

特异小样本工业产品表面缺陷检测方法研究

郑李明¹, 许天赐², 高浩然², 李庆华³, 胡晨光², 窦智²

(1.金陵科技学院 机电工程学院, 南京 211169; 2.河南师范大学 计算机与信息工程学院, 河南 新乡 453007; 3.莱芜钢铁集团银山型钢有限公司, 济南 271104)

摘要: 基于机器视觉的工业产品表面缺陷检测设备和系统大量应用在工业制造领域, 目前其难点在于工业检测数据的采集, 由于训练样本缺失导致深度学习网络模型无法有效训练. 为解决上述问题, 首先, 提出一种基于不规则掩码的伤痕样本生成算法, 改善了钢板表面缺陷检测任务中特异小样本数据集正负样本不均衡的情况; 然后, 在YOLOv8主干网络引入MHSA多头自注意力, 提高对钢板表面缺陷的关注度; 最后, 使用SiOU替换原损失函数, 增强网络模型的定位能力, 提高检测的准确性. 基于热轧钢板表面缺陷检测问题的实验结果表明, 该方法能够有效解决特异小样本工业探伤的具体问题.

关键词: 深度学习; 目标检测; YOLOv8; 注意力机制; 数据增强; 特异小样

中图分类号: TP391.41

文献标志码: A

文章编号: 1000-2367(2024)06-0088-09

近年来市场对工业制造领域产品外观及表面质量的要求越来越高, 促使制造企业不断提高制造工艺和方法. 但是, 这仍然无法避免缺陷产品的出现. 目前, 基于深度学习的视觉探伤已经在工业检测领域中成为一种趋势. 但其难点在于如何通过工业检测数据采集、训练样本集的生成及深度学习算法改进等手段, 使机器视觉技术在工业检测领域的应用中具有对特异性的小样本数据进行有效识别与检测的能力.

本文所述的特异小样本数据是指在工业领域中会出现因制造设备故障或制造工艺未正确执行而产生的质量缺陷产品的样本数据. 这类样本数据具有特异性、小样本的特点. 由于该类缺陷的出现具有偶然性, 因此样本的数据量较少, 这给需要大数据支撑的深度学习算法带来了挑战.

钢板是制造业中的基础产品, 广泛应用于船舶、汽车、航空、建筑等领域, 因此用户对其表面缺陷的质量要求严格. 比如: 近年来, 风力发电作为一种清洁可再生能源, 对于实现国家的低碳能源体系转型越来越重要. 因此, 国内出现了一大批风力发电站项目, 带动了制造风力发电系统立柱的风电钢板需求激增, 而风力发电机立柱的生产对钢板表面上的微细裂纹、结巴、划伤等缺陷非常敏感. 这些缺陷一旦流入到用户环节, 将会带来不可预估的事故, 制造企业将可能面临巨额的索赔. 如何对钢板表面缺陷样本数据进行有效处理, 产生缺陷种类均衡的训练样本集, 即对所有类型训练样本的数量、各类型样本集特征遍历程度都较为均等. 从而, 解决样本不均衡导致的多分类器识别率及精度的参差问题, 是钢板表面缺陷检测中具有挑战的问题.

近年来, 大多数较为先进的目标检测算法都使用了卷积神经网络模型(Convolutional neural network, CNN), 并且在目标检测任务中表现出优异的检测效果, 如一阶段检测器SSD^[1]和YOLO^[2]等, 二阶段检测器Faster R-CNN^[3]、R-FCN^[4]等. 一些学者尝试将目标检测算法应用于工业检测中, LI等^[5]基于一阶段目标检测YOLO网络用来检测钢板表面缺陷. ZHANG等^[6]将YOLOv3^[7]用于桥梁的缺陷检测任务上, 通过迁

收稿日期: 2023-06-26; **修回日期:** 2023-08-20.

基金项目: 国家自然科学基金(1904123; 61901160); 山东钢铁股份有限公司科技创新项目(GF2023014B).

作者简介(通信作者): 郑李明(1974—), 男, 江苏南京人, 金陵科技学院副教授, 博士, 研究方向为机器视觉及机器人学, E-mail: zlmhost@jit.edu.cn.

引用本文: 郑李明, 许天赐, 高浩然, 等. 特异小样本工业产品表面缺陷检测方法研究[J]. 河南师范大学学报(自然科学版), 2024, 52(6): 88-96. (Zheng Liming, Xu Tianci, Gao Haran, et al. Research on the detection method for special small-sample defects in industrial products[J]. Journal of Henan Normal University(Natural Science Edition), 2024, 52(6): 88-96. DOI:10.16366/j.cnki.1000-2367.2023.06.26.0001.)

移学习方法来优化原网络的检测性能。CHEN 等^[8]尝试将 DenseNet^[9]嵌入到 YOLOv3 网络结构中,使改进后的网络能够更好地应用于 LED 缺陷检测任务上。曹义亲等^[10]提出了一种改进 YOLOv5 的钢材表面缺陷检测算法。

与传统的人工检测相比,上述方法提高了制造业中的产品质检效率和准确率,降低人工成本。值得注意的是,制造业中良品率比较高,有缺陷的样本数量较少,会导致正负样本极度不均衡,而且行业数据有其特殊的商业价值和保密性特征,公开率极低,有效的训练样本难以获得,这给深度学习的应用带来了难度。此外,该领域对检测精度的要求很高,传统的互联网模式下的深度学习难以适应工业领域的要求。

针对热轧钢板缺陷中的特异小样本缺陷检测问题,本文提出了一种全新的钢板表面缺陷图像采集方法,通过新的算法扩增特异小样本缺陷数据以生成训练样本集,并通过在 YOLOv8 模型中增加注意力机制以提高热轧钢板缺陷中的特异小样本缺陷检测的精度和召回率的方法。

本文中主要贡献总结如下:(1)提出了一种全新的钢板表面缺陷图像采集系统方案,并在钢铁企业的工业现场中得到应用。(2)针对热轧钢板缺陷中的特异小样本缺陷的特点,提出了新型样本扩增算法,经过实验验证效果良好。(3)改进了 YOLOv8 模型,提升了网络模型的检测精度,大大降低了误检率,使之能够更好地应用于热轧生产线上特异小样本缺陷检测。

1 相关工作

1.1 数据采集

随着互联网相关技术(大数据、云计算、深度学习人工智能等)不断在 C 端市场中取得技术突破和应用成果,工业领域也不断将这些相关技术应用在其 B 端市场中,如生产、制造、物流、管理等领域,从而孕育出了工业互联网的概念。但是,工业互联网并不是简单将现有互联网技术应用在工业领域,而是具有其自身的特点:①硬件方面需要采用工业级数据采集专业设备(注:通常这些设备需要针对特定的应用领域进行专业化的定制开发),并融入物联网技术以实现设备和系统的网络化和模块化;②软件方面需要采用互联网软件架构思想,设计开发出能适应工业应用领域定制化且能快速响应用户需求的工业级软件系统。

将当前在 C 端市场上应用成熟的互联网技术通过专业化的深度开发,同时应用大数据、云计算及深度学习、人工智能等技术,融入互联网的思维,开发出具有互联网架构思想的工业互联网智能检测系统,已经成为工业产品表面缺陷检测技术发展的趋势。本节将简要介绍一下研究团队在热轧宽厚钢板表面缺陷自动检测系统开发项目中新型的数据采集系统,以说明本文中所使用的工业数据获取的方法。

1.2 新型热轧钢板检测图像采集系统

目前常用的热轧钢板检测图像的采集系统主要采用单色光源+线阵扫描摄像机的采集方式,即在不同光源条件下,将光源照射到钢板表层,然后 CCD 摄像机能够接收经过钢板的反射光线或散射光线进行扫描成像,图像的所有信息输入计算机终端^[11],如图 1 所示。

本研究团队提出了一种新型的热轧钢板检测图像的采集系统,即采用彩色面阵摄像机+新型白色 LED 同轴光源图像采集(图 2),对运动钢板进行视频流图像采集。

面阵摄像机在钢板的宽度方向上组成相机阵列,通过时间同步信号实现图像采集的同步性,从而实现钢板图像在时间和空间维度上的二维图像数据采集,如图 3 所示。




图1 基于机器视觉的钢板在线检测系统

Fig. 1 On-line inspection system of steel plate based on machine vision

采用彩色面阵摄像机+新型白色 LED& 同轴光源图像采集方案与常用的单色光源+线阵扫描摄像机的采集方案存在以下优势。

①采用面阵摄像机采集图像对钢板运动速度变化不敏感。即线阵摄像机在钢板检测时要求钢板的运动必须是匀速运动,否则很难标定钢板缺陷的准确大小,会出现钢板运动速度快时图像在线扫垂直方向上被压缩,反之则被拉伸的现象,从而造成图像失真较大。对于面阵摄像机来说,则不存在这种情况。

②钢板在辊道上运动时会出现上下摆动,其幅度可达 50 mm,通常线阵摄像机允许的钢板摆动幅度在 0~20 mm 范围内,而面阵相机允许的钢板摆动幅度在 0~120 mm 范围内^[5]。因此,面阵相机更适合钢板表面缺陷图像的动态采集。

③单色光源+线阵扫描摄像机采集的钢板图像为灰度图像,与彩色面阵摄像机+新型白色 LED& 同轴光源缺少了彩色通道上的信息,降低了缺陷识别的维度。

1.3 训练样本集的生成方法

①样本层面的解决方案:通过基于统计特征分析的数据增强算法实现样本的类间均衡化,解决样本的类间参差,从而解决分类器的准确度和精度参差。首先分析和挖掘各类伤痕对应样本的统计特征;然后以统计特征为导引,对冗余的样本集合进行抽样,对欠规模样本集合进行模拟样本生成。通过该手段,在遵从样本原始统计特性的前提下,同时保证了样本的多样性,实现样本层面的均衡性。采用该样本集合簇训练神经网络分类器,可有效解决分类精度参差问题。

②目标函数权重参数簇优化层面的解决方案:设计权重系数簇联合优化方法,通过智能化调整各分类置信度系数,使整个分类器的综合分类精度和准确度趋于最优,从而实现系统性优化。

原始的分类结果可表示为: $C = \max(r_1, r_2, \dots, r_n)$, 其中 r_i 分别代表待检测目标属于第 i 类的置信度。为了解决该问题,将可调节的参数化权重引入该分类器决策过程,如: $C = \max(w_1 \cdot r_1, w_2 \cdot r_2, \dots, w_n \cdot r_n)$, 对待优化权重调节系数 $w_1, w_2, w_3, \dots, w_n$ 进行归一化,以系统识别率和准确度最大化作为优化目标,并将其纳入演化学习过程,实现多参数联合优化,从而有效提升系统性能。

③挖掘通用性分类强特征层面的解决方案:构建统一的特征向量空间,并设计专门的深度网络,学习和挖掘所有伤痕类型的共性特征分量,从中提取具有可分性的强特征集合,并建立低维强特征空间。基于该特征空间,设计多分类器,实现鲁棒的多种伤痕的识别与分类问题。




图2 面阵摄像机+新型白色LED&同轴光源图像采集
Fig.2 Area array camera+new white LED& coaxial light source image acquisition

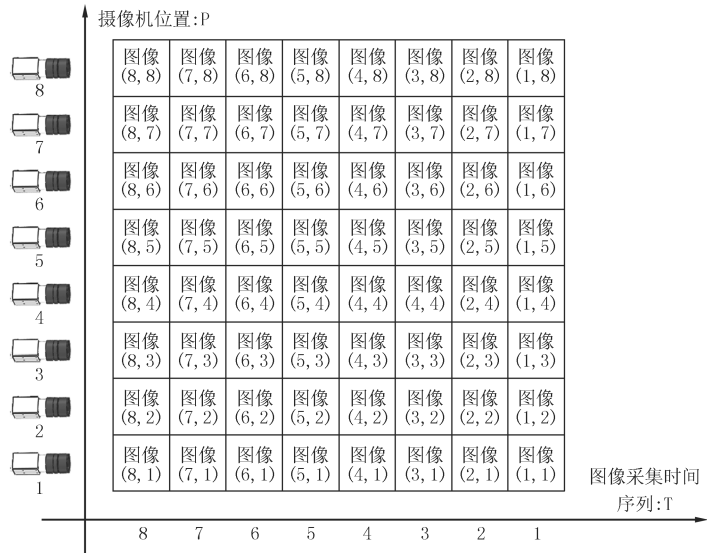


图3 钢板图像在时间和空间维度上数据采集
Fig.3 The steel plate images were collected in both temporal and spatial dimensions

2 特异小样本数据集生成及深度学习算法改进

2.1 基于不规则掩码的伤痕样本生成算法

由于制造业的品质管理,产品的次品率往往都控制在较低水平,导致缺陷数据集缺乏,且呈现特异性和小样本的特点.因此,如果要将深度学习应用于缺陷检测问题,就必须自己制作大规模的训练集.但是,特异性缺陷出现的概率极低,即使在线采集了数月,也只能得到十几张到几十张的缺陷样本.这样就无法有效地训练和优化深度网络,最终会导致检测失败,这在实验中有所体现.本文提出了一种基于不规则掩码的伤痕样本生成算法,该算法能够在遵从缺陷固有特征的前提下,生成大规模、高保真度和多样性强的样本集合,从而解决样本规模不足和样本不均衡问题.这使得将深度学习应用于特异性小样本目标检测问题具备较好的可行性.

首先,从采集到的良品集合中随机选取 N 个样本图像,对其求均值,得到背景模型 $I_B(x, y) = \frac{\sum_{i=1}^N I_i(x, y)}{N}$.其中, x, y 分别为样本图像中各像素的行、列坐标, I_i 表示选取到的第 i 个良品样本.

然后,通过边缘检测算法中的 Canny 算子进行边缘检测,其原理如下:计算图像灰度梯度,定义如式(1)所示.

$$G(x, y) = \sqrt{G_h(x, y)^2 + G_v(x, y)^2}, \quad (1)$$

其中, $G_h(x, y)$ 和 $G_v(x, y)^2$ 分别表示图像在水平和垂直方向上的梯度.第 1 步,计算非极大值抑制,即提取 $G(x, y)$ 的边缘特征

$$G_T(x, y) = \begin{cases} G(x, y), & G(x, y) > T, \\ 0, & \text{其他}, \end{cases} \quad (2)$$

其中, T 是边缘特征的阈值($T=0.76$).第 2 步,进行双阈值处理,将梯度图像 $G(x, y)$ 中的像素分为强边缘和弱边缘两部分,根据平均值和标准差计算出两个阈值 $T_1 = \mu_G - \sigma_G$ 和 $T_2 = \mu_G + \sigma_G$,其中, μ_G 和 σ_G 分别表示梯度的均值和方差.梯度值大于 T_1 的为强边缘,在 T_1 和 T_2 之间的为弱边缘,小于 T_2 的为非边缘.第 3 步,进行边缘连接操作,将弱边缘与强边缘相连,得到完整的边缘图像.第 4 步,通过统计钢板缺陷的特征得到伤痕的位置、大小、形状和透明度的出现概率,得到不同的掩码参数,用于生成不同的掩码伤痕形态.第 5 步,可以根据上述步骤得到的参数以及式(3)得到生成的 α 区域掩码图像:

$$M(x, y) = \sum_{i=1}^S \sum_{j=1}^V brush(x_j, y_j, \theta_j, w_i) * line(x_{j-1}, y_{j-1}, x_j, y_j, w_i) * ellipse(x_j, y_j, w_i), \quad (3)$$

其中,函数 $M(x, y)$ 表示生成的图像. x 和 y 分别表示图像上的像素坐标,而函数值表示在该像素处的颜色, S 表示伤痕数量, V 表示每条伤痕弯折次数, x_j 和 y_j 表示第 j 个弯折点的坐标, θ_j 表示第 j 个弯折点的弯折角度, w_i 表示第 i 条伤痕的宽度,函数 $brush(x_j, y_j, \theta_j, w_i)$ 表示在坐标 (x_j, y_j) 处,生成一条宽度为 w_i 、方向为 θ_j 的伤痕;函数 $line(x_{j-1}, y_{j-1}, x_j, y_j, w_i)$ 表示在点 (x_{j-1}, y_{j-1}) 和点 (x_j, y_j) 之间,生成一条宽度为 w_i 的伤痕;函数 $ellipse(x_j, y_j, w_i)$ 表示在坐标 (x_j, y_j) 处,绘制一个宽度为 w_i 的椭圆.

接着,将掩码 M 与背景 B 根据行、列的随机偏移量 h, w 进行融合,原理如式(4)所示:

$$I(i+h, j+w) = \begin{cases} 255, & M(i, j) > 0, \\ B(i+h, j+w), & M(i, j) = 0, \end{cases} \quad ((i, j) \in \alpha), \quad (4)$$

其中, I 表示融合后的新图像, $(i+h, j+w)$ 表示图像上的像素坐标,而 $B(i+h, j+w)$ 表示在该像素处的颜色, $M(i, j)$ 表示融合的掩码区域, h 和 w 表示随机融合的位置区域坐标.

最后,将上一步融合后的带有伤痕缺陷的图像 I 进行高斯模糊操作,使伤痕与背景更具有真实性,其公式如(5)所示:

$$F(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}, \quad (5)$$

其中, σ 表示标准差,用于控制高斯核函数的宽度, x 和 y 表示像素坐标.

本文生成算法有效消除了传统方法难以避免的融合痕迹,更加接近真实样本.生成样本的对比如图 4 所

示,其中左图为传统融合算法的生成样本,中图为本文算法的生成结果,右图为真实样本图.




图4 简单融合与mask生成伤痕对比

Fig.4 Simple fusion and mask generated scar contrast

基于不规则掩码的伤痕样本生成算法生成图像步骤如图 5 所示,其中左图分别为伤痕背景和 mask 掩码,中图为掩码融合后得到的样本图,右图为经过高斯模糊后得到的最终样本图.




图5 不规则掩码的伤痕图像产生步骤

Fig.5 Scar image generation step with irregular mask

2.2 MHSA 注意力模块

Transformer^[12]中的多头自注意力(multi-headself-attention, MHSA)模块,相较于普通的自注意力(self-attention, SA)^[13],MHSA 对注意力层进行了优化,支持多个“表示子空间”,有助于网络能够聚焦不同位置的能力,并行计算多个 Attention,通过多次计算来获取不同子空间上的相关信息,通过拼接进行融合,获得全局的数据特征信息,进一步的表示数据之间的相关性.其原理如图 6 所示.

在 MHSA 模块中对 V (值向量)、 Q (查询向量)、 K (键向量)进行自注意力变换, h 表示为 MHSA 模块中的头数.经历 h 次自注意力变换操作,接着将点积注意力的结果经过 Concat 拼接,然后再进行一次线性变换获得 MHSA 模块的最终输出.其原理就是利用多个独立的注意力计算,然后经过集成,其中每一个注意力机制函数对应着最终输出序列中一个子空间^[14].

2.3 优化损失函数

本文在实验中发现,原网络中的 CIoU^[15]损失函数,由于没考虑到所需真实框和预测框之间不匹配的方向,以至于模型收敛速度减慢、效率不高,导致模型的检测性能不高^[16].针对此问题,本文考虑所需回归之间的向量角度,重新定义惩罚指标,将原损失函数替换成 SIoU^[17]来提升网络的训练速度以及推理的准确性,见图 7.

(1)Angle cost.根据 α 的角度值来判断最小化的对象,当 α 小于 $\pi/4$,最小化 α ,反之将最小化 β .Angle cost 计算如式(6)所示.

$$\Lambda = 1 - 2 * \sin^2(\arcsin(x) - \frac{\pi}{4}), \quad (6)$$

其中, $x = \frac{c_h}{\sigma} = \sin(\alpha)$, $\sigma = \sqrt{(b_{c_x}^{g^t} - b_{c_x}^g)^2 + (b_{c_y}^{g^t} - b_{c_y}^g)^2}$, $c_h = \max(b_{c_y}^{g^t}, b_{c_y}^g) - \min(b_{c_y}^{g^t}, b_{c_y}^g)$.

(2)Distance cost.Distance cost 表示为真实的锚框和预测框的中心点之间的距离,SIoU 对 Distance cost 的重定义如式(7)所示.

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma \rho^t}), \tag{7}$$

其中, $\rho_x = (\frac{b_{c_x}^{g^t} - b_{c_x}}{c_w})$, $\rho_y = (\frac{b_{c_y}^{g^t} - b_{c_y}}{c_h})$, $\gamma = 2 - \Delta$. 当 α 逐渐接近于零时, Distance cost 的贡献会相应降低. 相对地, 当 α 越是无限接近于 $\pi/4$, 那么 Distance cost 贡献就会越大. 而且随着角度不断地增加, γ 将被赋予时间优先的距离值.




图6 多头注意力机制

Fig. 6 Multi-head attention mechanism




图7 SIoU损失函数

Fig. 7 SIoU function of loss

(3) Shape cost. Shape cost Ω 的定义如式(8)所示.

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega_t})^\theta, \tag{8}$$

其中, $\omega_w = \frac{|\omega - \omega^{g^t}|}{\max(\omega, \omega^{g^t})}$, $\omega_h = \frac{|h - h^{g^t}|}{\max(h, h^{g^t})}$. θ 的值是唯一存在, 表示为每个数据集的 Shape cost. 并且 θ 的值是非常重要的成分, 定义了 Shape cost 的关注程度, 当 θ 的值为 1 时. 它将优化 Shape 的长宽比, 以至于阻碍 Shape 的自由移动.

最终的 SIoU 损失函数定义如式(9)所示,

$$L_{\text{Siou}} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2}. \tag{9}$$

由于 Angle cost 的增加, SIoU 不仅可以获取到更加充分的表达, 而且还降低了惩罚项出现为零的概率, 这样会使得损失函数在收敛时更加稳定, 从而提升回归精度, 以便于减少预测的误差.

3 实验结果与分析

3.1 实验设定

在本文中, 实验所使用是 Linux 操作系统, GPU 采用 GeForce RTX 3090 的 24 GB 显卡, CPU 为 12th Gen Inter(R) core(TM) i9-12900 K, CUDA 版本为 11.7, CUDNN 版本为 8500, python 版本为 3.10.9, pytorch 版本为 1.13.1. 所有网络均未使用预训练模型, 设置训练轮次(epoch)为 300, 批量大小(batch size)为 16, 设置网络初始学习率为 0.01, 输入的图片尺寸大小统一缩放为 640×640 .

3.2 实验数据集

在实际现场工作中, 一般能采集到的伤痕数量很少, 并且大多是重复的, 不适用于网络训练. 因此对采集到的数据通过数据增强进行数据扩充, 使其能满足网络训练的需要.

本文使用的数据集共分为两种. 一种为钢板表面划伤数据集, 是从钢板生产过程中采集的划伤样本数

据,并对其进行了标注、分类,其中训练集图片有 37 张,验证集图片为 5 张,共计数据 42 张,包含 1 个种类.另一种为对钢板表面划伤数据集进行数据增强生成的数据集,其中训练集图片有 200 张,验证集图片为 37 张,共计数据 237 张.

3.3 评价指标

本实验中,以准确率、mAP 作为评价指标.准确率用来表示模型在实际检测任务当中,正确检测到的样本数量,占总样本数的比例.mAP 体现了目标检测网络的综合性能,其中 mAP 又分为 mAP_{0.5}、mAP_{0.5 : 0.95}.

3.4 消融实验

为了验证对 YOLOv8^[18] 模型修改的作用,在相同的实验环境和实验数据集上,对 YOLOv8 网络分别测试加入 MHPA 注意力机制和修改 SIou 损失函数的效果.实验结果如表 1 所示.

表 1 对 YOLOv8 不同的改进结果

Tab. 1 Different improvement results for YOLOv8

算法模型	mAP _{0.5} /%	(mAP _{0.5 : 0.95})/%	Precision/%	算法模型	mAP _{0.5} /%	(mAP _{0.5 : 0.95})/%	Precision/%
YOLOv8	83.0	46.3	74.4	YOLOv8+SIou	82.2	48.3	88.8
YOLOv8+MHPA	85.8	45.7	91.8	Ours	87.0	49.5	83.2

由表 1 可知,对 YOLOv8 加入注意力机制后,mAP_{0.5} 增加了 2.8%,Precision 增加了 17.4%,但是 mAP 出现了略微下降,降低了 0.6%.更换成 SIou 损失函数后,mAP_{0.5 : 0.95} 增加了 2.0%,Precision 上升了 14.4%,但 mAP 下降了 0.8%.而本文算法相比于原算法 mAP_{0.5} 增加了 4.0%,mAP_{0.5 : 0.95} 增加了 3.2%,Precision 增加了 8.8%.通过以上分析,可以验证本文所有的改进具有可行性.

3.5 实验对比分析

本节首先验证对数据集的数据增强是否有效.用 YOLOv8 模型依次对未进行数据增强的数据集(bruises-0)、增强 50 张图片的数据集(bruises-50)、增强 100 张图片的数据集(bruises-100)、增强 150 张图片的数据集(bruises-150)、增强 200 张图片的数据集(bruises-200)进行实验,实验的结果如表 2 所示.

表 2 不同数据集下的实验结果

Tab. 2 Experimental results under different data sets

数据集	mAP _{0.5} /%	(mAP _{0.5 : 0.95})/%	Precision/%
bruises-0	52.5	27.6	62.1
bruises-50	56.9	28.3	66.7
bruises-100	78.4	42.6	85.3
bruises-150	82.6	43.5	79.4
bruises-200	83.0	46.3	74.4

可以看出,数据集的图片数量增大时,模型的精度是呈现逐步上升趋势的,数据集从 150 增加到 200 张时,mAP_{0.5} 提升了 0.4%,mAP_{0.5 : 0.95} 也提升了 2.8%,但 Precision 却下降 5.0%.这个结果反映出,如果生成的样本占比过大,会导致过拟合现象发生.从上述表格数据中可知,本文的数据增强是有效果的.并综合各种评价指标与实验结果考虑,之后的对比实验数据集使用增强 200 张图片的数据集.

在表 3 中,对本文算法和现在流行的目标检测算法的效果进行了对比.

表 3 不同模型实验结果对比表

Tab. 3 Comparison table of experimental results of different models

算法模型	mAP _{0.5} /%	(mAP _{0.5 : 0.95})/%	Precision/%	算法模型	mAP _{0.5} /%	(mAP _{0.5 : 0.95})/%	Precision/%
YOLOv5 ^[19]	85.2	45.4	86.2	YOLOv8 ^[18]	83.0	46.3	74.4
YOLOv7 ^[20]	79.8	42.1	85.9	Ours	87.0	49.5	83.2

由表 3 可知,本文改进后的算法相比原算法模型 mAP_{0.5} 提升了 4.0%,达到了 87.0%;mAP_{0.5 : 0.95} 提升了 3.2%,达到了 49.5%;Precision 提升了 8.8%,达到了 83.2%.并且本文算法的 mAP 也超过了 YOLOv5^[19] 和 YOLOv7^[20],达到了最高.Precision 虽然略弱于它们,但是已经超过了 YOLOv8,综合起来性

能最优。

本文使用训练完成之后的 YOLOv8、YOLOv5、YOLOv7 以及本文算法从验证集中挑出 3 组图片进行检测,检测的结果如图 8 所示。




图8 检测结果图

Fig.8 Test result chart

从图 8 可以看出,本文改进后的算法相较于原 YOLOv8 的检测得分更高,漏检和错检的情况也有了改善.另外相比于其他的检测模型,使用后的检测得分也有提升.结果表明本文的数据增强算法和网络改进算法对钢板表面划伤的检测效果有一定的提升,有使用的价值。

4 总 结

针对钢板表面缺陷数据中存在特异小样本的问题,依托研发团队开发的新型热轧钢板检测图像采集系统所采集的数据,本文提出一种基于不规则掩码的伤痕样本生成算法,改善了钢板表面缺陷检测任务中特异小样本数据集正负样本不均衡的情况,极大地提高了特异小样本数据集检测的精度,为解决特异小样本问题提供了一个有效的方案.在深度学习算法上,本文又提出了一种改进 YOLOv8 网络的钢板表面缺陷检测方法,对原 YOLOv8 主干网络进行优化改进,便于更加高效地提取钢板表面缺陷的重要特征信息.加入 MHSA 多头自注意力,提高对钢板表面缺陷的关注度,同时对损失函数进行优化,使用 SIOU 替换原损失函数,增强网络模型的定位能力,提高检测的准确性.下一步,研发团队将在保证模型高检测精度的前提下,降低模型参数的规模,降低计算量,提升模型的检测速度,使之更适于实际应用。

参 考 文 献

- [1] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single shot multibox detector[C]//Computer Vision-ECCV 2016.[s.l.]:Springer International Publishing, 2016: 21-37.
- [2] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).[s.l.]:IEEE, 2017.
- [3] GIRSHICK R. Fast r-cnn[C]//Proceedings of the IEEE international conference on computer vision.[s.l.]:s.n.; 2015.
- [4] DAI J F, LI Y, HE K M, et al. R-FCN: object detection via region-based fully convolutional networks[EB/OL].[2023-05-17].<http://arxiv.org/abs/1605.06409v3>.
- [5] LI J Y, SU Z F, GENG J H, et al. Real-time detection of steel strip surface defects based on improved YOLO detection network[J]. IFAC-PapersOnLine, 2018, 51(21): 76-81.
- [6] ZHANG C B, CHANG C C, JAMSHIDI M. Bridge damage detection using a single-stage detector and field inspection images[EB/OL].[2023-05-17].<http://arxiv.org/abs/1812.10590v2>.
- [7] GONG C P, LI A J, SONG Y M, et al. Traffic sign recognition based on the YOLOv3 algorithm[J]. Sensors, 2022, 22(23): 9345.
- [8] CHEN S H, TSAI C C. SMD LED chips defect detection using a YOLOv3-dense model[J]. Advanced Engineering Informatics, 2021, 47: 101255.
- [9] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR).[s.l.]:IEEE, 2017.

- [10] 曹义亲,伍铭林,徐露.基于改进YOLOv5算法的钢材表面缺陷检测[J].图学学报,2023,44(2):335-345.
CAO Y Q,WU M L,XU L.Steel surface defect detection based on improved YOLOv5 algorithm[J].Journal of Graphics,2023,44(2):335-345.
- [11] 李美美.基于卷积神经网络的热轧钢板表面缺陷检测方法研究[D].鞍山:辽宁科技大学,2022.
- [12] 吴秀东.基于机器视觉的彩钢板表面缺陷检测与分类技术研究[D].淄博:山东理工大学,2019.
- [13] HAN L T,LYU H Y,ZHAO Y C,et al.Conv-former:a novel network combining convolution and self-attention for image quality assessment[J].Sensors,2022,23(1):427.
- [14] 谢镇域.基于注意力机制的序列建模与轻量化研究[D].北京:华北电力大学,2021.
- [15] ZHENG Z H,WANG P,REN D W,et al.Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J].IEEE Transactions on Cybernetics,2022,52(8):8574-8586.
- [16] 文斌,胡晖,杨超.基于LWN-Net的PCB缺陷检测算法[J].计算机集成制造系统,2024,30(2):496-507.
WEN B,HU H,YANG C.PCB defect detection based on LWN-Net algorithm[J].Computer Integrated Manufacturing Systems,2024,30(2):496-507.
- [17] GEVORGYAN Z.SIoU loss:more powerful learning for bounding box regression[EB/OL].[2023-05-16].<http://arxiv.org/abs/2205.12740v1>
- [18] KIM J H,KIM N,WON C S,et al.High-speed drone detection based on yolo-v8[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).[s.l.]:IEEE,2023.
- [19] GLENN J,CHAURASIA A,ALEX S,et al.Ultralytics/yolov5:V7.0-Yolov5 SOTA realtime instance segmentation[EB/OL].[2023-05-13].<https://ui.adsabs.harvard.edu/abs/2022zndo...7347926J/abstract>.
- [20] WANG C Y,BOCHKOVSKIY A,LIAO H Y M.YOLOv7:trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR).[s.l.]:IEEE,2023.

Research on the detection method for special small-sample defects in industrial products

Zheng Liming¹, Xu Tianci², Gao Haoran², Li QingHua³, Hu Chenguang², Dou Zhi²

(1. School of Mechanical and Electrical Engineering, Jinling Institute of Technology, Nanjing 211169, China; 2. School of Computer and Information Engineering, Henan Normal University, Xinxiang 453007, China; 3. Laiwu Iron and Steel Group Yinshan Section Steel Co., Ltd., Jinan 271104, China)

Abstract: Machine vision-based industrial product surface defect detection equipment and systems are widely used in the industrial manufacturing field. Currently, the main difficulty lies in the collection of industrial inspection data and the inability of deep learning network models to be effectively trained due to the lack of training samples. To solve these problems, firstly, this paper proposes a scar sample generation algorithm based on irregular masks to improve the imbalance of positive and negative samples in the special small sample dataset for steel plate surface defect detection task; then, the MHSA multi-head self-attention is introduced into the YOLOv8 backbone network to enhance the attention to steel plate surface defects; finally, the Siou loss function is used to replace the original loss function to enhance the network model's localization ability and improve detection accuracy. The experimental results on the hot rolled steel plate surface defect detection problem based on this method show that can be effectively solved.

Keywords: deep learning; object detection; YOLOv8; attention mechanism; data enhancement; special small samples

[责任编辑 陈留院 赵晓华]