

基于半监督学习的钢材表面缺陷检测方法

曹科研^{1,2}, 朱远迪¹, 汪新蕾¹, 王中阳¹

(1. 沈阳建筑大学 计算机科学与工程学院; 2. 辽宁省城市建设大数据管理与分析实验室, 辽宁 沈阳 110168)

摘要: 为了降低因钢材标注数据造成的大量成本、对标记数据的依赖, 解决钢材表面缺陷形状不规则且大部分缺陷尺寸较小导致的检测较难等问题, 提出一种基于半监督学习的钢材表面缺陷检测方法 STD Model。首先, 设计了一个特征提取模块提升框架, 以识别不规则形状目标的能力, 使模型能聚焦关键信息; 其次, 引入空间深度卷积提升模型对小目标、低分辨率目标的检测能力, 对传统二维卷积进行优化升级; 最后, 设计一个微小目标检测头提升模型识别微小目标的精度, 以精确捕捉微小物体。在 NEU-DET 公共数据集上的测试表明, 所提模型的 mAP@0.5 为 62.2%, 参数量为 12.40 MB, 相较于其他半监督学习模型性能更好、更轻量, 适合工业生产的部署应用。

关键词: 半监督学习; 钢材小目标检测; 特征提取模块; 空间深度卷积; 微小目标检测头

DOI: 10.11907/rjdk.251107

扫描二维码阅读全文:



中图分类号: TP301

文献标识码: A

文章编号: 1672-7800(2026)005-0168-09

Steel Surface Defect Detection Method Based on Semi-Supervised Learning

CAO Keyan^{1,2}, ZHU Yuandi¹, WANG Xinlei¹, WANG Zhongyang¹

(1. School of Computer Science and Engineering, Shenyang Jianzhu University;

2. Liaoning Province Big Data Management and Analysis Laboratory of Urban Construction, Shenyang 110168, China)

Abstract: To reduce the significant costs caused by the labeling of steel material data and the reliance on labeled data, and to solve the difficulties in detecting non-standard shapes of steel surface defects, many of which are small, a semi-supervised learning-based method for steel surface defect detection, named STD model, is proposed. Firstly, a feature extraction module is designed to enhance the framework's ability to recognize irregular shape targets, allowing the model to focus on key information; secondly, a spatial deep convolution enhancement model is introduced to improve the detection ability for small targets and low-resolution objects, optimizing traditional 2D convolution; finally, a small target detection head is designed to enhance the model's accuracy in identifying minuscule targets to accurately capture tiny objects. Testing on the NEU-DET public dataset shows that the proposed model achieves an mAP@0.5 of 62.2% with a parameter size of 12.40 MB, outperforming other semi-supervised learning models in terms of performance and being more lightweight, making it suitable for deployment in industrial production.

Key Words: semi-supervised learning; steel small target detection; feature extraction module; spatial deep convolution; small target detection head

0 引言

钢铁是当今世界不可缺少的原材料,在汽车、造船、机械制造、航空航天等行业中发挥着重要作用。由于原材料、设备、加工工艺等各种原因,钢铁产品在制造过程中存

在不同类型的表面缺陷,对产品外观、耐腐蚀性和使用寿命造成了消极影响^[1,2]。

目前,常见的缺陷类型包括裂纹、夹杂、斑块、点蚀面、滚入水垢和划痕等,缺陷检测任务包括识别缺陷类别和定位缺陷位置,非常具有挑战性^[3]。然而,人工检测传统缺陷非常耗时且不经济,对工人的技术也有一定的要求^[4]。

收稿日期: 2025-03-25

基金项目: 国家自然科学基金重点项目(62133014)

作者简介: 曹科研(1981-),女,博士,沈阳建筑大学计算机科学与工程学院教授、博士生导师,研究方向为城市空间数据管理等;朱远迪(1999-),男,沈阳建筑大学计算机科学与工程学院硕士研究生,研究方向为人工智能;汪新蕾(1994-),女,博士,沈阳建筑大学计算机科学与工程学院讲师、硕士生导师,研究方向为人工智能与大数据计算;王中阳(1989-),男,博士,沈阳建筑大学计算机科学与工程学院副教授、硕士生导师,研究方向为生物医学工程。本文通讯作者: 曹科研。

随着人工智能技术和工业视觉领域的发展,机器学习逐渐取代了人工检测技术^[5]。例如,人工神经网络、支持向量机、k近邻等传统机器学习方法已广泛应用于钢材表面缺陷检测,凭借其高效的检测效率、高度的可靠性减少了人工依赖,在钢材检测中成为主流^[6]。然而,这类算法在面对图像识别等复杂任务时表现不佳,对高维特征的处理能力不足。

近年来,深度学习在目标检测和分类、故障诊断、目标跟踪及各种其他基于图像的应用中取得了很大进步,凭借出色的特征自动提取能力和对数据集更强的泛化能力,成为了目标检测的主流方法^[7]。其中,有监督的检测已能很好地完成目标检测任务,相较于传统的机器学习方法而言,使用深度学习网络作为主干网络提取特征,具有精度高、速度快的优势^[8-11]。然而,其高准确度需依赖大量的标注数据,而钢材缺陷复杂目标较小,识别各种缺陷需要具备专业知识,会花费大量人力时间。

半监督学习凭借其可使用较少的标注数据进行训练的优势,显著降低了标注数据的成本和时间。同时,凭借伪标签生成方法和一致性正则化方法能提升模型对复杂特征的捕捉能力,在钢材检测方法中具备独有优势。半监督目标检测思想是使用大量未标注的数据进行训练,主流模型是教师—学生模型^[12-15]。首先,使用标记数据训练一个教师网络;其次,使用未标记数据生成伪标签和检测框来作为学生网络的真实值,指导学生模型进行训练。相较于全监督方法,半监督方法提升了对未标记数据的利用率,降低了标注数据成本。然而,针对钢材的半监督检测模型仍存在两点挑战:①钢材具有各种各样的缺陷特征,例如夹杂、压入氧化皮、斑块、麻点、裂纹、划痕,由于这些缺陷具有复杂的特征,因此检测准确度较低(见图1);②很多钢材缺陷尺寸较小,模型难以对小目标进行检测。

现有钢材检测方法未能关注钢材缺陷特征和微小目标,也没有关注到钢材标注数据难以获取的难点,而这对钢材缺陷检测至关重要。因此,本文需要重点解决的问题为:如何使用半监督方法提升模型的特征提取能力;如何提升检测头对微小目标的识别能力。为此,本文鉴于半监督方法在不易获取标注数据的检测任务(钢材、医学等领域等)中的优秀表现,提出了一种基于半监督学习的钢材缺陷检测方法。同时,为了进一步提升模型对钢材缺陷特征的提取能力,提出一种高效的特征提取模块SimDc。首先,通过4个分支提取输入特征图的特征并进行融合,引入动态蛇形卷积与SimAm注意力机制提升模型对复杂特征的检测能力;其次,针对钢材缺陷数据尺寸小的特点,引入空间深度卷积代替普通的二维卷积,使模型能提取更多特征;最后,加入一个微小检测头提升检测头对小目标的检测能力。




Fig. 1 Common steel surface defects

图1 常见钢材表面缺陷

1 相关工作

1.1 钢材缺陷检测

近年来,基于深度学习的目标检测算法受到了广泛关注,通常使用卷积神经网络(Convolutional Neural Network, CNN)自动提取特征,利用神经网络实现分类和定位。根据不同的网络结构,目标检测可分为单阶段目标检测器和两阶段目标检测器。其中,单阶段目标检测器以SSD和YOLO系列为主,可在一次操作中同时完成分类和定位,以提升检测速度^[16-20];Faster RCNN等两阶段目标检测器需要预先生成候选框再进行检测^[21]。实验表明,单阶段目标检测器具有速度快、计算效率高的优势,能快速适应不同的目标和环境;两阶段目标检测器检测过程较为繁琐、检测速度慢,但检测准确度相对较高。

随着深度学习发展,因其具有自动提取特征、适应性强和强大的表达能力等优势,被广泛应用于钢材缺陷检测研究。Li等^[22]基于Yolov5模型,通过设计新的瓶颈结构、改变网络深度和结构对钢材进行检测。Yu等^[23]以级联RCNN为基线架构检测钢材缺陷。Cheng等^[24]提出一个改进的RetinaNet检测钢材表面缺陷,提出一个新的注意力机制减少信息丢失,并加入一个自适应空间特征融合模块提取浅层、深层特征。Zhao等^[25]对Faster R-CNN网络进行重构,使用多尺度融合训练网络检测钢材缺陷。He等^[26]采用改进的卷积神经网络,通过多级特征融合网络将多个分层特征组合成一个特征,以提升钢材检测性能。

综上,基于深度学习网络的全监督的钢材缺陷检测模型通过改变网络结构来提升模型检测准确度,但未专门优化模型对钢材缺陷的特征提取和检测能力,忽视了现实中获取带标注钢材数据的难度,因此会增加数据标注成本。半监督学习相较于全监督学习具有独有优势,可使用较少

的标注数据,同时使用伪标签和一致性正则化方法作为辅助,不仅能降低数据标注成本、节省大量人力时间,还能增强模型的鲁棒性和对复杂特征的提取能力。

1.2 半监督缺陷检测

由于工业数据的标注成本高,导致获取大量的标注数据很困难,研究人员希望使用少量的标记数据降低成本,获得较高的检测准确度。因此,通过减少标注数据来降低标注成本的半监督检测方法逐渐走入研究人员的视野。

半监督方法因其可结合少量标注数据和大量未标注数据的优势,有效提升了模型泛化能力和准确性,降低了对标注数据的依赖。Xu等^[27]提出一种端到端的检测方法,伪标签由教师模型动态生成,通过衡量未标记图像的分类损失及框抖动选择可靠的伪框进行回归,以提升检测性能。Liu等^[28]通过综合类平衡损失筛选出准确的伪标签,以减少错误的伪标签导致的噪声问题。Tarvainen等^[29]使用一种平均模型权重而非平均预测标签的方法,减少因数据集过大造成的训练时间过长的问题,同时提升了检测准确度。Wang等^[30]为解决错误伪标签产生的噪音导致过拟合的问题,基于交并比(Intersection over Union, IoU)策略将自适应标签改为静态标签,以取得良好的检测

性能。分析上述模型可知,众多算法通过生成更准确的伪标签来提升半监督模型的检测准确度,但在钢材缺陷检测任务中,应针对钢材数据集中的钢材缺陷小目标、形状复杂且图片分辨率低的问题进行优化。目前,半监督缺陷检测和钢材检测虽取得了一定进展,但未聚焦于钢材标注数据获取成本高、钢材数据特有等问题进行研究。为此,本文将针对钢材数据集中缺陷目标复杂且形状较小等挑战,采用半监督方法提升模型特征提取和检测能力。

2 本文方法

本文方法以Efficient Teacher作为基准网络,如图2所示^[31]。学生框架最初通过标注数据进行训练,以确定其损失和权重。教师模型通过指数移动平均方法(Exponential Moving Average, EMA)在每次迭代中更新权重,提升伪标记的质量。首先,教师网络对未标记的数据进行马赛克增强处理,学生网络对未标记数据进行强数据增强处理;其次,教师框架通过推断增强数据、应用非最大抑制(Non-Maximum Suppression, NMS)和使用伪标签分配器生成伪标签;最后,利用伪标签指导学生训练网络和计算损失。




Fig. 2 Basic framework

图2 基础框架

2.1 学生教师模型

学生网络和教师网络均基于Yolov7架构,包含主干网络、颈部网络和检测头3个部分^[32]。具体地,Yolov7是目标检测领域的一个单阶段目标检测器,采用了轻量级的网络架构,在具有高精度检测性能的同时保证了速度与精度的平衡。同时,Yolov7具有良好的泛化性能,在钢材缺陷检测中表现出色。为了将其有效地应用到半监督钢材目标检测中,观察钢材数据集NEU-DET发现,钢材缺陷以小目标为主,且各个类别间的形状变化较大,如图3所示。

然而,现有模型并未注意到钢材缺陷以小目标为主且形状变化较大的特点,因此造成了检测准确度较低的结果。为了解决上述两个问题,首先,针对钢材目标形状变化明显的特点,提出一个高效的特征提取模块SimDc有针对性地改进网络,增强网络特征提取能力;其次,针对钢材缺陷小目标及分辨率较低的特点,使用空间深度卷积进行特征提取,以提升网络对小目标的检测能力;最后,加入一个微小目标检测头进一步提升对微小目标的检测能力,具




Fig. 3 Target size distribution

图3 缺陷目标尺寸分布

体结构如图4所示。其中,空间深度卷积取代原结构二维卷积来提取特征;MP代表用于降低特征维度的最大池化;SimDc取代原结构的高效层聚合网络(Efficient Layer Aggregation Networks, ELAN)来提取特征;头部网络增加了一个微小目标检测头。




Fig. 4 Processing flow of the proposed method

图 4 本文方法处理流程

2.2 数据预处理与数据增强

半监督方法与监督方法的不同之处在于:所使用的数据中只有一小部分是有标签的数据,大部分是无标签的数据。在数据预处理过程中,应根据特定比例将数据集划分为有标签数据和无标签数据。其中,有标签数据有助于初始监督训练学生框架;无标签数据则支持后续在半监督训练。在半监督目标检测中,由于标注数据占总数据的比例较小,且钢材数据中缺陷目标的形状不规则,因此要对数据进行数据增强预处理。为此,本文采用马赛克和强数据增强技术来增强模型泛化能力和鲁棒性,解决数据稀缺问题,并在一定程度上提升模型对形状复杂的钢铁数据和小目标的检测能力。

(1)强数据增强技术。强数据增强技术对原始数据进行更剧烈、更大规模的变换,例如大规模旋转、大规模裁剪、高对比度调整、添加大量噪声等,以创建与原始数据存在显著差异但仍保持类别不变的新样本,从而提升框架对特征表示的鲁棒性。虽然,这种增强通常会生成样本看起来偏离原始数据分布,但理论上仍应属于同一类别的合理变化范围。

(2)马赛克数据增强。该技术在 YOLOv4 论文中被首次提出,通常用于增强模型的鲁棒性和泛化能力,解决数据稀缺难题,如图 5 所示。由此可见,该方法使用随机缩放、裁剪和排列来拼接 4 幅图像。在训练过程中,模型会遇到一个复杂的场景,包括不同来源的图像片段,可通过随机缩放引入大量小目标的数据集,以增强模型鲁棒性。

2.3 SimDc 模块

因钢材缺陷的种类较多且各个种类间形状差异较大,为了针对性地提升模型对钢材检测的准确度,以适应不同形状的缺陷目标,提升网络特征提取能力,在教师学生网络中提出 SimDc 特征提取模块,并加入 SimAm 注意力机




Fig. 5 Mosaic data augment

图 5 马赛克数据增强

制、动态蛇形卷积来解决上述问题^[33,34]。

SimDc 结构将输入特征图的通道维度分为两部分,如图 6 所示。首先,左半部分不作进一步计算而直接合并,最大限度地减少反向传播过程中的冗余梯度计算,降低计算和内存需求;其次,右半部分添加动态蛇形卷积和 SimAm 注意力机制,输出中一个用于拼接操作,另一个再次通过动态蛇形卷积与 SimAm 注意力机制进行处理;最后,将 4 个输出分支拼接,并使用 1×1 卷积进行通道调整后传递到下一个模块。实验表明,SimDc 模块相较于基线 ELAN 模型能更有效地提取特征。

为了提升 SimDc 框架识别不规则目标的能力,既忽略了无关的背景元素,还采用了 SimAm 注意力机制。SimAm 让网络学习到更具区分性的神经元,先从当前神经元推理出三维权重,再反向优化神经元,从而有效解决钢材缺陷种类较多且各个种类间形状差异较大的问题。为此,本文加入 SimAm 注意机制,使网络检测不规则目标和形状差异显著的目标。

由于钢材缺陷形状不规则、目标较小且缺陷的种类多,标准卷积神经网络的卷积层在处理规则数据、网格状数据时效果较好,而对不规则扭曲的数据结构的有效性较




Fig. 6 SimDc module

图6 SimDc 模块

差。为此,SimDc引入动态蛇形卷积,通过动态调整卷积核的形状和大小来适应数据的不规则性,而卷积核根据数据结构进行调整,因此在SimDc模块中添加动态蛇形卷积可

弥补网络对不规则形状目标检测准确度较低的缺陷。

本文将SimAm注意力机制与动态蛇形卷积相结合,以提升教师学生网络的特征提取能力,增强模型对不同尺度、形状目标的感知能力,提升了模型准确性和鲁棒性。

2.4 空间深度卷积

通过钢材缺陷数据集发现,大多数缺陷都很小且分辨率较低,在特征提取过程中有效捕捉目标有一定的挑战,会降低检测准确性。学生教师网络通常使用二维卷积神经网络(Convolutional Neural Network, CNN)进行特征提取、融合,限制提取低分辨率图像和钢材缺陷数据集中微小目标的能力。为此,在框架中采用空间深度卷积替换标准的二维卷积,降低模型对高分辨率输入图像的依赖性,解决模型对小目标检测性能不高的局限性^[35]。

空间深度转换卷积(Spatial Depth Conversion Convolution, SPDConv)包括空间深度层和非步长卷积层。空间深度转换层将空间维度转换为通道维度,对特征图 x 进行下采样,增加通道维度来获取更多信息,如图7所示。




Fig. 7 SPDConv

图7 空间深度卷积

首先,输入特征图经过一个缩放因子降采样,将原始特征图分成若干子特征图;其次,将这些子特征图在通道维度进行连接,按比例因子的倍数缩小空间维度,按比例因子的平方倍数增加通道维度的数量;最后,每个输入的特征图像素都被分配到一个特定通道,使原始特征图的空间维度成倍缩小,平方倍的增加通道维度以获取更多特征图中的特征信息。

虽然空间深度层会降低特征图的空间维度,但有可能导致部分信息丢失、降低图像的可识别性,对检测细小的钢材缺陷十分不利,因为降低分辨率会使其更难识别。为此,在SPD层后通过一个非步长卷积层,即一个步长为1的卷积层解决该问题,如图7所示。由此可见,SPD层中的特征图会降低通道维度,而空间维度保持不变,添加该层可确保滤波器能在输入特征图上逐像素移动,有助于减少SPD层可能出现的过度采样问题。此外,使用步长卷积可能会丢失细节信息,因此采用非步长卷积保留更多的信

息。综上,将SPD层与非步长卷积相结合构成的空间深度卷积,可在不丢失信息的前提下降低空间维度,挖掘特征图中的更多信息,提升模型对低分辨率目标和小型目标的检测精度。

2.5 微小检测头

钢材中大部分缺陷都以小目标的形式分布,尺寸都非常小,在日常检测任务中经常会出现漏检、错检现象。为此,本文设计了一个SimDc模块,目的是改善模型检测不规则小目标的性能。同时,在检测头部网络设计了一种专门用于检测小目标的微小检测头,以解决小目标检测不理想的情况,如图8所示。

由此可见,颈部网络输出的4个检测分支分别为极小目标、小型目标、中型目标和大型目标。相较于原始图像而言,4个特征图的大小分别增加了4、8、16和32倍,分辨率越高的特征图用于检测较小的目标,分辨率越低的特征图用于检测较大的目标。具体地,分辨率较小的特征图中每

个像素对应原特征图中的范围更大,即感测区域更大,因此可检测到更大的目标;新增的极小目标检测头相较于原特征图进行了两次降采样操作,包含了待检测目标更丰富的底层特征信息,将颈部网络与骨干网络中相同大小的特征图融合后,可更有效、准确地检测小目标。




Fig. 8 Small detection head

图8 微小检测头

2.6 伪标签分配器

教师网络生成的伪标签必须经过筛选,才能选出可靠的伪标签进行后续计算。常规的伪标签分配器通过设置一个阈值 τ ,将得分低于 τ 的伪标签指定为背景伪标签,高于 τ 的伪标签指定为可靠伪标签,并将可靠的伪标签用于计算的学生网络的损失函数。

Efficient Teacher中的伪标签分配器采用了一种独特的策略,利用两个阈值 τ_1 、 τ_2 将伪标签分为可靠和不确定两组, τ_1 为低阈值、 τ_2 为高阈值。伪标签阈值得分低于 τ_1 的背景伪标签被过滤掉;阈值得分在 $\tau_1 \sim \tau_2$ 之间的伪标签被认为是不确定的伪标签;点数高于 τ_2 的伪标签被认为是可靠的伪标签。综上,利用学生网络计算损失函数时,先确定要使用哪个阈值范围内的伪标签,再使用不同的损失函数进行计算。

$$L_{total} = L_s^{cls} + L_s^{reg} + L_s^{obj} + L_{da} + \lambda(L_u^{cls} + L_u^{reg} + L_u^{obj}) \quad (1)$$

式中: L_{total} 表示总的损失; L_s^{cls} 表示标注数据分类损失; L_s^{reg} 表示标注数据回归损失; L_s^{obj} 表示标注数据置信度损失; L_u^{cls} 表示来自未标注数据的分类损失; L_u^{reg} 表示未标注数据回归损失; L_u^{obj} 表示未标注数据置信度损失; L_{da} 表示域自适应损失;超参数 λ 通常设置为3,目的是平衡标注数据与未标注数据的损失。

监督训练损失函数采用交叉熵函数CE定义,CIOU表示交并比, $X_{(h,w)}^{cls}$ 、 $X_{(h,w)}^{reg}$ 、 $X_{(h,w)}^{obj}$ 分别表示学生模型的分、回归和置信度输出, $Y_{(h,w)}^{cls}$ 、 $Y_{(h,w)}^{reg}$ 、 $Y_{(h,w)}^{obj}$ 分别表示标注值的分类、回归和置信度。

$$L_s = \sum_{h,w} CE(X_{(h,w)}^{cls}, Y_{(h,w)}^{cls}) + CIOU(X_{(h,w)}^{reg}, Y_{(h,w)}^{reg}) + CE(X_{(h,w)}^{obj}, Y_{(h,w)}^{obj}) \quad (2)$$

最后,无监督训练损失函数 L_u 为:

$$L_u = L_u^{cls} + L_u^{reg} + L_u^{obj} \quad (3)$$

$$L_u^{cls} = \sum_{(h,w)} (1\{p(h,w) \geq \tau_2\} CE(X_{(h,w)}^{cls}, Y_{(h,w)}^{cls})) \quad (4)$$

$$L_u^{reg} = \sum_{(h,w)} (1\{p(h,w) \geq \tau_2 \vee obj^* > 0.99\} CIOU(X_{(h,w)}^{reg}, Y_{(h,w)}^{reg})) \quad (5)$$

$$L_u^{obj} = \sum_{(h,w)} 1\{p(h,w) \leq \tau_1\} CE(X_{(h,w)}^{obj}, 0) + 1\{p(h,w) \geq \tau_2\} (X_{(h,w)}^{obj}, Y_{(h,w)}^{obj}) + 1\{\tau_1 \leq p(h,w) \leq \tau_2\} (X_{(h,w)}^{obj}, obj_{(h,w)}^*) \quad (6)$$

式中: $Y_{(h,w)}^{cls}$ 、 $Y_{(h,w)}^{reg}$ 、 $Y_{(h,w)}^{obj}$ 为伪标签分配器对特征图坐标 (h,w) 上的采样结果的分类、回归和置信度得分; $obj_{(h,w)}^*$ 为伪标签的置信度得分; $p(h,w)$ 为伪标签在坐标 (h,w) 上的得分; $1\{\cdot\}$ 为指示函数,如果满足条件 $1\{\cdot\}$,则输出1,否则输出0。

3 实验结果与分析

3.1 数据集

本文利用NEU-DET数据集进行实验,包含裂纹、夹杂、斑块、麻点、压入氧化皮和划痕等6种典型的钢材表面缺陷,每个类别包含300个缺陷图形,共计1800张图片^[36]。同时,按7:2:1的比例将图像划分为训练集、测试集和验证集,并将训练集分为已标记图像与未标记图像,最终得到训练集1260张图片,测试集360张图片,验证集180张图片,默认情况下将训练集的10%作为标记数据。

3.2 实验环境与评价指标

在NVIDIA RTX4090(24 GB内存)GPU和Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10 GHz上进行训练和测试;软件环境为Python 3.8、Pytorch 1.9、CUDA 11.1、cuDNN 8.0.5;训练配置为:批量大小为16,学习率为0.001,总共训练了150个epochs,EMA平滑超参数为0.999, $\tau_1=0.1$, $\tau_2=0.8$ 。同时,以mAP@0.5、mAP@0.5:0.95和参数量作为评价指标来验证所提方法的有效性。

3.3 实验结果

本文使用coco标准,在NEU-DET数据集中将所提方法与Efficient Teacher、Unbiased Teacher、Soft Teacher和Consistent Teacher等前沿方法进行比较;还与全监督方法Mamba Yolo-T、Yolov10s和Yolov11s进行比较,他们使用的训练集数量与半监督使用的有标签数量相同。实验结果如表1所示。

Table 1 Experimental results on NEU-DET dataset

表1 在NEU-DET数据集上的实验结果

Model	mAP@0.5	mAP@0.5:0.95	Params	Inference speed
	/%	/%	/MB	/ms
Efficient Teacher	58.4	26.9	6.42	6.6
Unbiased Teacher	57.4	23.6	41.48	34.1
Soft Teacher	57.3	25.5	41.40	29.7
Consistent Teacher	58.1	26.8	32.05	26.1
Mamba Yolo-T ^[37]	58.2	27.0	5.98	9.4
Yolov10s ^[38]	59.7	29.0	8.07	8.2
Yolov11s ^[39]	59.9	29.3	9.43	9.9
Ours	62.2	29.5	12.40	10.0

由此可知,本文模型相较于基线框架而言,mAP@0.5、mAP@0.5:0.95 分别提升 3.8%、2.6%。相较于 Consistent Teacher 而言,mAP@0.5、mAP@0.5:0.95 分别提升 4.1%、2.7%。同时,本文模型因使用了单阶段目标检测器 YOLOv7,使得模型参数较少。其他半监督方法在 mAP@0.5、mAP@0.5:0.95 中的准确率分别不到 58%、26%,而所提方法仅利用较少的参数即可实现较高的准确率。

在与全监督方法的比较结果中发现,所提模型在 mAP@0.5、mAP@0.5:0.95 中也均取得了最好的结果,虽然参数量略高,推理时间相较于基线模型和全监督模型存在差距,但能满足工业监控对实时性的要求。此外,训练与测试的损失函数曲线如图 9 所示。




Fig. 9 Training and test loss function curves

图9 训练和测试损失函数曲线

表 2 为不同学习率的实验结果。由此可知,学习率为 0.001 时 mAP@0.5 为 62.2%;学习率为 0.01 时 mAP@0.5 为 60.5%,下降的原因为模型参数更新幅度大,导致损失函数在最小值附近震荡,从而阻碍了收敛。当学习率为 0.000 1 时,mAP@0.5 为 60.7%,原因为模型卡在了局部最小值,或者模型卡在了鞍点附近,很难摆脱鞍点。

Table 2 Results of the learning rate ablation experiments

表2 学习率消融实验结果

lr	mAP@0.5/%	mAP@0.5:0.95/%
0.01	60.5(-1.7)	28.2(-1.3)
0.001	62.2	29.5
0.000 1	60.7(-1.5)	28.5(-1.0)

表 3 为不同批量大小的实验结果。由此可知,批量大小为 4 时,mAP@0.5 为 59.9%;批量大小为 8 时,mAP@0.5 为 60.8%;批量大小为 16 时,mAP@0.5 为 62.2%,原因为较

小的样本计算梯度导致梯度估计的噪声过大。当批量进一步增加到 32 时,mAP@0.5 为 61.2%,原因为较大的批量值容易使模型陷入局部最小值。

Table 3 Results of the batchsize ablation experiments

表3 批量大小消融实验结果

batchsize	mAP@0.5/%	mAP@0.5:0.95/%
4	59.9(-2.3)	28.2(-1.3)
8	60.8(-1.4)	28.6(-0.9)
16	62.2	29.5
32	61.2(-1.0)	28.8(-0.7)

表 4 为设置不同 τ_1 、 τ_2 的实验结果,本文实验的 $\tau_1=0.1$ 、 $\tau_2=0.8$,主要通过调节 τ_2 来调整可信伪标签的阈值。由此可知,当 $\tau_2=0.6$ 时,mAP@0.5 为 60.7%;当 $\tau_2=0.7$ 时,mAP@0.5 为 60.8%,原因为 τ_2 值过小会导致判定为可信的伪标签过多,错误的伪标签会干扰半监督的训练。当 $\tau_2=0.9$ 时,mAP@0.5 为 60.6%,原因为 τ_2 值过大会导致被标记为可信的伪标签数量过少,从而降低了模型的学习能力和泛化能力。

Table 4 Results of τ_1 and τ_2 ablation experiments

表4 τ_1 、 τ_2 消融实验结果

τ_1	τ_2	mAP@0.5/%	mAP@0.5:0.95/%
0.1	0.6	60.9(-1.3)	28.4(-1.1)
0.1	0.7	61.1(-1.1)	28.7(-0.8)
0.1	0.8	62.2	29.5
0.1	0.9	60.8(-1.4)	28.5(-1.2)

表 5 为不同超参数 λ 的实验结果。本文实验 $\lambda=3$,用来平衡标记数据损失函数与无标记数据损失函数,减小 λ 会导致无标记数据损失函数所占比重减小。例如, $\lambda=1$ 、2、4 时,mAP@0.5 分别为 58.8%、60.9%、59.8%,证明了适当的 λ 值才能提升模型准确度。

Table 5 Results of the λ ablation experiments

表5 λ 消融实验结果

λ	mAP@0.5/%	mAP@0.5:0.95/%
1	58.8(-3.4)	27.2(-2.3)
2	60.9(-1.3)	28.0(-1.5)
3	62.2	29.5
4	59.8(-2.4)	27.6(-1.9)

3.4 消融实验

在 NEU-DET 数据集上进行消融实验,以评估空间深度卷积、SimDc 模块、微小检测头及参数选择对模型的影响,实验结果如表 6 所示。模型 A 为基准模型 Efficient Teacher。

(1)模型 B。将模型中的普通二维卷积替换为空间深度卷积,以验证空间深度卷积模块的有效性。由此可知,加入空间深度卷积后可保留更多信息,提升模型对小目标、低分辨率目标的准确性,mAP@0.5、mAP@0.5:0.95 分别提升 1.6%、1.2%。

(2)模型 C。将模型 B 中的 ELEN 替换为 SimDc 模块,以评估 SimDc 模块的有效性。实验表明,加入动态蛇形卷

积、SimAm 注意机制可增强模型在复杂场景下的检测性能,mAP@0.5、mAP@0.5:0.95 分别提升 1.5%、1.3%。同时,为了测试微小检测头对小型目标的检测性能,在模型 C 中加入极微小检测头后,mAP@0.5、mAP@0.5:0.95 分别提升 0.7%、0.4%。

Table 6 Results of the ablation experiment
表 6 消融实验结果

Model	Model structure	mAP@0.5/%	mAP@0.5:0.95/%
A	Efficient Teacher	58.4	26.9
B	A+SPDConv	60.0(+1.6)	28.3(+1.2)
C	B+SimDc	61.5(+1.5)	29.1(+0.8)
D	C+Extreme tiny detect head	62.2(+0.7)	29.5(+0.4)

3.5 可视化结果

为了更好地揭示注意力机制提升模型特征提取能力的作用,将注意力机制进行特征热图可视化,如图 10 所示。图 10(a)为输入图像;10(b)为基线模型的热力图可视化结果;图 10(c)为加入 SimAm 注意力机制后的热力图可视化结果。




Fig. 10 Attention mechanism visualization heatmap results
图 10 注意力机制可视化热力图结果

由此可见,基线模型捕捉的缺陷目标不够清晰、缺陷特征不够明显;加入注意力机制后,钢材图像缺陷的特征热力图相更明显,证明了加入 SimAm 注意力机制能使模型关注到钢材的缺陷位置,可更好地检测缺陷特征。

本文还展现了所提模型与基线模型在 NEU-DET 数据集的检测结果,如图 11 所示。其中,左边为标签,中间为基线模型的检测结果,右边为所提模型的检测结果。

由图(11)a 可见,由于缺陷目标小、分布不集中、较为

复杂,baseline 模型出现了检测不准确的现象,而所提模型能完全检测到缺陷。由图(11)b 可见,由于图片清晰度不高,当目标不明显时 baseline 模型漏检了两个目标。由图(11)c 可见,在复杂的目标检测且目标较小的情况下,baseline 模型检测效果不佳,而所提模型效果优势明显,能检测到所有缺陷目标。




Fig. 11 Detection results of the proposed method and baseline
图 11 本文方法与基线的检测结果

4 结语

本文提出一种针对钢材缺陷目标的半监督检测模型。首先,评估钢材标注数据获取难度,考虑到半监督方法能更好地进行特征学习,提升模型对复杂特征的捕捉能力,因此选择半监督方法检测钢材缺陷;其次,发现钢材缺陷具有不规则特征和小目标的特点,便提出 SimDc 特征提取模块改进模型,通过 4 个分支融合提取的特征以提升模型特征提取能力;再次,为了应对微小目标和低分辨率钢材的挑战,设计空间深度卷积替换传统二维卷积以提升模型在这些任务中的精度;最后,通过加入微小检测头进一步提升模型检测头对小目标的检测性能。

在 NEU-DET 公共数据集的实验表明,所提模型的检测准确度优于其他目标检测模型,最佳的 mAP@0.5、mAP@0.5:0.95 分别为 62.2%、29.5%。同时,消融实验的结

果也证实了所提各模块对提升模型性能的有效性。然而, 本文研究依然存在一些不足, 未来将针对工业部署的特点, 在提升模型的检测能力的同时优化模型结构, 以满足轻量化的要求。

参考文献:

- [1] TANG B, CHEN L, SUN W, et al. Review of surface defect detection of steel products based on machine vision[J]. IET Image Processing, 2023, 17(2): 303–322.
- [2] YANG H, MA L, LI Z. Tracing China's steel use from steel flows in the production system to steel footprints in the consumption system[J]. Renewable and Sustainable Energy Reviews, 2023, 172: 113040.
- [3] LYU X, DUAN F, JIANG J, et al. Deep metallic surface defect detection: the new benchmark and detection network[J]. Sensors, 2020, 20(6): 1562.
- [4] AMIN D, AKHTER S. Deep learning-based defect detection system in steel sheet surfaces[C]// 2020 IEEE Region 10 Symposium, 2020: 444–448.
- [5] ATZLESBERGER J, ZAGAR B G, CIHAL R, et al. Sub-surface defect detection in a steel sheet[J]. Measurement Science and Technology, 2013, 24(8): 84003.
- [6] DROUBI M G, FAISAL N H, ORR F, et al. Acoustic emission method for defect detection and identification in carbon steel welded joints[J]. Journal of Constructional Steel Research, 2017, 134: 28–37.
- [7] BHATT P M, MALHAN R K, RAJENDRAN P, et al. Image-based surface defect detection using deep learning: a review[J]. Journal of Computing and Information Science in Engineering, 2021, 21(4): 40801.
- [8] WANG L, LIU X, MA J, et al. Real-time steel surface defect detection with improved multi-scale Yolo-v5[J]. Processes, 2023, 11(5): 1357.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137–1149.
- [10] YANG G, WANG J, NIE Z, et al. A lightweight Yolo8 tomato detection algorithm combining feature enhancement and attention[J]. Agronomy, 2023, 13(7): 1824.
- [11] WANG G, CHEN Y, AN P, et al. UAV-Yolov8: a small-object-detection model based on improved Yolo8 for UAV aerial photography scenarios[J]. Sensors, 2023, 23(16): 7190.
- [12] LIU Y C, MA C Y, KIRA Z. Unbiased teacher v2: semi-supervised object detection for anchor-free and anchor-based detectors[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 9819–9828.
- [13] HUA W, LIANG D, LI J, et al. Sood: towards semi-supervised oriented object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 15558–15567.
- [14] LIU L, ZHANG B, ZHANG J, et al. Mixteacher: mining promising labels with mixed scale teacher for semi-supervised object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7370–7379.
- [15] ZHANG J, LIN X, ZHANG W, et al. Semi-DETR: semi-supervised object detection with detection transformers[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 23809–23818.
- [16] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// 14th European Conference on computer vision, 2016: 21–37.
- [17] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2016: 779–788.
- [18] REDMON J, FARHADI A. Yolo9000: better, faster, stronger[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2017: 7263–7271.
- [19] FARHADI A, REDMON J. Yolo3: an incremental improvement[DB/OL]. <https://arxiv.org/abs/1804.02767>.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolo4: optimal speed and accuracy of object detection[DB/OL]. <https://arxiv.org/abs/2004.10934>.
- [21] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137–1149.
- [22] LI Z, WEI X, HASSABALLAH M, et al. A deep learning model for steel surface defect detection[J]. Complex & Intelligent Systems, 2024, 10(1): 885–897.
- [23] YU Z, WU Y, WEI B, et al. A lightweight and efficient model for surface tiny defect detection[J]. Applied Intelligence, 2023, 53(6): 6344–6353.
- [24] CHENG X, YU J. RetinaNet with difference channel attention and adaptively spatial feature fusion for steel surface defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1–11.
- [25] ZHAO W, CHEN F, HUANG H, et al. A new steel defect detection algorithm based on deep learning[J]. Computational Intelligence and Neuroscience, 2021(1): 5592878.
- [26] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(4): 1493–1504.
- [27] XU M, ZHANG Z, HU H, et al. End-to-end semi-supervised object detection with soft teacher[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 3060–3069.
- [28] LIU Y C, MA C Y, HE Z, et al. Unbiased teacher for semi-supervised object detection[DB/OL]. <https://arxiv.org/abs/2102.09480>.
- [29] TARVAINEN A, VALPOLA H. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results[DB/OL]. <https://arxiv.org/abs/1703.01780>.
- [30] WANG X, YANG X, ZHANG S, et al. Consistent-teacher: towards reducing inconsistent pseudo-targets in semi-supervised object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 3240–3249.
- [31] XU B, CHEN M, GUAN W, et al. Efficient teacher: semi-supervised object detection for Yolo5[DB/OL]. <https://arxiv.org/abs/2302.07577>.
- [32] WANG C Y, BOCHKOVSKIY A, LIAO H Y. Yolo7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464–7475.
- [33] YANG L, ZHANG R Y, LI L, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]// International Conference on Machine Learning, 2021: 11863–11874.
- [34] QI Y, HE Y, QI X, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 6070–6079.
- [35] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases, 2022: 443–459.
- [36] BAO Y, SONG K, LIU J, et al. Triplet-graph reasoning network for few-shot metal generic surface defect segmentation[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1–11.
- [37] WANG Z, LI C, XU H, et al. Mamba YOLO: SSMS-based yolo for object detection[DB/OL]. <https://arxiv.org/abs/2406.05835>.
- [38] WANG A, CHEN H, LIU L, et al. Yolo10: real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2024, 37: 107984–108011.
- [39] KHANAM R, HUSSAIN M. Yolo11: an overview of the key architectural enhancements[DB/OL]. <https://arxiv.org/abs/2410.17725>.

(责任编辑: 刘嘉文)