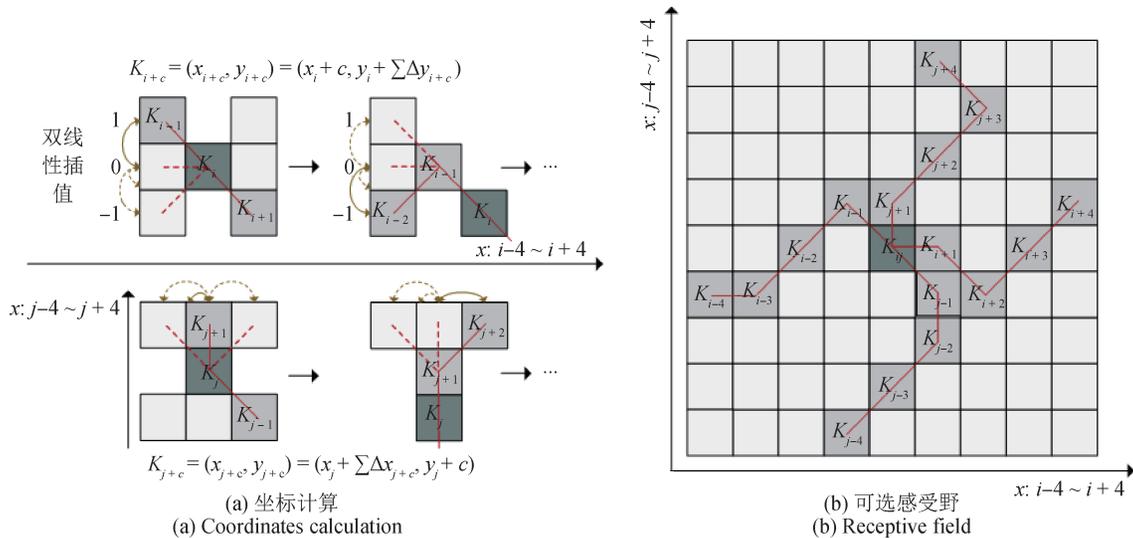


图4 DSConv原理示意图

Fig.4 Illustration of the principle of DSConv

式中: $K_{i±c}$ 为X轴的坐标位置; c 为坐标点与网格中心的水平距离, $c = 0, 1, 2, 3, 4$; Δy 为Y轴的偏移量。

Y轴方向的变化为

$$K_{j±c} = \begin{cases} (x_{j+c}, y_{j+c}) = (x_j + \sum_{j}^{j+c} \Delta x, y_j + c) \\ (x_{j-c}, y_{j-c}) = (x_j + \sum_{j-c}^j \Delta x, y_j - c) \end{cases} \quad (4)$$

式中: $K_{j±c}$ 为Y轴的坐标位置; c 为坐标点与网格中心的垂直距离, $c = 0, 1, 2, 3, 4$; Δx 为X轴的偏移量。

偏移量 Δ 通常为小数, 而坐标通常是整数, 因此采用双线性插值进行计算, 即

$$K = \sum_{K'} B(K', K) \cdot K' \quad (5)$$

式中: K 为卷积网格中的坐标, 为小数; K' 为原卷积核中各元素的整数位置; B 为双线性插值核, 可分解为两个一维核, 即

$$B(K', K) = b(K_x, K'_x) \cdot b(K_y, K'_y) \quad (6)$$

式中: K_x 为 K 分解到X轴上的坐标分量, K_y 为 K 分解到Y轴上的坐标分量, K'_x 为 K' 分解到X轴上的坐标分量, K'_y 为 K' 分解到Y轴上的坐标分量, b 为一维核。

如图4(b)所示, DSConv中卷积核经变形后最终获得了9×9的感受野。

2.2.2 Resnet改进

Resnet包含5个阶段, 即Stage1~Stage5。如图5所示, 为了使DSConv发挥更好的效果, 构建

动态蛇形卷积块, 在 Stage4、Stage5 引入动态蛇形卷积, 提升特征提取网络灵活性的同时更精确地匹配细长弯曲结构, 从而准确地捕捉保险丝关键特征, 提升模型的泛化能力。

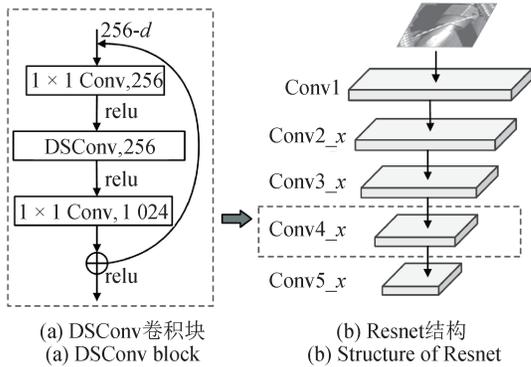


图5 改进 Resnet

Fig.5 Improved Resnet

2.3 CBAM 注意力机制

航空发动机保险丝体积小, 图像像素占比小, 极易淹没在复杂背景中。而在深度卷积神经网络中, 随着网络的深入, 尺度较小的目标经过多次卷积和池化操作后, 细节信息可能在下采样过程中丢失, 导致难以准确检测。针对此问题, 在特征融合过程中引入 CBAM 注意力模块, 使网络更好地保留小目标的浅层语义特征, 提升航空发动机保险丝检测效果。

2.3.1 CBAM

CBAM^[20]是一种轻量级的前馈卷积注意力模块, 通过引入通道和空间两种不同的注意力机制, 使模型能够自适应地调整特征图的权重, 着重关注目标区域的特征信息, 同时抑制无效特征, 以适应不同的任务和场景。

CBAM 的整体结构如图 6 所示, 输入特征经过通道注意力模块(Channel Attention Module, CAM)后, 与原特征图相乘, 得到中间特征图, 再经过

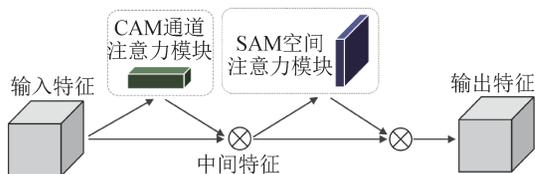


图6 CBAM 整体结构示意图

Fig.6 The overview of CBAM

空间注意力模块(Spatial Attention Module, SAM)并与中间特征相乘, 得到输出特征图。计算公式为

$$F' = M_c(F) \otimes F \quad (7)$$

$$F'' = M_s(F') \otimes F' \quad (8)$$

式中: F 为输入特征, $F \in R^{C \times H \times W}$; M_c 为 CAM 一维卷积, $M_c \in R^{C \times 1 \times 1}$; F' 为中间特征, $F' \in R^{C \times H \times W}$; M_s 为 SAM 二维卷积, $M_s \in R^{1 \times H \times W}$; \otimes 为逐元素相乘符号; F'' 为输出特征, $F'' \in R^{C \times H \times W}$ 。

CAM 模块的网络结构如图 7 所示, 输入特征图经过两个并行的最大池化层(Max Pool)和全局池化层(Avg Pool)压缩为 $C \times 1 \times 1$ 大小; 然后输入到双层共享感知机(Share MLP)模块, 该模块首先将通道数压缩为原来的 $1/r$, 再扩张到原通道数, 并利用 ReLU 激活函数得到两个特征图, 最后进行逐元素相加, 再通过 sigmoid 激活函数得到 CAM 的输出特征图并生成权重系数 M_c 。计算公式为

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \\ = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (9)$$

式中: σ 为 sigmoid 激活函数, MLP 为双层共享感知机运算符, AvgPool 为全局池化层运算符, MaxPool 为最大池化层运算符, W_1 、 W_0 为错层感知机权重, F_{avg}^c 、 F_{max}^c 为池化特征图。

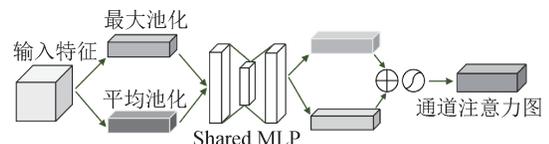


图7 CBAM 的通道注意力模块

Fig.7 CAM of the CBAM

SAM 模块的网络结构如图 8 所示, 将 CAM 的输出结果进行最大池化和平均池化, 得到两个大小为 $1 \times H \times W$ 的特征图; 利用 Concat 对两个特征图进行拼接, 并进行 7×7 卷积操作, 使其通道数降为 1; 最后利用 sigmoid 激活函数得到 SAM 模块

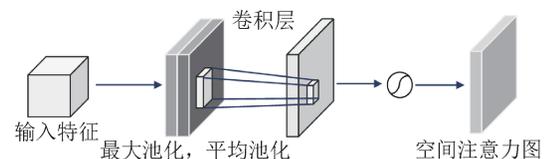


图8 CBAM 的空间注意力模块

Fig.8 SAM of the CBAM

的输出特征图，并生成权重系数 M_s 。计算公式为

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) \quad (10)$$

$$= \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s]))$$

式中： $f^{7 \times 7}$ 为 7×7 卷积， F_{avg}^s 、 F_{max}^s 为池化特征图。

2.3.2 FPN 改进

Mask R-CNN 采用 FPN 进行特征融合，该结构结合自底向上、自顶向下、横向连接方法，将浅层分辨率高的语义信息和深层分辨率低的语义信息进行融合^[21]。保险丝目标小，特征信息从最底层传输到顶层的过程中容易丢失，因此在 FPN 自顶向下采样过程中加入 CBAM 注意力机制，使网络更好地聚焦于小目标，增强保险丝区域的特征表达，同时抑制背景特征，提高保险丝分割质量。改进 FPN 如图 9 所示。

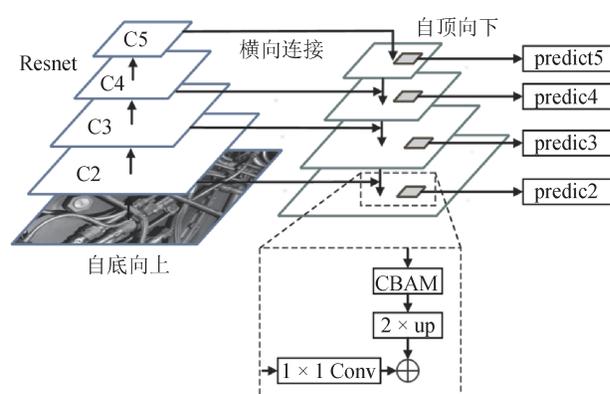


图9 改进 FPN

Fig.9 Improved FPN

3 实验及分析

3.1 实验环境与评价指标

实验环境详细信息见表 1。训练过程中迭代次数设置为 90 000，初始学习率为 0.001，batchsize 设为 16。

为了评估改进 Mask R-CNN 模型在航空发动机保险丝实例分割任务中的性能，采用交并比 (Intersection Over Union, IOU) 阈值为 0.5 时的平均精度 (Average Precision, AP) A_{AP50} 作为模型检测的评价指标， A_{AP50} 计算公式为

$$A_{\text{AP50}} = \int_0^1 p(r) dr \quad (11)$$

式中： p 为准确率， r 为召回率。

表 1 实验环境

Tab.1 Experimental environment	
名称	配置
操作系统	Ubuntu 20.04
CPU	Intel Xeon Sliver 4310 CPU @ 2.10 GHz
GPU	NVIDIA RTX A5000
显存	24 GB
编程语言	Python 3.9
开发环境	Pytorch 1.10.1 + CUDA11.3

3.2 实验数据集

为构建航空发动机保险丝数据集，采用分辨率为 4 096 × 3 000 的摄像机，以北京航空航天大学航空博物馆中陈列的 AL31F 航空发动机保险丝作为目标对象，采集航空发动机局部图像共 172 张。然后，利用图像标注工具 LabelMe 对图像中保险丝区域进行标注，将标注数据以 json 文件格式进行存储。

为了提高模型的泛化性能，克服数据匮乏产生的过拟合问题，采用混合数据增强方式对采集的图像进行扩增，包括随机平移、翻转、旋转、拉伸等几何变换方式以及随机调整亮度、对比度、噪声等像素变换方式，每个生成的图像至少采用了一种有效的数据增强方法，如图 10 所示。扩增后进一步筛选相似度过高的图像，最终保留 1 187 张图像。最后将图像和标签文件转化为 COCO 数据集格式，并按照 8 : 1 : 1 的比例随机划分为训练集、验证集和测试集。

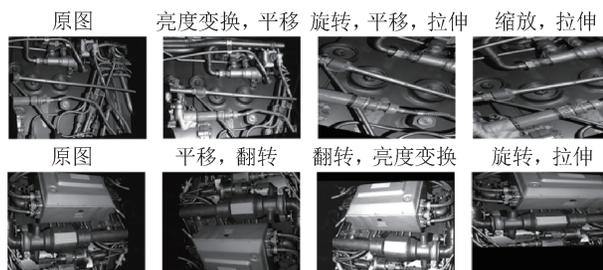


图 10 数据增强示例

Fig.10 Example of data enhancement

3.3 实验结果分析

3.3.1 消融实验

为了验证改进模块的提升效果，依次在基线

模型的基础上对改进模块进行消融实验, 结果见表2。采用分通道的Gamma变换后, 掩码 A_{AP50} 较基线模型提升了2.23%。在此基础上, 引入动态蛇形卷积后, A_{AP50} 较基线模型提升了3.31%; 将CBAM注意力模块融入FPN, 可使 A_{AP50} 较基线模型提升4.20%。本文改进的模型掩码 A_{AP50} 较基线模型提升了5.83%。实验结果表明: 所采用的改进模块能够有效提升保险丝的分割精度。

表2 消融实验结果

Tab.2 Results of ablation experiments

模型	Mask R-CNN	Gamma	DSCConv	CBAM	$A_{AP50}/\%$
1	√				76.71
2	√	√			78.94
3	√	√	√		80.02
4	√	√		√	80.91
5	√	√	√	√	82.54

3.3.2 对比实验

为了进一步验证改进网络在航空发动机保险丝分割任务中的优越性, 将改进Mask R-CNN模型与经典实例分割模型SOLOv2进行比较, 结果见表3。

表3 对比实验结果

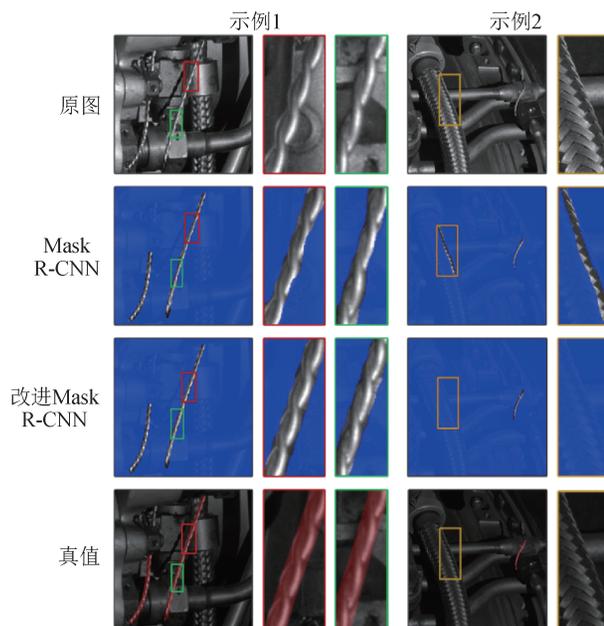
Tab.3 Results of contrast experiments

模型	$A_{AP50}/\%$
Mask R-CNN	76.71
SOLOv2	69.80
改进Mask R-CNN	82.54

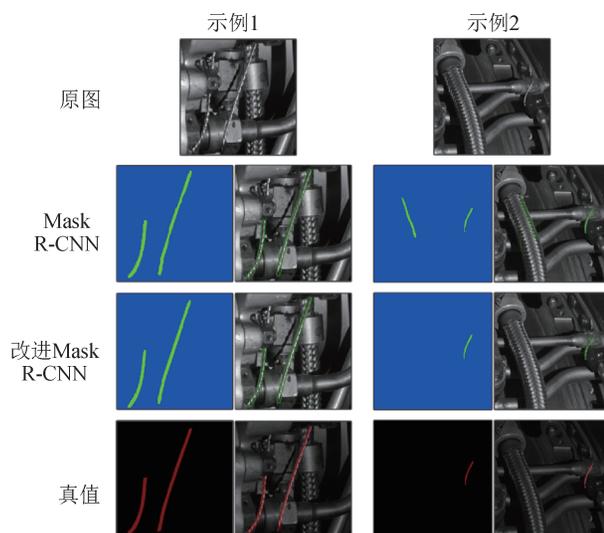
SOLOv2的 A_{AP50} 为69.80%, 所选基础模型的 A_{AP50} 高于SOLOv2模型, 在保险丝分割任务中更有优势。改进Mask R-CNN的 A_{AP50} 较SOLOv2高了12.74%, 能够更准确地进行保险丝分割。

3.3.3 可视化结果

分别采用改进Mask R-CNN模型与原始模型进行训练、验证及测试, 图11为保险丝测试结果的局部放大图像。在示例1中, 原模型的检测结果存在局部不完整、边缘缺失现象, 改进Mask R-CNN



(a) 分割结果对比示意图
(a) Comparison of segmentation results



(b) 边界框及掩码对比示意图
(b) Comparison of boundary boxes and masks

图11 测试结果局部放大图像

Fig.11 Partially enlarged image of test results

模型能够准确地分割出完整的保险丝区域且边缘保持完好。

在示例2中, 原始模型错误地将航空发动机电缆区域识别为保险丝, 而改进的Mask R-CNN模型能够正确识别区分。

对比实验表明, 改进的Mask R-CNN模型能够更准确地识别复杂环境下的保险丝, 在保持保险丝结构与边缘的完整性与连续性方面表现出了更卓越的性能, 有效提升了分割精度。

4 结论

为实现航空发动机保险丝的准确分割, 本文将动态蛇形卷积和CBAM融入Mask R-CNN的特征提取网络中, 使得网络自适应地聚焦保险丝细长弯曲的结构, 并增强对小目标的关注。实验表明, 改进的Mask R-CNN模型在航空发动机保险丝实例分割任务中表现出了较好的稳健型, 平均精度相较基础模型提升了5.83%, 有效地减少了保险丝漏检、误检现象, 有利于航空制造业向智能化、自动化发展, 对于航空发动机的安全可靠运行具有重要意义。

参考文献

- [1] 刘锦秋. 某航空发动机小零件故障分析与修理[J]. 价值工程, 2018, 37(2): 100-102.
- LIU J Q. Fault analysis and repair of small parts of an aero-engine[J]. Value Engineering, 2018, 37(2): 100-102. (in Chinese)
- [2] WANG X, LU J, CHEN R, et al. Research on design and planning of pulsating aero-engine assembly line based on plant simulation[C]// 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Chongqing, China, IEEE, 2020: 591-595.
- [3] AUST J, PONS D. Comparative analysis of human operators and advanced technologies in the visual inspection of aero engine blades[J]. Applied Sciences-Basel, 2022, 12(4). DOI: 10.3390/app12042250.
- [4] LEI Q, ZHONG J, WANG C. Joint optimization of crack segmentation with an adaptive dynamic threshold module[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(7): 6902-6916.
- [5] LIAO D, YANG J, LIAO X, et al. Detection method of Si_3N_4 bearing rollers point microcrack defects based on adaptive region growing segmentation[J]. Measurement, 2024, 235. DOI: 10.1016/j.measurement.2024.114958.
- [6] CHEN Z, XU T, PAN Y, et al. Edge feature enhancement for fine-grained segmentation of remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1-13.
- [7] KHAN Z, YANG J. Nonparametric K-means clustering-based adaptive unsupervised colour image segmentation[J]. Pattern Analysis and Applications, 2024, 27(1). DOI: 10.1007/s10044-024-01228-5.
- [8] YANG B, ZHU X, LIU Y, et al. Bridge the spatial semantic gap: multiattention shape adaptive network for infrared target segmentation[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-14.
- [9] GUI S, SONG S, QIN R, et al. Remote sensing object detection in the deep learning era — a review[J]. Remote Sensing, 2024, 16(2). DOI: 10.3390/rs16020327.
- [10] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]// 2017 IEEE International Conference on Computer Vision (ICCV). Venice, IEEE, 2017: 2980-2988.
- [11] ZHANG G, LU X, TAN J, et al. RefineMask: towards high-quality instance segmentation with fine-grained features[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA, IEEE, 2021: 2061-2069.
- [12] KE L, DANELLJAN M, LI X, et al. Mask transfiner for high-quality instance segmentation[C]// 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA, USA, IEEE, 2022: 4402-4411.
- [13] BOLYA D, ZHOU C, XIAO F, et al. YOLACT: real-time instance segmentation[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South), IEEE, 2019: 9156-9165.
- [14] BOLYA D, ZHOU C, XIAO F, et al. YOLACT++ better real-time instance segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(2): 1108-1121.
- [15] CHEN X, GIRSHICK R, HE K, et al. TensorMask: a foundation for dense object segmentation[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South), IEEE, 2019: 2061-2069.
- [16] WU J, DENG Q, XIAN R, et al. An instance segmentation method for insulator defects based on an attention mechanism and feature fusion network[J]. Applied Sciences, 2024, 14(9). DOI: 10.3390/app14093623.
- [17] XU Y, LI D, XIE Q, et al. Automatic defect detection and segmentation of tunnel surface using modified Mask R-CNN[J]. Measurement, 2021, 178. DOI: 10.1016/j.measurement.2021.109316.
- [18] CHENG Y, LAI X, XIA Y, et al. Infrared dim small tar-

- get detection networks: a review [J]. *Sensors*, 2024, 24 (12). DOI: 10.3390/s24123885.
- [19] QI Y, HE Y, QI X, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation [C]// 2023 IEEE/ CVF International Conference on Computer Vision (ICCV). Paris, France, IEEE, 2023: 6047–6056.
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C]// 15th European Conference on Computer Vision (ECCV). Munich, Cham, Springer International Publishing, 2018: 3–19.
- [21] ZHU M, HAN K, YU C. Dynamic feature pyramid networks for object detection [J]. *Pattern Recognition*, 2021, 10(79): 236–242.

(本文编辑: 刘圣晨)



第一作者: 张凤飞(2000—), 女, 硕士研究生, 主要研究方向为图像处理、视觉检测。



通信作者: 孙军华(1975—), 男, 教授, 主要研究方向为双目视觉、结构光视觉、图像处理、三维点云分析。