

智能光学感知的航空紧固件旋转目标检测方法研究与应用

董玮¹ 丛立国¹ 付永亮¹ 鲁鹏¹ 李琨¹ 董晨曦²

1.中国第一汽车股份有限公司；2.河南航天精工制造有限公司

DOI: 10.12238/jpm.v5i10.7332

[摘要] 本文针对航空紧固件检测的工业需求，提出了一种轻量级的旋转目标检测方法——OLAFDet (Orientation-Aware Lightweight Aviation Fastener Detection method)。该方法通过构建基于强化语义和优化空间的特征融合机制，有效缓解了深层次特征融合时的信息差异问题，并通过空洞幻影模块减少了特征融合网络的参数量。为了解决水平检测方法在密集场景下的漏检和缺乏目标角度信息的问题，本文采用了高斯类环形平滑标签方法，将检测框角度的回归问题转化为分类问题，增加了180个角度类别预测。实验结果表明，OLAFDet在权威公开旋转数据集DOTA上的检测精度优于现有方法，且模型大小仅为18MB，适合边缘部署。在航空紧固件检测任务中，该方法实现了99.76%的mAP，检测速度超过20FPS，满足了工业应用的高精度与实时性要求。

[关键词] 航空紧固件检测；旋转目标检测；特征融合；空洞幻影模块；高斯类环形平滑标签；边缘智能

Research and application of intelligent optical sensing method for aerospace fastener rotating target detection

Dong wei¹ Cong liguo¹ Fu yongliang¹ Lu peng¹ Li kun¹ Dong chenxi²

1.Engineering and technology department, China FAW Corporation Limited;

2.Henan Aerospace Precision Maching Co., Ltd

[Abstract] In this paper, an Orientation-Aware Lightweight Aviation Fastener Detection method (OLAFDet) is proposed to meet the industrial requirements of aviation fastener detection. By constructing a feature fusion mechanism based on enhanced semantics and optimized space, this method effectively alleviates the problem of information difference in deep and shallow feature fusion, and reduces the number of parameters in feature fusion network by using a hollow phantom module. In order to solve the problem of missing detection and lack of target Angle information of level detection method in dense scenes, this paper adopts Gaussian class ring smooth label method, transforms the regression problem of detection frame Angle into classification problem, and adds 180 Angle category prediction. The experimental results show that OLAFDet has better detection accuracy than existing methods on the authoritative open rotation data set DOTA, and the model size is only 18MB, which is suitable for edge deployment. In the aviation fastener inspection task, the method achieves 99.76% mAP, and the detection speed exceeds 20 FPS, which meets the high precision and real-time requirements of industrial applications.

[Key words] aviation fastener testing; Rotating target detection; Feature fusion; Hollow phantom module; Gauss-type ring smooth label; Edge intelligence

1 引言

在现代航空制造业中，紧固件作为连接和固定飞机结构的关键部件，其质量和可靠性直接关系到飞机的安全性和性能。因此，对航空紧固件的精确检测是确保飞机制造质量的重要环节。传统的紧固件检测方法依赖于人工视觉检查，不仅效率低下，而且容易受到人为因素的影响，难以满足现代工业自动化和智能化的需求。随着深度学习技术的发展，基于计算机视觉的目标检测技术为航空紧固件的自动化检测提供了新的解决方案。现有的目标检测方法大多针对水平目标设计，难以直接应用于形状各异、角度多变的航空紧固件检测。特别是在密集场景下，水平检测方法容易出现漏检，且无法提供紧固件的精确角度信息，这对于后续的自动抓取和分拣工作至关重要。因此，研究一种能够准确检测旋转目标的方法，对于提升航空紧固件检测的自动化水平具有重要意义。

本文提出了一种基于 YOLOv5 的轻量级航空紧固件旋转检测方法 OLAFDet，通过创新的特征融合机制和空洞幻影模块，实现了对航空紧固件的高精度旋转检测。同时，通过引入高斯

类环形平滑标签方法，将角度回归问题转化为分类问题，进一步提高了检测的准确性和鲁棒性。实验结果表明，OLAFDet 在保证检测速度的同时，显著提升了检测精度，为航空紧固件的自动化检测提供了一种有效的技术手段。

2 实验方法

本文以 YOLOv5 为例，在 PANet 特征融合络基础上，构建基于强化语义和优化空间的特征融合机制，缓解深浅层特征融合时的信息差异问题；为了减少特征融合网络的参数量，设计以更少量卷积运算获得更大感受野特征图的空洞幻影模块；针对水平检测方法具有检测框存在大量背景区域、密集场景下容易漏检以及缺乏目标角度信息等局限性，采用高斯类环形平滑标签方法将检测框角度的回归问题转化为分类问题，对原有预测分支进行改进，增加 180 个角度类别预测以实现航空紧固件的旋转检测。本文提出的轻量级航空紧固件旋转检测方法（orientation-aware lightweight aviation fastener detection method, OLAFDet）如图 1 所示。

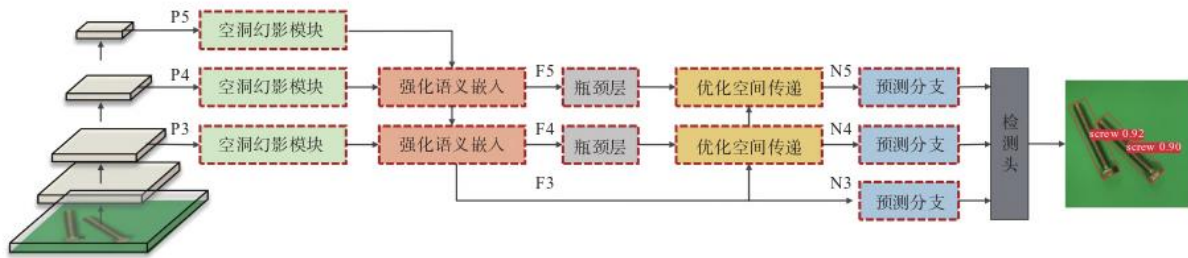


图 1 轻量级航空紧固件旋转检测方法

2.1 基于强化语义和优化空间的特征融合机制

针对简单特征融合方式忽略深浅层特征信息差异问题，本文提出一种基于强化语义和优化空间的特征融合机制，其包含强化语义信息嵌入模块和优化空间信息传递模块，分别减少深浅层特征之间语义信息差异和空间信息差异，提高特征融合性能，从而提升模型检测精度。

首先，在自顶向下特征融合路径中的上采样操作前，增加一个残差模块，其跳跃连接叠加经过不同卷积操作的深层特征，可以减少深浅层特征之间语义信息差异，使得在特征融合过程中，深层特征的语义信息能够更有效地利用逐元素相乘的方式将其嵌入到下一横向连接的浅层特征中，强化了语义信息嵌入的有效性。强化语义信息嵌入模块由 3 部分组成，分别是残差模块、上采样操作、逐元素相乘融合，公式如下：

$$F_i = Upsample(R(P_{i+1})) \otimes P_i$$

Upsample (·) R (·) ⊗ 式中：Fi 表示经过强化语义信息嵌入模块后输出第 i 层特征；代表上采样操作；表示特征经过残差模块的输出；表示逐元素相乘；P 表示经骨干网络输出的特征。同样地，在自底向上特征融合路径中的下采样操作后，增加一个残差模块，其跳跃连接叠加经过不同卷积操作的浅层

特征，可以减少深浅层特征之间空间信息差异，使得在特征融合过程中，浅层特征的空间信息能够更有效地利用逐元素相乘的方式将其传递到上一横向连接的深层特征中，优化了空间信息传递的准确性。优化空间信息传递模块由 3 部分组成，分别是下采样操作、残差模块、逐元素相乘融合，公式如下：

$$N_{i+1} = R(Downsample(F_i)) \otimes F_{i+1}$$

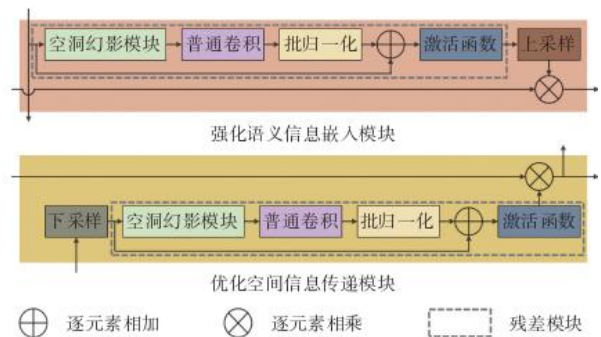


图 2 强化语义与优化空间特征融合机制

Downsample (·) 式中：N 表示经过优化空间信息传递模块后输出的特征；代表下采样操作。强化语义信息嵌入模块和优化空间信息传递模块详细网络结构如图 2 所示。相比 PANet

网络结构,本文的特征融合机制主要创新点有以下 2 点:第一,在深浅层特征融合前,增加了残差模块,通过残差“去掉相同主体部分,突出微小变化”的思想,有助于减少深浅层特征信息差异。第二,采用逐元素相乘的方式融合深浅层特征,有助于丰富深层特征的空间信息以及增强浅层特征的语义性,提升模型检测性能。

2.2 更少卷积运算更大感受野的空洞幻影模块

针对 CNN 目标检测网络对内存和计算资源要求高的问题,韩凯等人指出在深度神经网络中,通常会包含丰富甚至冗余的特征图,以保证对输入数据有全面的理解,因而通过更廉价的

操作生成部分冗余特征图,即可在不损失精度的同时,减少模型的运算量。本文提出一种通过更少卷积运算获得更大感受野特征图的空洞幻影模块,其核心思想是深度可分离空洞卷积可以在降低特征图生成的运算量的同时扩大特征图感受野。具体操作如下:设输入特征图尺寸为 $W \times H \times m$, 输出特征图尺寸为 $W' \times H' \times n$, 首先通过卷积模块得到通道数为 $n/2$ 的本征特征图。将本征特征图作为深度可分离空洞卷积的输入,生成新的具有更大感受野的相似特征图。最后将本征特征图和相似特征图进行拼接,得到最终输出,如图 3 所示。




图 3 空洞幻影模块

对于 3 通道 5×5 特征图,经过 4 个 3×3 卷积核的普通卷积运算量为 $4 \times 3 \times 3 \times 3 = 108$;深度可分离卷积将一个普通卷积分割成了逐深度卷积和逐点卷积。对于上述特征图卷积操作,逐深度卷积运算量为 $3 \times 3 \times 3 = 27$,逐点卷积运算量为 $1 \times 1 \times 3 \times 4 = 12$ 。因此生成相同尺寸特征图,深度可分离卷积的运算量仅是普通卷积的 $(27+12) / 108 \approx 0.36$ 倍。深度可分离空洞卷积是在深度可分离卷积采样中插入 0 值,用以扩张采样分辨率,其优点在于无需池化即可增大感受野。因此本文提出的空洞幻影模块利用深度可分离空洞卷积生成相似特征图,实现通过更

少量卷积运算获得更大感受野的特征图,从而在基本不损失模型精度的情况下,有效降低生成特征图的运算量。利用空洞幻影模块优势,基于跨阶段局部网络 (crossstagepartialnetwork, CSPNet) “丰富梯度组合并减少计算量”思想设计瓶颈层,将输入特征图划分为 2 个部分,使得梯度流通过不同的网络路径传播,最后通过跨阶段层次结构进行合并,其原理如图 4 所示。瓶颈层可有效加强网络特征融合能力,并降低特征融合网络的参数量。




图 4 瓶颈层

2.3 基于高斯类环形平滑标签的旋转检测方法

基于水平框的检测方法难以满足工业场景下航空紧固件的检测需求。本文通过采用高斯类环形平滑标签方法在原有水平预测分支上增加目标角度信息的预测。基于回归的旋转框角度预测存在边界问题,即理想的预测结果可能出现定义范围以外的情况。本文采用长边定义法来定义旋转框角度,该角度是指旋转框长边与 X 轴之间的夹角,角度表示范围是 $(-90^\circ, 90^\circ)$,如图 5 所示。假设候选框此时为 -90° ,而真实框是 60° ,这时候候选框最理想的回归路线是逆时针旋转 30° (因为角度具有周期性, 60° 候选框也可以表示为 -120°),但这样

就超出了 $(-90^\circ, 90^\circ)$ 的范围。所以候选框只能顺时针旋转 150° 回归,导致误差变大,增加回归难度。

为避免以上所提的边界问题,本文通过采用杨学等人解决遥感图像旋转检测问题提出的高斯类环形平滑标签,将角度回归问题离散为分类问题,即在原有水平预测分支上增加 180 个目标角度类别的预测,从而实现航空紧固件的旋转检测,其提出高斯类环形平滑标签 (gaussian-likecircularsmoothlabel, GCSL) 的具体表达式如下:

$$G_{CSL}(x) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, & \theta - \sigma < x < \theta + \sigma \\ 0, & \text{otherwise} \end{cases}$$

式中： x 为预测角度值； θ 为真实角度值； μ 和 σ 均为常数项。（ $\theta - \sigma$ ， $\theta + \sigma$ ）通过设置高斯窗口函数，使得模型可以衡量预测角度值和真实角度值之间的角度距离，即在范围内，越接近真实角度值的预测值的损失值越小。同时，利用窗口函数的周期性，巧妙地解决了角度周期性的问题。例如在角度值范围属于（ -90° ， 90° ）的长边表示法中，GCSL 使得 89° 和 -90° 两个角度值关系变成近邻。综上所述，本文提出的新的轻量级航空紧固件旋转检测方法，由上述设计模块所组成。在进行强化语义和优化空间的特征融合的同时，以更少量卷积运算获得更大感受野特征图，并具有 180 个角度预测的旋转检测，可应用到对准确性、鲁棒性等要求严格的航空紧固件检测工业场景中。

3 实验结果与分析

3.1 评估指标

方法	来源	参数量/ MB	PL/%	BD/%	BR/%	GTF/%	SV/%	LV/%	SH/%	TC/%	BC/%	ST/%	SBF/%	RA/%	HA/%	SP/%	HC/%	mAP/%
FR-O ^[20]	CVPR2018	242	79.42	77.13	17.70	64.05	35.30	38.02	37.16	89.41	69.64	59.28	50.30	52.91	47.89	47.40	46.30	54.13
TOSO ^[21]	ICASSP2020	212	80.17	65.59	39.82	39.95	49.71	65.01	53.58	81.45	44.66	78.51	48.85	56.73	64.40	64.24	36.75	57.92
PloU Loss ^[22]	ECCV2020	-	80.90	69.70	24.10	60.20	38.30	64.40	64.80	90.90	77.20	70.40	46.50	37.10	57.10	61.90	64.00	60.50
Axis Learning ^[23]	RS2020	-	79.53	77.15	38.59	61.15	67.53	70.49	76.30	89.66	79.07	83.53	47.27	61.01	56.28	66.06	36.05	65.98
MARNet ^[24]	IJRS2021	-	88.91	77.91	39.88	71.17	62.79	58.96	66.25	90.87	73.73	79.04	57.57	64.33	62.47	61.64	51.80	67.15
GSDet ^[25]	TIP2021	-	81.12	76.78	40.78	75.89	64.50	58.37	74.21	89.92	79.40	78.83	64.54	63.67	66.04	58.01	52.13	68.28
RADet ^[26]	RS2020	-	79.45	76.99	48.05	65.83	65.46	74.40	68.86	89.70	78.14	74.97	49.92	64.63	66.14	71.58	62.16	69.09
RoI Transformer ^[27]	CVPR2019	273	88.64	78.52	43.44	75.92	68.81	73.68	83.59	90.74	77.27	81.46	58.39	53.54	62.83	58.93	47.67	69.56
BBAVectors ^[28]	WACV2021	276	88.35	79.96	50.69	62.18	78.43	78.98	87.94	90.85	83.58	84.35	54.13	60.24	65.22	64.28	55.70	72.32
SCRDet ^[29]	ICCV2019	427	89.98	80.65	52.09	68.36	68.36	60.32	72.41	90.85	87.94	86.86	65.02	66.68	66.25	68.24	65.21	72.61
GLS-Net ^[30]	RS2020	-	88.65	77.40	51.20	71.03	73.30	72.16	84.68	90.87	80.43	85.38	58.33	62.27	67.58	70.69	60.42	72.96
R3Det ^[6]	AAAI2021	787	88.76	83.09	50.91	67.27	76.23	80.39	86.72	90.78	84.68	83.24	61.98	61.35	66.91	70.63	53.94	73.79
FEDet ^[31]	ICCSE2021	-	89.09	79.87	51.13	70.20	78.42	80.54	87.84	90.86	83.91	85.31	58.33	66.90	67.74	69.74	63.43	74.89
TricubeNet ^[32]	WACV2022	-	88.75	82.12	49.24	72.98	77.64	74.53	84.65	90.81	86.02	85.38	58.69	63.59	73.82	69.67	71.08	75.26
Beyond Bounding-Box ^[33]	CVPR2021	-	89.08	83.20	54.37	66.87	81.23	80.96	87.17	90.21	84.32	86.09	52.34	69.94	75.52	80.76	67.96	76.67
OLAFDet		18	89.28	85.09	48.75	64.65	80.81	84.70	88.09	90.70	86.72	87.41	60.14	67.12	75.02	81.55	67.39	77.16

3.2 实验与评估

为验证本文方法的有效性，在权威公开旋转数据集上进行实验评估。DOTA 是旋转检测领域中最知名、权威的数据集之一，包含 2806 张图像（训练集 1411 张、验证集 458 张、测试集 937 张），其中包含 15 个类别，共 188282 个不同尺度、形状方向各异的实例对象（zoo

本文方法采用 SGD 作为优化器进行训练，初始学习率 learningrate=0.01，权重衰减 weightdecay=0.0005，高斯窗口函数常数项 $\mu=0$ ， $\sigma=2$ ，动量 mome-ntum=0.937，训练轮次。

在目标检测领域，常采用 mAP（meanaverageprecision）对算法性能进行定量评估，其定义如下：

$$mAP = \frac{\sum_{i=1}^c AP_i}{C}$$

式中：AP（averageprecision）为单一类别的平均准确率；C 为检测类别总数；mAP 是多个类别 AP 的平均值，而 AP 就是精度（precision，P）和召回率（recall，R）组成曲线下方的面积，公式如下：

$$P = \frac{TP}{TP + FP}$$

$$R = \frac{TP}{TP + FN}$$

$$AP = \int_0^1 P(r)dr$$

式中：TP 表示预测为正样本，模型真实标签也是正样本；FP 表示预测为正样本，模型真实标签为负样本；FN 为表示预测为负样本，模型真实标签为正样本。

epoch=300。完成训练后，对测试集进行检测，并将检测结果提交到 DOTA 官方服务器进行评测，最后得到本文方法的实验结果。采用 mAP 作为评估模型检测精度的性能指标，权重文件大小作为评估模型参数量的指标，与近年来前沿旋转框检测方法对比实验结果如表 1 所示。

表中“-”表示该方法未公开对应参数。在检测精度上，本文方法优于近年来主流旋转检测方法，并且权重文件大小只有 18MB，仅为 R3Det 方法权重文件大小的 2.28%，在工业场景中进行边缘部署具有极大的轻量化优势。为进一步验证本文方

法中所提及的各个模块对提升模型整体性能的有效性，在 DOTA 数据集上进行消融分析实验，实验结果如表 2 所示。

表 2 消融分析实验结果

检测框类型	基准模型		OLAFDet	
	水平框	旋转框	旋转框	旋转框
高斯类环形平滑标签		√	√	√
强化语义和优化空间			√	√
空洞幻影模块				√
mAP/%	42.32	76.86	77.17	77.16
参数量/MB	14.8	15.8	21.3	18.0

表中“√”表示采用对应模块，基准模型是水平检测方法，因此使用数据集水平框标签进行训练。因为水平检测方法会引入大量背景区域的干扰信息以及密集场景下容易漏检，导致基准模型的 mAP 仅有 42.32%，引入高斯类环形平滑标签后，mAP 提升到 76.86%；使用强化语义和优化空间特征融合模块后 mAP 进一步提升，达到 77.17%，空洞幻影模块在基本不损失模型精

表 3 为航空紧固件检测的测试结果。

类别	螺栓	垫片	螺帽	圆柱销	铆钉	螺钉
AP_s	100.00	100.00	100.00	100.00	100.00	100.00
AP_m	100.00	100.00	98.93	99.99	99.12	100.00
AP	100.00	100.00	99.17	99.99	99.43	100.00
mAP	99.76					

表中：A 凡为单目标场景下的平均准确率；AP，为随机混合散落场景下的平均准确率。从表 3 可以看到，单目标场景下航空紧固件旋转检测 mAP 均达到 100%，且随机混合散落场景下航空紧固件旋转检测 mAP 均在 98% 以上，部分可视化检测结果如图 7 所示。




图 6 典型航空紧固件

度的情况下，降低模型 15.49% 的参数量。综上所述，本文所提出方法及各模块的有效性得到验证。

3.3 航空紧固件旋转检测性能评估及其分析

为进一步验证本文所提方法，需要对航空紧固件旋转检测性能进行评估。本文以 6 款典型航空紧固件为例，即螺栓、垫片、螺帽、圆柱销、铆钉以及螺钉，如图 6 所示，在生产环境中采集共计 1000 张不同尺度、背景各异、包含不同目标数量的航空紧固件图片。通过对航空紧固件图片增加随机噪点、模糊处理、虚化处理等方法扩展到 6000 张。最后，使用 olabelimg 软件对航空紧固件图片进行人工标注旋转框标签，并按 4:1 的比例划分训练集和测试集。

针对模型训练，本文方法采用 SGD 作为优化器，初始学习率 learning_rate=0.01，权重衰减 weight_decay=0.0005，高斯窗口函数常数项=0, =2，动量 momentum=0.937。训练 300 轮次后得到航空紧固件旋转检测模型，在测试集上进行性能评估。

图 7 中，螺帽、圆柱销以及铆钉 3 种小型紧固件在随机混合散落的场景下，因存在多个紧固件堆叠等现象，从而导致少量漏检，故其 mAP 未达到 100%。但值得一提的是，在航空紧固件实际分拣过程中，随着堆叠上方的紧固件被分拣，下方紧固件将能够被正确检测，从而确保航空紧固件分拣任务的完成。

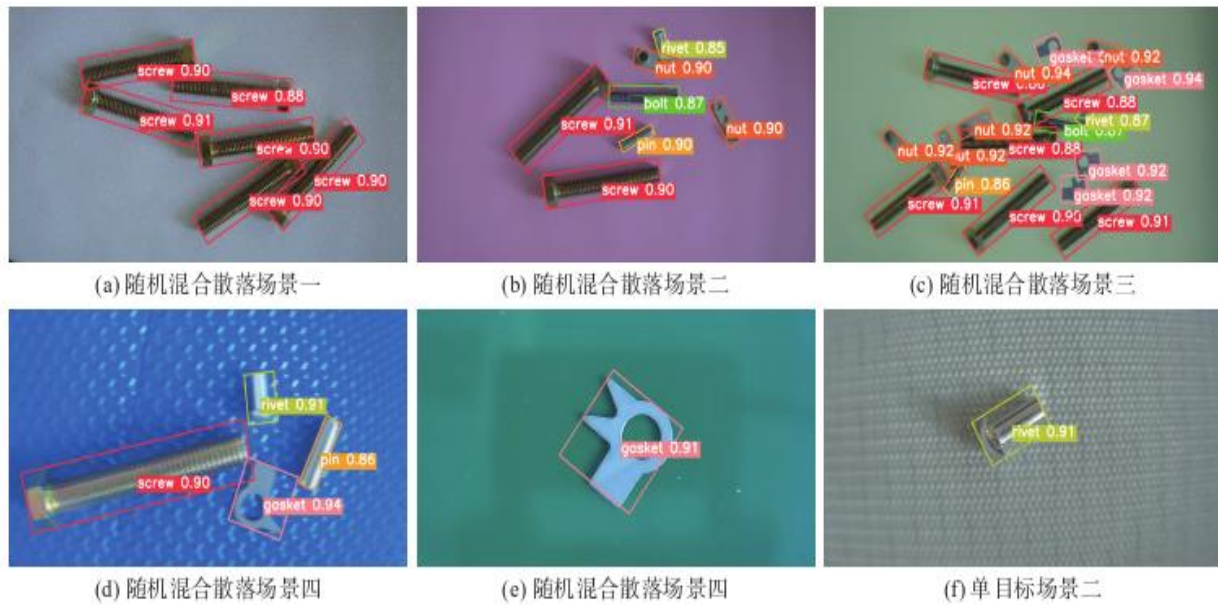


图7 OLAFDet 检测结果示例

将上述高精度检测方法部署在 NVIDIA JetsonAGX Xavier 上,其检测速度超过 20 FPS,可满足工业场景下航空紧固件旋转检测边缘部署的需求。

4 结论

本文提出一种面向边缘智能光学感知的旋转检测方法,可应用于工业场景下航空紧固件检测任务。基于强化语义和优化空间的特征融合机制提升模型的检测性能,空洞幻影模块有利于本文方法的边缘部署,将水平检测改进为旋转检测,显著提升了检测精度,并且便于紧固件的自动抓取分拣工作。本文所提方法及其各模块的有效性在权威公开旋转数据集上得到验证。将本文方法部署在嵌入式边缘智能设备 NVIDIA Jetson XavierAGX 上,对航空紧固件检测 mAP 达到 99.76%,检测速度超过 20 FPS,满足工业应用要求。在未来工作中,我们拟增加模型的目标检测类别,并考虑将本文方法进一步推广应用到其他工业场景中去。

[参考文献]

- [1]郭永强,谭夏萍.紧固件保险的标准比较[J].科技创新与应用,2024,14(14):23-27+31.DOI:10.19981/j.cn23-1581/G3.2024.14.006.
- [2]孙珍军,辛叶盛,唐伟.一种临时紧固件及其预紧力测量方法[J].机械设计,2024,41(04):36-41.DOI:10.13841/j.cnki.jxsj.2024.04.025.
- [3]宋梦佳,尹亚豪,郭磊,等.钢丝绳网紧固件镀锌层厚

度测量不确定度评定[J].理化检验-物理分册,2024,60(04):34-36.

[4]李谨,徐少可,王要伟,等.非标法兰设计过程中紧固件设计载荷的研究[J].阀门,2024,(03):286-289.DOI:10.16630/j.cnki.1002-5855.2024.03.005.

[5]董华军,姚佳岐,何晨阳,等.地铁车底松动紧固件视觉检测算法研究[J/OL].铁道科学与工程学报,1-12[2024-05-16].https://doi.org/10.19713/j.cnki.43-1423/u.T20231952.

[6]闫柱,王庆国,王凯,等.汽车螺纹紧固件防腐性能分析与提升[J].汽车工艺师,2024,(03):34-36.DOI:10.16173/j.cnki.ame.2024.03.008.

[7]铸工业之“米”掘永年之金——走进河北省邯郸市永年区紧固件产业集群[J].中国中小企业,2024,(02):42-43.

[8]李晓玲.永年紧固件的昨天、今天和明天[J].中国中小企业,2024,(02):44-47.

[9]卯鑫,冯思庆,刘鹏,等.带有防咬死铜镀层的标准螺纹紧固件放气率测试[J/OL].真空,1-4[2024-05-16].http://kns.cnki.net/kcms/detail/21.1174.tb.20240129.1121.002.html.

[10]李林骏.基于 PLC 的轨道紧固件检修车设计[J].现代工业经济和信息化,2024,14(01):155-156+188.DOI:10.16525/j.cnki.14-1362/n.2024.01.047.

通讯作者:董玮,高级工程师。