

TAE-YOLO: 一种高效的轻量级铸件缺陷检测算法

陈子豪¹ 张 龙¹ 缪剑晖² 洪 军² 司 斌¹ 沈颖杰¹

(1. 安徽工业大学冶金工程学院, 马鞍山 243002; 2. 安徽海立精密铸造有限公司, 马鞍山 238100)

摘 要 在砂型铸造中, 准确识别铸件表面气孔、裂纹和夹杂等缺陷至关重要。针对现有铸件缺陷检测算法在资源受限的工业环境中部署存在的问题, 提出了一种高效、轻量化的铸件缺陷检测算法——TAE-YOLO。TAE-YOLO 算法采用轻量级的 Detect_TADDH 检测头替换原有检测头, 并引入 YOLOv9 中的高效 ADown 降采样模块。此外, 为加速特征提取, 提出了 C2f_EFFC 卷积模块。通过在自建铸件缺陷数据集上的验证结果表明, TAE-YOLO 在铸件缺陷检测中相比 YOLOv8n 在 $m_{AP}@0.5$ 指标上提高了 8.5%, 同时参数量减少了 43.5%。

关键词 铸件缺陷检测; TAE-YOLO 算法; 深度学习

中图分类号 TG245; TP311

文献标志码 A

DOI: 10.15980/j.tzzz.T20240391

TAE-YOLO: An Efficient Lightweight Casting Defect Detection Algorithm

CHEN Zihao¹, ZHANG Long¹, MIAO Jianhui², HONG Jun², SI Bin¹, SHEN Yingjie¹

(1. School of Metallurgical Engineering, Anhui University of Technology, Maanshan 243002; 2. Anhui Highly Precision Casting Co., Ltd., Maanshan 238100)

Abstract: Accurate identification of defects such as surface porosity, cracks, and inclusions is essential in sand casting. To address the challenges associated with deploying existing casting defect detection algorithms in resource-constrained industrial environments, an efficient and lightweight casting defect detection algorithm——TAE-YOLO was proposed. The lightweight Detect_TADDH inspection head was employed to replace the original inspection head, and the efficient ADown downsampling module was integrated from YOLOv9. Additionally, C2f_EFFC convolution module was proposed to accelerate feature extraction. Validation on a self-constructed casting defect dataset indicates that TAE-YOLO achieves an 8.5% increment in $m_{AP}@0.5$ compared to YOLOv8n, while the parameter amounts is reduced by 43.5%.

Key Words: Casting Defect Detection, TAE-YOLO, Deep Learning

砂型铸造因其效益高和适应性强, 广泛应用于汽车制造、航空航天等领域^[1]。然而, 采用砂型铸造生产的铸件易出现裂纹、气孔、夹杂等缺陷, 严重影响铸件品质^[2]。传统的砂型铸造表面缺陷检测主要依赖人眼进行, 不仅效率低下, 还受到检测人员的经验、疲劳和主观判断等因素的影响, 导致检测结果准确性和一致性难以保障^[3]。随着工业自动化和智能化的发展, 机器视觉技术应运而生。

传统的机器视觉技术显著提升了铸件缺陷的检测效率和准确性, 但其图像处理算法通常依赖大量手动设计的特定特征提取, 这在处理复杂或非标准化图像时非常困难, 且对工程师的技术要求较高。为满足工

业自动化和高精度检测需求, 深度学习技术为铸件缺陷检测开辟了新的方法。通过训练神经网络, 深度学习能够自动学习图像中的特征表示, 从而实现高精度的检测和分类。早期的缺陷检测多采用以卷积神经网络(CNN)为代表的两阶段网络, 其强大的特征提取能力对铸件缺陷检测尤为重要^[4]。CHEN K Y 等^[5]通过在 Faster-RCNN 中集成可变形卷积和特征金字塔网络(FPN), 扩展了卷积层的感受野, 实现了铝合金缺陷的多尺度检测。MERY D^[6]使用 CNN 进行铝铸件缺陷检测, 使用包含约 640 000 个斑块的数据集进行训练, 平均精度均值 m_{AP} 可达 0.710 2; TANG Z H 等^[7]提出了空间注意双线性 CNN, 通过增强特征表示能力, 实现了铸

收稿日期: 2024-09-26; 修订日期: 2024-10-30

基金项目: 国家自然科学基金资助项目(51405002); 安徽省自然科学基金资助项目(2108085ME173)

第一作者简介: 陈子豪, 男, 2001 年出生, 硕士研究生, E-mail: chen-zihao01113@foxmail.com

通信作者: 张龙, 男, 1983 年出生, 副教授, E-mail: longzhang@ahut.edu.cn

引用格式: 陈子豪, 张龙, 缪剑晖, 等. TAE-YOLO: 一种高效的轻量级铸件缺陷检测算法[J]. 特种铸造及有色合金, 2025, 45(9): 1 320-1 326.

CHEN Z H, ZHANG L, MIAO J H, et al. TAE-YOLO: An efficient lightweight casting defect detection algorithm[J]. Special Casting & Nonferrous Alloys, 2025, 45(9): 1 320-1 326.

件的无损检测。然而,两阶段检测算法通常需要大量计算资源,并且推理延迟较高,难以满足铸件表面缺陷实时检测的需求。相比之下,单阶段检测算法如YOLO^[8]和SSD^[9]系列由于其高效的实时性能而受到关注。这类算法可以在一次前向传播中同时预测目标的类别和位置,大幅缩短推理时间。鲍春生等^[10]在铸件划痕缺陷检测中通过提出YOLOv3-Mv2模型显著提升了检测精度。尽管该模型采用锚框(Anchor-Based)检测方式增加了计算量,但检测性能得到了显著优化。此外,ZHANG B等^[11]结合双向特征金字塔和高效通道注意力(ECA)模型,增强了SSD的特征通道信息,从而提高了缺陷检测的准确性。

尽管深度学习技术在图像识别和缺陷检测方面取得了重要进展,但现有许多方法仍过于关注提升检测精度,而忽视了推理速度和模型轻量化的优化。在实际工业应用中,许多场景面临资源受限的挑战,如嵌入式设备和边缘计算平台,因计算能力和内存有限,无法运行复杂的大型模型。因此,在保证检测精度的同时,提高算法的效率并减小模型体积成为亟待解决的问题。

针对此问题,本研究提出一种更高效、更轻量的铸件缺陷检测算法——TAE-YOLO。该算法以YOLOv8n为基准模型,采用轻量化的Detect_TADDH检测头替换原有检测头,并引入YOLOv9中的高效

ADown降采样模块。此外,为进一步加速特征提取,提出C2f_EFFC卷积模块。此优化策略在保持高检测精度的基础上,可以显著提升模型在工业应用中的实用性和响应速度。

1 TAE-YOLO检测算法

TAE-YOLO延续了YOLO架构的设计理念,进一步优化网络结构,以实现工业环境中铸件缺陷检测的更高效、更轻量化。TAE-YOLO检测网络由主干网络(Backbone)、颈部结构(Neck)和检测头(Detect)3部分组成,其网络结构见图1,其中 w 为通道维度的缩放因子,用于调整特征图的通道数; r 为注意力机制模块里的维度缩减因子,用于降低计算维度。可以看出,在Backbone和Neck部分,将YOLOv8^[12]中的降采样模块CBS替换为YOLOv9^[13]的ADown模块,以提升降采样效率和模型轻量化能力。此外,为了有效识别铸件中不同尺寸的缺陷特征,将原模型中的C2f模块(输入维度为512)替换为C2f_EFFC模块,旨在增强网络对输入数据空间结构和语义信息的理解和利用,从而提升模型的表达能力与泛化性能。在检测头部分,提出Detect_TADDH检测头替换YOLOv8中的原始Detect头,优化了通道维度并将输出固定为512,从而在保证检测精度的同时大幅减小模型的计算复杂度,实现轻量化目标。




图1 TAE-YOLO网络结构图

Fig.1 Structure diagram of TAE-YOLO network

2 改进模块

2.1 TADDH检测头

为了应对铸造厂复杂的工业环境,必须要设计更为高效的缺陷检测模型。本研究提出TADDH检测头,其流程见图2。基于FENG C J等^[14]提出的TOOD (Task-Oriented One-Stage Object Detection)理念,不仅在标签分配策略上实现了任务对齐,还在检测模型的头部结构中引入了定制化的任务对齐机制。传统目标检测器往往采用分离的分类和定位分支,这限制了两个任务之间的信息交流。为了克服这一局限,提出了TADDH (Task-Aligned Dynamic Detection Head)模型,其通过特征提取器从多个卷积层中学习能够促进任务间交互的特征,从而获得更加综合的特征表示。在定位分支方面,本研究利用DCNV2 (Deformable Convolution V2)^[15]和这些交互特征来计算DCNV2的偏移量和掩码,而在分类分支方面,则利用这些交互特征进行动态特征选择。该设计不仅增强了任务间的协同作用,还显著提升了目标检测的性能。




图2 TADDH检测头结构图

Fig.2 Structural diagram of TADDH detection head

通过使用共享卷积,大幅减少了参数量,使模型更加简洁高效。流程首先对每个检测层进行处理,利用共享卷积层提取特征;随后,任务分解模块将特征分解为分类特征和回归特征。分类特征用于计算分类概率并与其结果相乘,回归特征则通过动态卷积和偏移对齐进行回归预测,最后将回归和分类特征拼接,生成最终预测结果。

2.2 ADown降采样模块

为了提高铸件缺陷检测的实时性能,将YOLOv8模块中的Backbone和Neck部分的卷积层(CBS)替换为YOLOv9中的ADown降采样模块。降采样是一种常用的技术,旨在减少特征图的空间维度,从而帮助模型在更高层次上捕捉图像特征,并减少计算量。ADown模块的设计目标是以高效且对性能影响较小的方式执行这一操作。通过减少参数量,ADown模块降低了模型的复杂度,有助于提高运行效率,特别是在资

源受限的环境中。尽管该模块降低了特征图的空间分辨率,但其设计也注重尽可能保留图像信息,以便模型能够更准确地进行目标检测。同时,ADown模块具备可学习能力,可以根据不同的数据场景进行自适应调整,以优化性能。

图3为ADown模块的流程图,其中, H 为特征图的高度, W 为特征图的宽度, C 为特征图的通道数。首先进行平均池化,池化核为2,步幅为1,填充为0;接着将张量沿通道维度分为两部分。第1部分进入第1个卷积层,第2部分则进行最大池化,池化核为3,步幅为2,填充为1,随后输入第2个卷积层。图中CBS卷积层是由卷积层Conv、批量归一化层BN和SILU()激活函数层组成。最后,将两部分在通道维度上拼接,形成输出结果。这些卷积层负责提取特征图中的有用信息,通过调整步幅降低特征图的空间维度。通过优化卷积层中的参数量,ADown模块在减少模型复杂度的同时,保持甚至提升了铸件表面缺陷检测的精度。




图3 ADown模块流程图

Fig.3 Flowchart of ADown module

2.3 高效特征级联卷积(EFFC)

为了有效识别铸件中不同尺寸的缺陷特征,设计了一种高效特征级联卷积(Efficient Feature Fusion Conv, EFFC)的方法。通过将不同层级或不同尺寸的特征图进行卷积处理并合并,旨在增强网络对输入数据的空间结构和语义信息的理解与利用,从而提高模型的表达力和泛化性能。

图4为EFFC网络结构图。图4a可以看出,C2f_EFFC结构是在YOLOv8的C2f基础上替换了原有的残差模块,并引入了特征级联卷积技术。图4d中特征级联卷积首先采用分组策略^[16],将输入特征图分为2部分:第1部分直接进行 1×1 卷积操作;第2部分则进一步细分,进行特征级联处理。第2部分的特征图分别经过 3×3 和 5×5 的卷积操作,然后通过堆叠、融合,以及 1×1 卷积来提取特征,最终将这些多尺度卷积结果重新组合,并通过 1×1 卷积融合为最终输出张量。

在处理第2部分特征时,针对每组特征使用相应的卷积核尺寸进行卷积。所有卷积后的特征图随后被整合,并通过 1×1 卷积进行融合,以合并不同尺度

的特征信息。通过这种分组卷积策略,有效地减少了计算量,同时保持了模型的性能,提高了整体的效率。




图4 EFFC网络结构图

Fig.4 Structure diagram of EFFC network

3 试验结果分析

3.1 试验配置

试验环境: Windows10 操作系统, CPU: i7-13700KF, GPU: RTX 4080 (16G), IDE: PyTorch, Python 版本: 3.8, CUDA 版本: 11.6。

模型训练参数设置: 本研究在试验中对参数进行合理设置以平衡模型的收敛速度与精度。学习率基于训练过程中模型收敛情况的敏感性, 选择0.001, 这可以有效加速模型的收敛, 同时避免了过大学习率可能

引发的发散问题; 权重衰减参数默认设置为0.0005, 旨在通过轻微的L2正则化减少过拟合风险; 批大小(batch_size)设置为32, 是在硬件性能支持的前提下, 通过试验验证在保证模型稳定性与收敛速度方面取得的较优选择。总迭代次数为300, 其余参数均保持默认值。

3.2 数据集采集与预处理

本研究数据集源自砂型铸造现场生产的铸件。依据GB/T 41972-2022将铸件缺陷划分为孔洞类(Porosity)、残缺类(Incomplete)、多肉类(Excess)和裂纹类(Crack), 见图5, 均属于小目标检测范畴。




图5 铸件缺陷示例

Fig.5 Examples of casting defects

图6为铸件缺陷数据集收集现场。缺陷图像通过海康高精度相机拍摄, 图像分辨率为 1280×1024 。拍摄过程中, 通过调整相机与铸件间的距离高度, 完成了

6个不同角度的旋转拍摄。此方法不仅提升了算法在多场景下的缺陷检测能力, 还增强了神经网络的鲁棒性。最终收集到1600张缺陷图像, 将收集到的图像使

用labelimgV1.8.6^[17]进行标记,并将铸件的缺陷分别标记为Porosity、Incomplete、Excess和Crack,为每个图像生成.txt文件和.xml文件。由于部分铸件同时存在两种或两种以上缺陷,数据集中共有1 689个缺陷,其中孔洞类缺陷有731个,约占43.28%;残缺类缺陷有372个,约占22.02%;多肉类缺陷有377个,约占22.32%;裂纹类缺陷有209个,约占12.37%。最后数据集按照8:1:1的比例随机划分为训练集(1 280张)、验证集(160张)和测试集(160张)。训练集用于模型训练,验证集用于调整 and 选择模型参数及超参数,测试集则用于对模型的初步评估。



图6 铸件缺陷数据集收集现场

Fig.6 Collection site of casting defect data set

1.海康高精度相机1号 2.铸件 3.海康高精度相机2号

3.3 评价指标

为验证本研究提出的铸件缺陷检测的性能,使用平均精度均值 m_{AP} (Mean average precision, mAP)、准确率 $P_{\text{准确}}$ (Precision)、召回率 $R_{\text{召回}}$ (Recall)、模型的参数量 $P_{\text{参数}}$ (Params)、浮点运算数 (GFLOPs) 和模型的大小 (Model size) 对模型进行评价,准确率是指在所有被模型预测为正类的样本中,实际为正类的比例,召回率则是指在所有实际为正类的样本中,被模型正确预测为正类的比例。其计算方法如下:

$$m_{AP} = \frac{1}{N} \sum_{i=1}^N A_{P_i} \quad (1)$$

$$P_{\text{准确}} = \frac{T_p}{T_p + F_p} \quad (2)$$




图7 TAE-YOLO 指标对比图

Fig.7 Comparison of indicators for TAE-YOLO model

$$R_{\text{召回}} = \frac{T_p}{T_p + F_N} \quad (3)$$

式中, N 为检测总数; A_p 为单个类别的评估指标; T_p 为真正例; F_p 为假正例; F_N 为假反例。

3.4 算法对比试验


为了进一步验证 TAE-YOLO 算法的准确性和优越性,在自建数据集上选取了 YOLOv5、YOLOv8n、YOLOv9 和 YOLOv10n 为代表的主流目标检测算法进行铸件缺陷检测对比,试验配置均相同。以 $m_{AP}@0.5$ 、 $P_{\text{准确}}$ 、 $R_{\text{召回}}$ 、 G_{FOLPs} 、 $P_{\text{参数}}$ 和 Model size 作为评价指标,对比试验结果见表1,其中, $m_{AP}@0.5$ 是将所有的类别的样本的精确度取平均值。 $P_{\text{参数}}$ 和 G_{FOLPs} 表示模型的复杂度和计算成本。由表1可知,TAE-YOLO 算法整体性能优于当前主流目标检测算法。与 YOLOv5、YOLOv8n、YOLOv9 和 YOLOv10n 相比,TAE-YOLO 在 $m_{AP}@0.5$ 指标上分别提高了13.8%、8.5%、16.1%和10.8%;在 $P_{\text{准确}}$ 指标上分别提高了约21.61%、5.42%、13.21%和8.73%;在 $R_{\text{召回}}$ 指标上分别提高了约8.92%、11.47%、13.14%和9.71%。其 G_{FOLPs} 与 YOLOv5 相当,但优于其他算法。在参数量方面,TAE-YOLO 较基准模型 YOLOv8n 减少了43.5%。此外,TAE-YOLO 的模型大小也小于其他主流算法。综上,TAE-YOLO 在铸件缺陷检测领域展现出更高的效率和更快的性能。

表1 对比试验结果

Tab.1 Experimental result comparison

模型	$m_{AP}@0.5/\%$	$P_{\text{准确}}/\%$	$R_{\text{召回}}/\%$	G_{FOLPs}/G	$P_{\text{参数}}/\text{MB}$	模型大小/MB
YOLOv5	81.1	76.8	83.0	7.3	2.51	5.05
YOLOv8n	85.1	88.6	81.1	8.1	3.01	5.97
YOLOv9	79.5	82.5	79.9	238.9	51.01	390
YOLOv10n	83.3	85.9	82.4	8.4	2.71	5.51
TAE-YOLO	92.3	93.4	90.4	7.3	1.70	3.50

图7为 TAE-YOLO 模型在 $m_{AP}@0.5$ 、 $m_{AP}@0.5-0.95$ 、准确率和召回率指标上的对比图。可以看出,



TAE-YOLO算法在模型精度和收敛性方面均处于主流模型的领先水平。

3.5 消融试验

为验证 TADDH 检测头、ADown 降采样模块和 C2f_EFFC 在铸件缺陷检测模型中的有效性及其对模型性能的影响,在统一的训练条件下开展了一系列的消融试验,结果见表 2,其中序号 1~3 分别代表了单独集成 C2f_EFFC、ADown 降采样模块和 TADDH 检测头对模型性能的影响;序号 4~6 探讨了同时替换两种模块对模型性能的影响;序号 7 则展示了同时集成

C2f_EFFC、ADown 降采样模块和 TADDH 检测头后的模型性能变化情况。

可以看出,与基础模型 YOLOv8n 相比,单独集成 TADDH 检测头、ADown 降采样模块或 C2f_EFFC 时,虽然 $m_{AP}@0.5$ 指标有所波动(轻微下降或升高),但 G_{FLOPs} 和模型大小均明显减小。当同时集成两种改进模块时,在确保检测精度前提下, G_{FLOPs} 和模型大小显著下降。当同时集成 3 种改进模块时,精度得到了提升, G_{FLOPs} 和模型大小明显下降。这表明 TAE-YOLO 模型在提升效率方面具有明显优势。

表 2 消融试验结果

Tab.2 Results of ablation experiments

序号	C2f		降采样		检测头		$m_{AP}@0.5/\%$	G_{FLOPs}/G	$P_{参数}/MB$	模型大小/ MB
	C2f	C2f-EFFC	Conv	ADown	Detect	TADDH_Detect				
1	—	✓	✓	—	✓	—	83.1	7.6	2.71	5.46
2	✓	—	—	✓	✓	—	86.9	7.4	2.59	5.20
3	✓	—	✓	—	—	✓	85.6	7.6	2.24	4.49
4	—	✓	—	✓	✓	—	85.6	6.9	2.31	4.68
5	—	✓	✓	—	—	✓	84.1	7.9	2.01	4.07
6	✓	—	—	✓	—	✓	84.9	7.8	1.80	3.66
7	—	✓	—	✓	—	✓	92.3	7.3	1.70	3.50

3.6 算法验证

根据算法对比试验和消融试验的结果,将 YOLOv8n 模型与 TAE-YOLO 模型在铸件缺陷检测中的表现进行可视化对比。随机选择了测试集中的 4 张照片进行检测,结果见图 8,图中缺陷标注由缺陷名称和置

信度组成。可以看出, YOLOv8n 模型在侧面多肉缺陷和正面小孔洞缺陷中出现了漏检情况, TAE-YOLO 模型相比 YOLOv8n 展现出更高的置信度。这表明 TAE-YOLO 在铸件缺陷检测能力方面具有进一步提升的潜力。




图 8 缺陷检测可视化对比

Fig.8 Visual comparison of defect detection

4 结 论

(1) 提出了 TAE-YOLO 算法, 采用轻量级的 Detect_TADDH 检测头替换原有检测头, 并引入 YOLOv9 中的高效 ADown 降采样模块。此外, 为加速特征提取, 提出了 C2f_EFFC 卷积模块。

(2) TAE-YOLO 算法在铸件缺陷检测方面相比 YOLOv8n 在 $m_{AP}@0.5$ 指标上提高了 8.5%。此外, TAE-YOLO 在参数量方面较基准模型 YOLOv8n 减小了 43.5%。

(3) 通过消融试验, TADDH 检测头通过共享卷积显著减少了参数量, 并在模型头部结构中引入了定制化任务对齐机制。此外, 采用 YOLOv9 中的 ADown 降采样模块, 优化了卷积层的参数配置; 最后, 提出的高效特征级联卷积(EFFC)使用分组卷积策略, 更有效识别铸件中不同尺寸的缺陷特征。

参 考 文 献

- [1] XU Y C, LI G Y, JIANG W M, et al. Investigation on characteristic and formation mechanism of porosity defects of Al-Li alloys prepared by sand casting[J]. Journal of Materials Research and Technology, 2022, 19: 4 063-4 075.
- [2] 胡佳琪, 王成军, 杨超宇, 等. 基于改进 YOLOX 算法的铝铸件表面成孔缺陷检测研究[J]. 特种铸造及有色合金, 2023, 43(9): 1 205-1 209.
- [3] 张辉, 张邹铨, 陈煜嵘, 等. 工业铸件缺陷无损检测技术的应用进展与展望[J]. 自动化学报, 2022, 48(4): 935-956.
- [4] KHANAM R, HUSSAIN M, HILL R, et al. A comprehensive review of convolutional neural networks for defect detection in industrial applications[J]. IEEE Access, 2024, 12: 94 250-94 295.
- [5] CHEN K Y, ZENG Z Y, YANG J F. A deep region-based pyramid neural network for automatic detection and multi-classification of various surface defects of aluminum alloys[J]. Journal of Building Engineering, 2021, 43: 102 523-10 2528.
- [6] MERY D. Aluminum casting inspection using deep learning: A method based on convolutional neural networks[J]. Journal of Non-destructive Evaluation, 2020, 39(1): 12-23.
- [7] TANG Z H, TIAN E G, WANG Y X, et al. Nondestructive defect detection in castings by using spatial attention bilinear convolutional neural network[J]. IEEE Transactions on Industrial Informatics, 2021, 17(1): 82-89.
- [8] JIANG P Y, ERGU D J, LIU F Y, et al. A review of YOLO algorithm developments[J]. Procedia Computer Science, 2022, 199: 1 066-1 073.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[A]//Computer Vision-ECCV 2016: 14th European Conference[C]. Amsterdam, the Netherlands, 2016.
- [10] 鲍春生, 谢刚, 王银, 等. 基于深度学习的铸件缺陷检测[J]. 特种

铸造及有色合金, 2021, 41(5): 580-584.

- [11] ZHANG B, FANG S Q, LI Z X. Research on surface defect detection of rare-earth magnetic materials based on improved SSD[J]. Complexity, 2021(1): 4 795 396.
- [12] HUSSAIN M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677-687.
- [13] WANG C Y, YE H I H, LIAO H Y M. YOLOv9: Learning what you want to learn using programmable gradient information[J]. arXiv preprint arXiv, 2024, 13 616: 72 751.
- [14] FENG C J, ZHONG Y J, GAO Y, et al. TOOD: Task-aligned one-stage object detection[A]//2021 IEEE/CVF International Conference on Computer Vision (ICCV)[C]. Montreal, QC, Canada, 2021.
- [15] ZHU X Z, HU H, LIN S, et al. Deformable convnets v2: More deformable, better results[A]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition[C]. Long Beach, CA, USA, 2019.
- [16] ZHANG X, LIU C, YANG D G, et al. RFACConv: Innovating spatial attention and standard convolutional operation[J]. arXiv preprint arXiv:2304, 2023(1): 3 198.
- [17] BRYAN C R, ANTONIO T, KEVIN P M, et al. LabelMe: A database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008(3): 157-173.

(编辑: 刘晨辉)

欢迎关注《特种铸造及有色合金》微信公众号矩阵, 文章信息、行业研究动态与资讯信息早知道!



特种铸造
(关注铸造及有色合金
领域重要研究成果)



压铸界
(压铸领域最新动态
及研究)



青稞讲堂
(金属领域青年科学家
最新研究成果)



特种铸造及有色
合金杂志
(文章动态时刻关注)