

DOI: 10.13382/j.jemi.B2508486

# 改进 DRAEM 的非监督纤维绳索表面缺陷检测算法\*

方忠志 朱华波 陶友瑞 石 泽

(河北工业大学机械工程学院 天津 300401)

**摘要:**针对细小纹理以及背景复杂的场景中纤维绳索表面缺陷检测存在小目标漏检率高、检测精度低和算法鲁棒性不足等问题,提出了一种基于判别式训练重建嵌入模型(discriminatively trained reconstruction embedding for surface anomaly detection, DRAEM)改进的纤维绳索表面缺陷算法。在预处理部分加入 GrabCut 分割算法提取每张图像的掩码,通过掩码约束异常生成减少背景影响,以避免复杂背景造成的误检的问题;在重构网络中加入跳跃连接来捕获高维图像空间正态数据分布,并添加通道和空间双重注意力模块以强调对异常区域重建的能力,以提高细小纹理的重构效果避免纹理丢失而导致小尺度缺陷漏检的问题;在分割网络编码器后两层加入 Transform 模块优化对正常与异常的级联的全局特征的捕捉;同时用空洞空间金字塔池化(atrous spatial pyramid pool, ASPP),捕获不同尺度的上下文信息进行全局特征聚合,为分割提供足够的语义差异,以提高模型的分割精度和表面小目标缺陷的检测精度。实验结果表明,与原 DRAEM 对比图像级 AUROC 提高了 4.4%,像素级 AUROC 提高了 4.43%,像素级平均精度提高了 21.86%,提高了模型的识别精度与鲁棒性,更好地应用于纤维绳索的缺陷检测。

**关键词:** 纤维绳索;表面缺陷检测;DRAEM**中图分类号:** TP391.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Improved unsupervised DRAEM algorithm for surface defect detection in fiber ropes

Fang Zhongzhi Zhu Huabo Tao Yourui Shi Ze

(School of Mechanical Engineering, Hebei University of Technology, Tianjin 300401, China)

**Abstract:** To address the issues of high missed detection rates for small targets, low detection accuracy, and insufficient algorithm robustness in fiber rope surface defect detection under scenarios with fine textures and complex backgrounds, this paper proposes an improved fiber rope surface defect detection algorithm based on the unsupervised model a discriminatively trained reconstruction embedding for surface anomaly detection (DRAEM). In the preprocessing stage, the GrabCut segmentation algorithm is incorporated to extract masks for each image, reducing background interference through mask-constrained anomaly generation and mitigating false positives and missed detections caused by complex backgrounds. In the reconstruction network, skip connections are introduced to capture high-dimensional image space normal data distributions, and a dual channel-spatial attention module is added to enhance the reconstruction capability for anomalous regions, to improve the reconstruction quality of fine-scale textures, thereby avoiding texture loss and preventing the missed detection of small-scale defects. In the segmentation network, Transformer modules are integrated after the last two layers of the encoder to optimize the capture of cascaded global features between normal and abnormal regions. Additionally, atrous spatial pyramid pooling (ASPP) is employed to capture multi-scale contextual information for global feature aggregation, providing sufficient semantic differentiation for segmentation and enhancing the model's segmentation accuracy and the detection accuracy of small surface defects. Experimental results demonstrate that, compared to the original DRAEM, the proposed method achieves a 4.4% improvement in image-level AUROC, a 4.43% increase in pixel-level AUROC, and a 21.86% boost in pixel-level average precision. These enhancements significantly improve the model's recognition accuracy and robustness, making it more effective for fiber rope defect detection applications.

**Keywords:** fiber ropes; surface defect detection; DRAEM

收稿日期: 2025-06-21 Received Date: 2025-06-21

\* 基金项目: 国家自然科学基金联合基金项目(U23A6017)、石家庄市科技项目(SJZZXA24005, SJZZXC24002)、石家庄科技局项目(SJZZXC23002)资助

## 0 引言

纤维绳索表面缺陷检测在工业安全领域具有关键性作用,直接影响绳索的承载能力、耐久性及工程可靠性。尤其在深海工程、船舶系泊、建筑吊装、消防救援及高空作业等场景中,纤维绳索作为核心承力部件,其表面完整性直接关系到人员安全和设备稳定性。纤维绳索表面缺陷主要包括断丝、局部磨损、烧损、断裂以及脏污等,以上缺陷均可能导致绳索强度骤降,甚至造成灾难性断裂事故。因此,实现纤维绳索表面缺陷的精准识别与评估,是保障工程安全的重要环节。传统检测手段多依赖于人工目检,存在检测效率低、主观偏差大和小目标缺陷识别能力弱等局限,特别是在户外复杂背景及大规模绳索检测需求下难以保证检测准确度和效率<sup>[1]</sup>。近年来,深度学习技术进入快速的发展<sup>[2]</sup>,涌现出各种表面缺陷检测模型,表面缺陷检测的精度与速度不断提升,为解决纤维绳索复杂表面缺陷的精准识别提供了新的可能<sup>[3]</sup>。

基于深度学习的表面缺陷检测算法根据模型对训练数据集的标注信息不同,分为监督学习、半监督学习和非监督学习<sup>[4]</sup>。随着深度学习技术的不断发展,目前非监督的表面缺陷检测方法逐渐成熟,通过学习正常样本的特征分布或使用合成缺陷样本进行训练,从而显著减少了数据标注的工作量<sup>[5]</sup>。特别是在缺陷样本获取难度大导致数据集有限或者缺陷可能具有模糊的边缘以及不规则形状的情况下,非监督学习方法具有更高的灵活性。在非监督缺陷检测方法中,最常用的表面缺陷检测方法主要包括基于重构的方法、基于嵌入相似度的方法和基于合成的方法<sup>[6]</sup>。

基于重构的方法通过训练对正常图像的重建来定位缺陷。最常见的是基于自编码器和生成对抗网络的模型对正常图像进行编码和重构。AnoGAN<sup>[7]</sup>是第一次将生成对抗网络(generative adversarial network, GAN)引入缺陷检测的方法,通过不断迭代优化潜在向量,减少重构损失定位缺陷,不过该方法的耗时太长,需要大量的推理时间。于是 Akcay 等<sup>[8]</sup>提出了 GANomaly 模型,该模型引入编码器直接生产潜在向量减少耗时,并根据对抗损失、重构损失和潜在空间损失的组合来提高重建质量定位缺陷。为了进一步提高重建图像的质量, Akcay 等<sup>[9]</sup>进一步提出了 Skip-GANomaly,在编码器和生成器之间添加了 Skip-connection,改进了基于 GANomaly 的损失函数,充分融合了正常样本的多尺度特征。然而基于重构的方法的网络有时能够被泛化,也可以很好地重建异常输入,从而导致错误的异常检测。

基于嵌入的方法使用预训练的模型来提取广义正态特征,然后采用多元高斯分布、记忆库和归一化流等统计

算法嵌入正态特征分布,通过将输入特征与学习的分布进行比较来定位异常。Defard 等<sup>[10]</sup>提出 PaDim 模型,将图像分块,利用预训练模型提取每个位置特征,并估计其均值和协方差矩阵,建立高斯模型计算 Mahalanobis 距离,得到异常图,降低了计算成本,在 MVTEC AD<sup>[11]</sup>等工业检测数据集上优于多数 GAN 和 Autoencoder 方法。PatchCore<sup>[12]</sup>使用一个最大代表性的记忆库来存储正常的补丁特征,将提取特征进行局部领域聚合,提出核心采样算法减少内存库规模,根据最近邻距离生成异常热力图。然而,工业图像通常与预训练模型的数据集不同,直接使用预训练的特征可能会导致不匹配问题过大等问题。

基于合成的方法通过对无异常图像模拟异常进行训练来判别是否异常。Zavrtanik 等<sup>[13]</sup>提出一种基于判别式训练重建嵌入模型(discriminatively trained reconstruction embedding for surface anomaly detection, DRAEM),通过将数据增强后的 Perlin<sup>[14]</sup>噪声异常添加到正常图像上来训练重构子网络和判别子网络,但是在纹理复杂的场景中,可能因重构误差波动导致误检。Liu 等<sup>[6]</sup>提出了一种高效且轻量的模型 SimpleNet,利用预训练 WideResNet50<sup>[15]</sup>提取特征,引入了特征适配器将局部特征转移到目标域,实现了高效的推理。Rolih 等<sup>[16]</sup>在 SimpleNet 的基础上提出了 SuperSimpleNet,将单独的分类头集成到模型中,增强了图像的全局上下文和异常检测能力,但是太过于依赖 backbone,如果 backbone 无法提取有意义的特征,异常检测性能会显著下降。基于合成的异常缺陷与真实异常并不完全匹配,这意味着模糊缺陷可以包含在分布特征空间中,从而导致误检。

尽管已有研究的非监督表面缺陷检测算法取得了一定的进展,但针对纤维绳索在工业场景中背景引起误检、小目标漏检率高和检测精度低的问题。本文提出了一种基于 DRAEM 改进的纤维绳索表面缺陷检测算法。通过 GrabCut 算法提取绳索部分的区域与掩码,仅在绳索区域加入合成异常,避免背景的影响导致误检。受 Skip-GANomaly 启发,在重构子网络间添加了 Skip-connection,同时在最后一层添加了异常适配模块,提高异常重构效果,防止纹理丢失导致小尺度缺陷漏检的问题。在分割子网络编码器后 2 层添加 Transform 模块<sup>[17]</sup>优化网络的全局特征提取能力;在分割前,加入空洞空间金字塔池化(atrous spatial pyramid pool, ASPP)<sup>[18]</sup>,实现通过多尺度特征提取和全局上下文信息聚合,来提升缺陷检测精度。实验结果表明,在纤维绳索的表面缺陷检测任务中拥有更高的准确性和更好的泛化性能。

## 1 非监督异常检测 DRAEM 算法改进

表面缺陷检测作为工业检测中的重要任务,旨在识

别和定位捕获对象表面的异常区域。Zavrtnik 等<sup>[13]</sup>提出了由重构子网络和判别子网络组成的 DRAEM 模型,训练重构子网络进行无异常重构,而判别子网络在原始图像和重建图像的级联上训练判别模型,生成异常检测图,来区分正常与异常区域的差异实现对异常的直接定位。本文在 DRAEM 模型的基础上进行改进,如图 1 所示。它首先通过 GrabCut 算法对数据集进行预处理,将

图像中的绳索区域进行分割,利用分割出来的掩码图应用于异常图像的生成。随后将合成异常图像通过重构子网络重构出正常图像,重构子网络为编码器-解码器架构。本文在重构子网络架构中创新性引入跳跃连接以及异常适配模块;在判别子网络结构中本文引入 Transform 模块和 ASPP 来优化特征融合,为后续创造足够的语义信息。

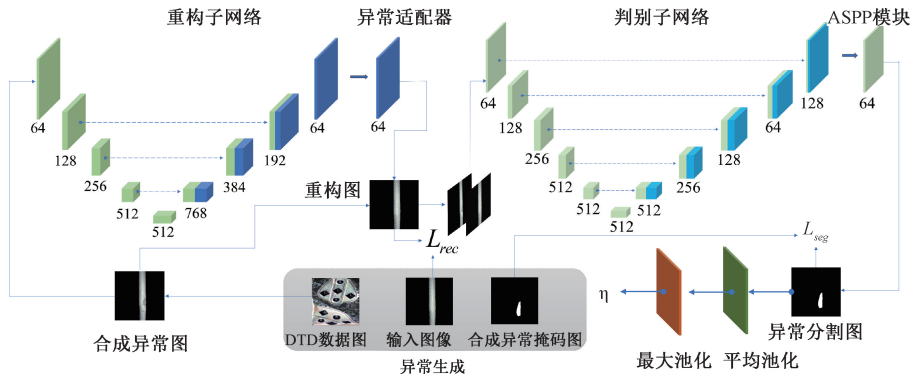


图 1 改进 DRAEM 异常检测算法网络结构

Fig. 1 Network architecture of the improved DRAEM algorithm for anomaly detection

### 1.1 数据预处理与异常生成

在实际工业场景的应用中,获取的纤维绳索图像往往具有复杂的背景,干扰网络的训练,从而影响网络模型的准确性和鲁棒性易产生误检的现象。针对上述问题,本文增加预处理部分,通过 GrabCut 算法分割绳索区域,如图 2 所示。

过迭代的方式,将图像中的前景和背景进行分割。为了寻找包含绳索区域的矩形框,对于绳索图像先进行灰度化处理转为灰度图,再通过高斯模糊对绳索边缘进行降噪处理,将模糊后的图像进行 Otsu 自动二值化处理,即可获得绳索区域轮廓与初始矩形框,最终通过 GrabCut 算法迭代分割出绳索以及对应的掩码图像,如图 3 所示。

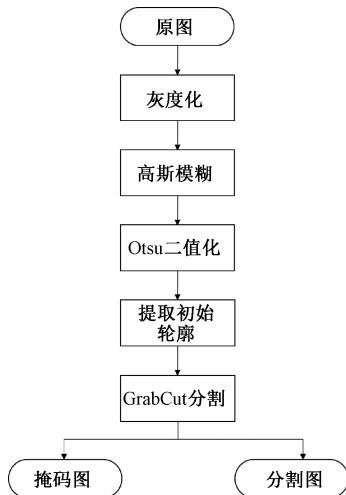


图 2 绳索预处理背景分割流程

Fig. 2 Flowchart of the preprocessing pipeline for background segmentation of rope images




图 3 绳索预处理背景分割效果

Fig. 3 Visualization of background segmentation preprocessing for rope images

在本文异常生成中使用二值化柏林噪声填入可描述纹理数据集 (describable textures dataset, DTD) 的方式来创建异常,异常生成遵循如下原则:不需要模拟真实的异常外观特征,只需通过生成分布外特征的数据来训练模型区分正常与异常数据的能力,如图 4 所示。

将异常数据源图像 A 从进行如下 3 种随机数据增强:色调分离、锐度调整、中途曝光、直方图均衡化、直方图均衡化、亮度调整、颜色调整和自动对比度。由

GrabCut 算法是一种基于图割理论和高斯混合模型 (gaussian mixture model, GMM) 的图像分割算法。它通

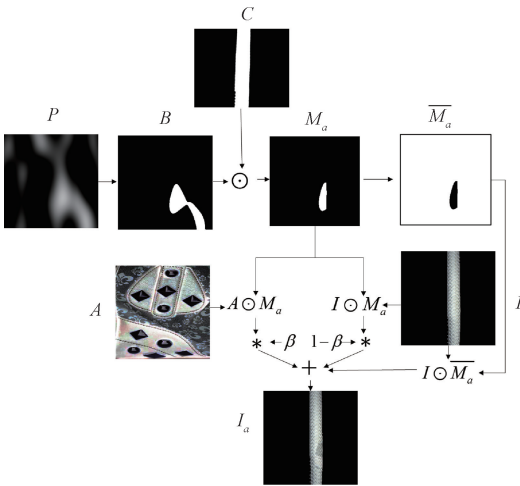


图 4 模拟异常图像生成流程

Fig. 4 Flowchart of the process for simulating synthetic anomaly images

Perlin<sup>[14]</sup> 噪声生成器生成噪声图像通过随机均匀采样的阈值二值化为异常图  $B$ ，再将异常图  $B$  与绳索分割之后的掩码图  $C$  相乘得图  $M_a$ ，增强后的图像  $A$  与噪声图  $M_a$  相乘，并与原图  $I$  混合生成最终异常图  $I_a$ ，如式 (1) 所示。

$$I_a = \overline{M_a} \odot I + (1 - \beta)(M_a \odot I) + \beta(M_a \odot A) \quad (1)$$

式中： $\overline{M_a}$  为  $M_a$  的补矩阵， $\beta \in [0.1, 1.0]$  为不透明度参数。在自制纤维绳索数据集中，真实的异常只存在于绳索区域，且背景部分产生异常会干扰网络学习，所以使用 GrabCut 分割产生的掩膜约束图像的区域异常生成，使得生成的异常全部位于绳索区域中，如图 5 所示。




图 5 绳索模拟异常合成

Fig. 5 Simulated synthetic anomaly image of rope

### 1.2 重构子网络

重构子网络通过隐式学习策略实现异常区域的检测与重建，在保持输入图像正常区域完整性的同时，异常区域重建出合理的无异常内容。DRAEM 模型的原始重构子网络架构中，编码器模块采用四级渐进式下采样结构：每级由两组卷积核尺寸为  $3 \times 3$ 、步长为 1 的卷积层与核尺寸为  $2 \times 2$ 、步长为 2 的最大池化层组成。通过 4 次下采样将输入张量大小为  $256 \times 256$  的图像转换为大小为  $16 \times 16$  的张量，但这意味着，重构图像是由编码器底层  $16 \times 16$  分辨率的特征图上经过解码器 4 层卷积和上采样得到的，对于目标较为明显且纹理简单的图像表现较好，

可以创建足够的重构误差，这种 4 次指数级降采样策略虽然有效扩大了高层特征的感受野，但不可避免地导致空间分辨率过度衰减，这种纯卷积深层网络会优先保留语义信息而牺牲纹理细节。对纤维绳索这种重复纹理性且复杂度较高的图像无法保证很好的纹理重构效果。

该架构在表面缺陷检测任务中对高对比度和全局性异常比如金属划痕及涂层脱落情况下表现出较好的泛化性能，其重构误差主要来源于语义级特征差异。然而，当处理纤维绳索等具有复杂拓扑结构的细粒度纹理样本时，卷积层会造成高频纹理信息的不可逆损失。具体而言，纤维绳索的细小纹理特征在 4 次池化过程中被过度平滑，而解码器的浅层卷积层缺乏足够的参数容量来建模此类非结构化纹理的生成先验。此外，对抗训练中判别器对没有足够语义信息的低分辨率特征图，难以保证纤维绳索拓扑结构的一致性，最终导致异常定位热图在纹理密集区域产生大量伪影。

针对此问题，受 Skip-GANomaly 的启发，引入多尺度特征融合机制：跳跃连接。保留原始结构，添加下 3 层的跳跃连接，在完整 U-Net 的基础上去除了第一层的跳跃连接，目的是保留纹理重建性能的同时赋予一定的对于异常区域错误重建的能力，给分割提供语义差异，如图 6 所示。

同时在解码器的最后一层前添加了一个轻量化的异常适配器，如图 7 所示。由通道、空间双重注意力与卷积构成，将通道注意力权重图与空间注意力权重图融合，得到同时关注通道和空间的注意力特征图，最后利用残差连接将注意力权重作用于特征图中，以强调对异常区域重建的能力。针对纤维绳索这种复杂纹理对象，实现对异常区域的消除或错误重建创建分割差异，以及对正常纹理的精确重建，如图 8 所示。

### 1.3 判别子网络

判别子网络为类似 U-Net<sup>[19]</sup> 的网络架构，并同样采用跳跃连接。由于重建图像与异常图像在异常区域存在显著的外观差异，通过学习输入重建图像与异常图像的通道级联图像，判别子网络即可分割出异常区域输出异常图。在 DRAEM 中，分割子网络的输入为异常图像与重构图像沿通道维度的级联。其编码器采用层级式卷积结构对输入进行特征提取，但受限于传统卷积操作的局部感受野。具体而言，卷积在浅层网络中更倾向于捕捉局部纹理和细节特征，而难以对图像全局语义信息进行有效建模。

为优化全局特征提取能力，本文提出一种改进策略，在编码器深层网络中引入 Transformer 模块。Transform 模型由 Google 团队在 2017 年提出的。该模块主要由多头注意力机制、前馈神经网络构成，并包含残差连接和层归一化。多头注意力机制可并行学习不同子空间的语义

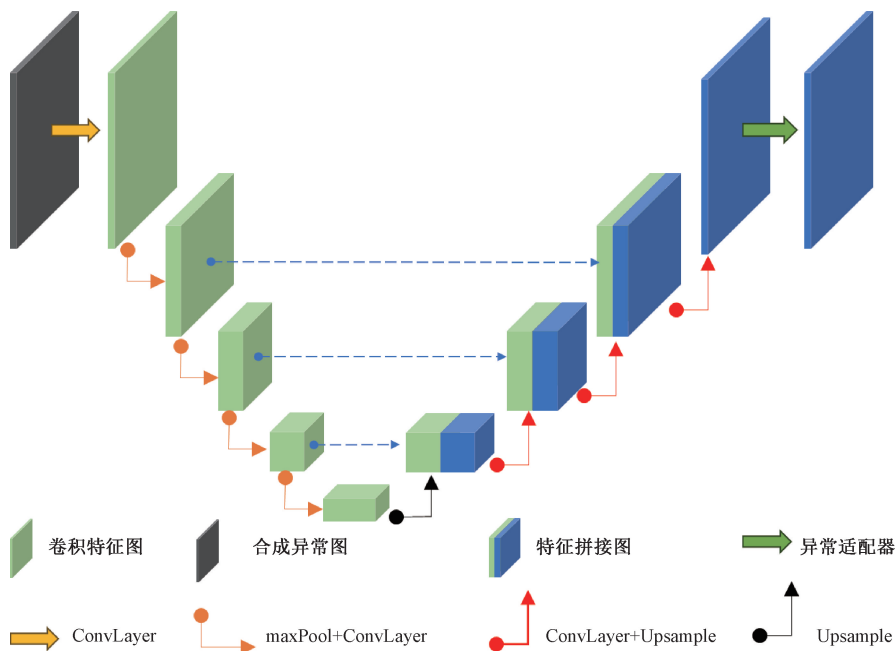


图 6 重构子网络结构

Fig. 6 Network structure of the reconstruction subnetwork

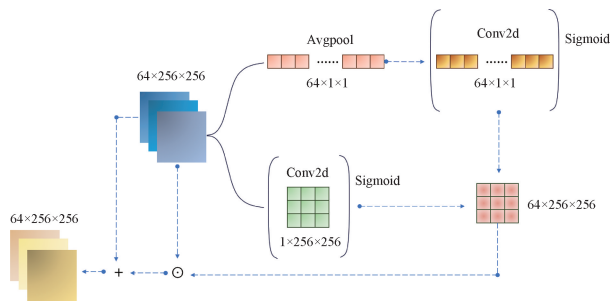


图 7 异常适配器网络结构

Fig. 7 Architecture of the anomaly adapter module

Transformer 模块, 可通过多头注意力机制与前馈神经网络更好地提取特征图当中的全局语义信息, 突破卷积操作的局部性约束, 实现上下文信息的融合, 如图 9 所示。




图 8 绳索细小纹理重构改进效果

Fig. 8 Improved visualization of fine texture reconstruction for ropes

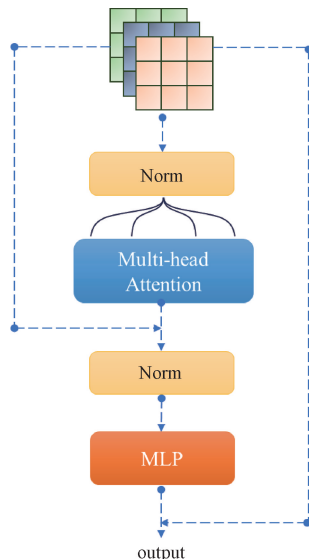


图 9 Transformer 模块网络结构

Fig. 9 Architecture of transformer module

信息, 能够获取不同大小的局部特征信息以及全局信息, 丰富网络表达能力, 增强模型表达能力。

随着编码器通过下采样, 其对应的感受野覆盖范围成比例扩大, 因此编码器后几层的特征张量本质上承载了更高抽象级别的全局语义信息。在此阶段嵌入

同时在最后的分割前, 引入 ASPP 模块, 通过其多分支并行的不同膨胀率的空洞卷积结构, 更好地实现了多尺度上下文特征的同步捕获和有效聚合。这一机制解决了非监督场景下缺陷尺度差异大、判别依赖强上下文以及语义信息不足的问题。它显著提升了特征表示的判别

能力,抑制正常纹理变化导致的干扰,从而最终创造出更充分、更具区分度的语义信息,驱动模型输出更高精度、更鲁棒的表面缺陷分割结果,如图 10 所示。改进后的判别子网络结构图如图 11 所示。

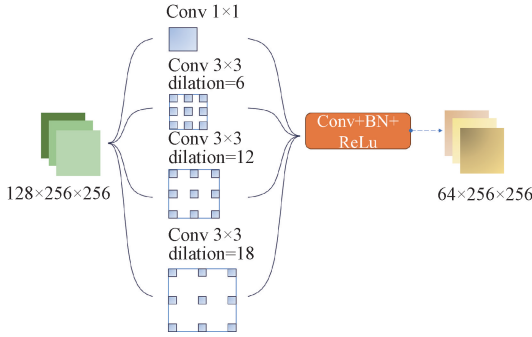


图 10 ASPP 模块网络结构

Fig. 10 Architecture of ASPP module

### 1.4 损失函数

为了训练重构子网络,提高重建效果,其中重建损失由  $l_2$  损失和结构相似性指数 (structural similarity index measure,  $SSIM$ )<sup>[20]</sup> 损失构成,用  $l_2$  损失来衡量重建图像与原图之间的像素级差异, $SSIM$  损失来衡量图像的相似性,如式(2)所示。

$$L_{rec}(I, I_r) = \lambda L_{SSIM}(I, I_r) + l_2(I, I_r) \quad (2)$$

式中: $I$  为输入异常图像, $I_r$  为重建图像, $\lambda$  为损失平衡超参数, $L_{SSIM}(I, I_r)$  与  $l_2(I, I_r)$  分别为输入异常图像与重建图像的  $SSIM$  损失与  $l_2$  损失。 $l_2$  损失。异常图像与重建图像的  $SSIM$  损失如式(3)所示。

$$L_{SSIM}(I, I_r) = \frac{1}{N_p} \sum_{i=1}^H \sum_{j=1}^W 1 - SSIM(I, I_r)_{(i,j)} \quad (3)$$

式中: $H$  和  $W$  分别为异常图像  $I$  的高和宽, $N_p$  为异常图像  $I$  的像素个数, $SSIM(I, I_r)_{(i,j)}$  为图像与  $I_r$  以图像坐标  $(i, j)$  为中心的  $SSIM$  值,如式(4)所示。

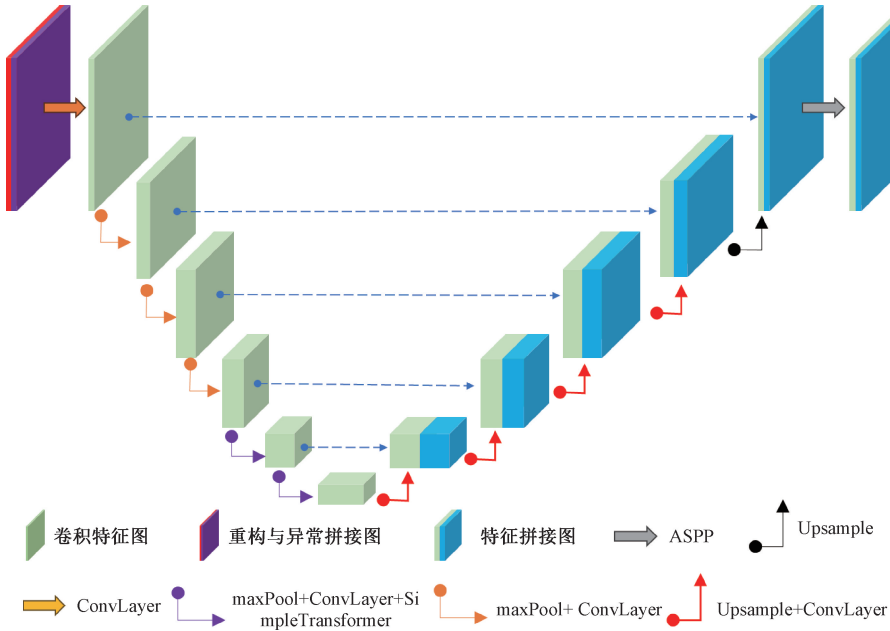


图 11 判别子网络结构

Fig. 11 Network structure of the discriminant subnetwork

$$SSIM(I, I_r)_{(i,j)} = l(i, j) \cdot c(i, j) \cdot s(i, j) = \frac{(2\mu_i \mu_j + C_1)(2\sigma_{ij} + C_2)}{(\mu_i^2 + \mu_j^2 + C_1)(\sigma_i^2 + \sigma_j^2 + C_2)} \quad (4)$$

式中: $\mu_i$  与  $\mu_j$  为局部均值; $\sigma_i^2$  与  $\sigma_j^2$  为局部方差; $\sigma_{ij}$  为局部协方差; $C_1 = (0.01 \cdot L)^2$ ; $C_2 = (0.03 \cdot L)^2$ , $L = 1$ ; $l(i, j)$  为亮度比较函数; $c(i, j)$  为对比度比较函数; $s(i, j)$  为结构比较函数,如式(5)~(7)所示。

$$l(i, j) = \frac{2\mu_i \mu_j + C_1}{\mu_i^2 + \mu_j^2 + C_1} \quad (5)$$

$$c(i, j) = \frac{2\sigma_{ij} + C_2}{\sigma_i^2 + \sigma_j^2 + C_2} \quad (6)$$

$$s(i, j) = \frac{\sigma_{ij} + C_3}{\sigma_i \sigma_j + C_3} \quad (7)$$

其中  $C_3 = C_2/2$ 。为了提高判别子网络的分割准确性和鲁棒性,将 Focal Loss 作为判别子网络的分割损失  $L_{seg}$ 。根据重构子网络和判别子网络的损失函数,DRAEM 算法的总损失如式(8)所示。

$$L(I, I_r, M_a, M) = L_{rec}(I, I_r) + L_{seg}(M_a, M) \quad (8)$$

式中: $M_a$  与  $M$  分别为真实标签与输出异常分割掩码。

将判别子网络输出的异常检测掩码  $M_o$  通过均值滤波卷积层进行平滑处理,得出最终异常评分  $\eta$ ,如式(9)所示。

$$\eta = \max(M_o * f_{s_f \times s_f}) \quad (9)$$

式中:  $f_{s_f \times s_f}$  为大小  $s_f \times s_f$  的平均滤波器。

## 2 实验验证

### 2.1 数据集与实验参数设置

本文通过 2 种直径不同的纤维绳索,利用工业相机拍摄大小为  $2\,448 \times 2\,048$  pixels 的数据集图像共 333 张,其中包含正常图像 165 张以及缺陷图像 168 张,训练集包含正常图像 136 张,测试集包含正常图像 29 张和缺陷图像 168 张,如图 12 所示。本文实验的深度学习模型搭建在 Window11 操作系统下版本为 11.8 的并行计算平台和编程模型 (compute unified device architecture, CUDA) 进行模型加速。本文实验的硬件平台为 Intel Core i7-12 700 处理器和显存为 16 GB 的 NVIDIA GeForce RTX 3 060 Ti GPU,能够为深度学习实验提供良好的支持。



图 12 纤维绳索表面缺陷数据集

Fig. 12 Dataset of surface defects for fiber ropes

在本文实验模型训练参数的设置中,模型在自制纤维绳索数据集上训练 600 个 epoch, Batch size 设置为 12, 所有输入图像大小设置为  $256 \times 256$ , 学习率设置为  $10^{-4}$ , 同时设置多阶段学习率衰减策略动态降低学习率,以平衡模型收敛速度与精度,在 480 和 540 epoch 后将学习率乘以 0.2 降低 80%。采用在  $(-45, 45)$  度范围内的图像旋转作为数据集的数据增强方法,提高模型的训练效果。为了评估模型,使用了异常检测的标准度量受试者工作特征曲线下面积 (area under the receiver operating characteristic curve, AUROC)。图像级 AUROC (I-AUROC) 用于异常检测,像素级的 AUROC (P-AUROC) 用于评估异常定位。为了更好地反映定位精度,同时采用了图像级平均精度度量 (I-AP) 和像素级平均精度度量 (P-AP),它更适合高度不平衡的类,特别是对于表面异常检测,对精度衡量起着重要作用。

### 2.2 模型对比

为了验证本文模型的有效性,本文选取以下几种先进的非监督异常检测模型进行对比实验:抽象语法树 (abstract syntax tree, AST)<sup>[21]</sup>、EfficientAD<sup>[22]</sup>、SimpleNet<sup>[6]</sup>、SuperSimpleNet<sup>[16]</sup>、INP-Former<sup>[23]</sup> 和基于像素的自适应分割器 (pixel-based adaptive segmenter, PBAS)<sup>[24]</sup>。对比实验结果如表 1 所示。由实验结果可以看出,在 I-AUROC、P-AUROC 指标中相较于其他模型均有一定量的提升,说明本文模型在图像级和像素级的异常判别能力上具有一定的优越性。并且在 P-AP 指标上达到 61.76%,其他模型最高也仅达到 57.27% 的像素定位精度,该数据表明本文算法在纤维绳索的图像缺陷检测精度以及表面缺陷像素定位精度上均远优于目前主流的算法。但是本文算法在 I-AP 指标上略低于其他模型,说明在异常图像的判别能力上稍有不足。为了更加直观地展示该算法的有效性,将这几种模型的检测效果图进行对比,如图 13 所示。从异常概率图和热图可以看出改进算法对于纤维绳索的表面缺陷具有更高的像素定位精度,充分证明了该算法的有效性。

表 1 模型对比实验结果

Table 1 Model comparison experimental results (%)

Method	I-AUROC	P-AUROC	I-AP	P-AP
AST <sup>[21]</sup>	81.16	91.74	95.71	14.56
EfficientAD <sup>[22]</sup>	85.94	93.08	98.4	37.9
SimpleNet <sup>[6]</sup>	85.23	96.9	99.53	43.23
SuperSimpleNet <sup>[16]</sup>	94.52	96.14	98.84	30.29
INP-Former <sup>[23]</sup>	97.69	97.63	98.59	57.27
PBAS <sup>[24]</sup>	96.59	96.87	98.35	36.16
本文	97.7	99.63	97.58	61.76

### 2.3 消融实验

为了提高纤维绳索表面缺陷检测的精度,本文对非监督模型 DRAEM 进行了改进,主要包括对重构子网络的改进以及对判别子网络的改进。

1) 在重构子网络的后 3 层 U-Net 网络结构中加入了跳跃连接;

2) 在重构子网络解码器的最后一层引入一个基于空间、通道双重注意力的异常适配器;

3) 在判别子网络编码器的后两层卷积之后加入 Transform 模块;

4) 在判别子网络解码器的最后一层加入 ASPP 空洞空间金字塔池化。

为了验证以上改进对模型纤维绳索的表面缺陷检测精度的提升的有效性,以自制数据集为基础,以图像级和

像素级的 AUROC 以及 AP 为度量指标,原 DRAEM 模型为基线模型,逐步加入以上改进措施进行对比,研究各模

块对网络性能提升的影响,来进行消融实验,实验结果如表 2 所示。

表 2 消融实验

Table 2 Ablation experiment

(%)

跳跃连接	异常适配器	Transform 模块	ASPP 模块	I-AUROC	P-AUROC	I-AP	P-AP
				93.3	95.2	98.9	39.9
✓				97.8	99.64	97.45	57.7
✓	✓			97.45	99.59	97.27	59.71
✓	✓	✓		97.29	99.57	97.3	61.08
✓	✓	✓	✓	97.7	99.63	97.58	61.76

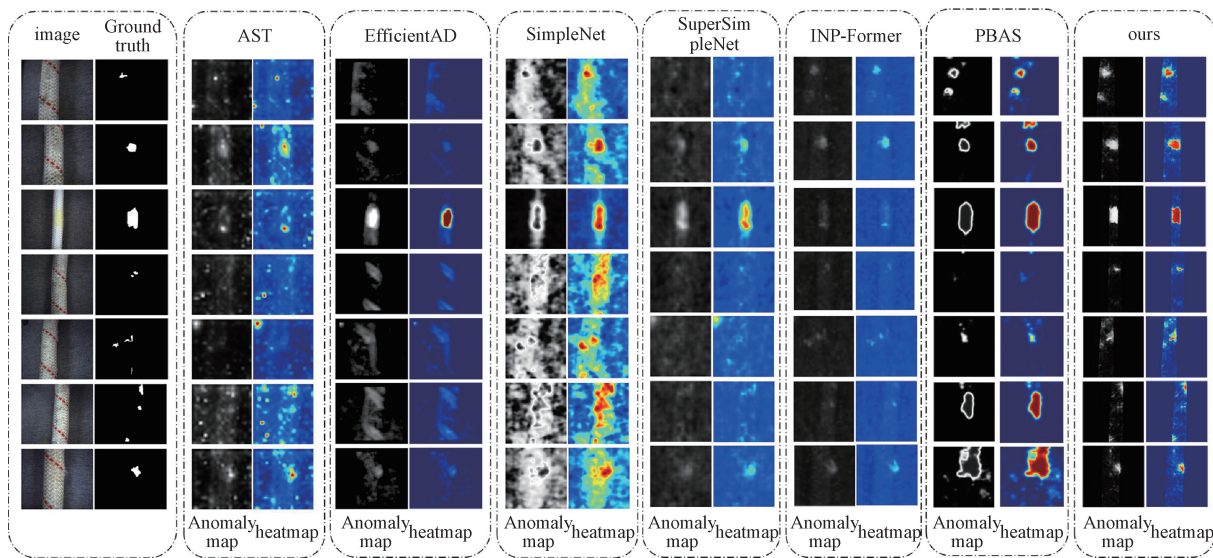


图 13 模型检测效果对比

Fig. 13 Comparison of model detection results

表 2 的消融实验结果表明,通过对模型的逐步改进,虽然 I-AP 降低了 1.32%,降低了对异常图像的判别能力。但是 I-AUROC、P-AUROC 和 P-AP 分别提高至 97.7%、99.63%和 61.76%,表明本文算法在整体图像判别能力和缺陷的像素级定位精度上均有提升。由于绳索表面缺陷多为小目标缺陷,原 DRAEM 模型在纤维绳索的表面缺陷检测任务中虽然表现出较高的 AUROC 指标精度,但是在像素级平均精度指标中表现不佳,只有 39%。说明模型的缺陷局部定位精度还有待提高。

针对绳索重构纹理丢失的问题,本文在重构子网络中加入跳跃连接,提高图像的纹理和异常重建效果,对于后续判别子网络的分割精度具有显著的提高。在加入异常适配器之后,进一步提高了异常区域的重建能力,避免小目标缺陷的漏检,从而提高了模型的分割精度。对比效果如图 14 所示。

最后在判别子网络中通过引入 Transform 模块和 ASPP 空洞空间金字塔池化后,优化了模型的全局特征提取能力和不同尺度语义信息的捕获能力,将模型的像素




图 14 纤维绳索重构效果

Fig. 14 Visual results of fiber rope reconstruction

级平均定位精度提高至 61.76%,提高了 21.86%。同时从表 2 可以看出,与原 DRAEM 对比 I-AUROC 提高了 4.4%,P-AUROC 提高了 4.43%,通过改进模型具备了更高的检测精度。为了使模型改进缺陷定位精度对比更加

合理,在原 DRAEM 模型中同样引入图像预处理进行对比,对比效果如图 15 所示。

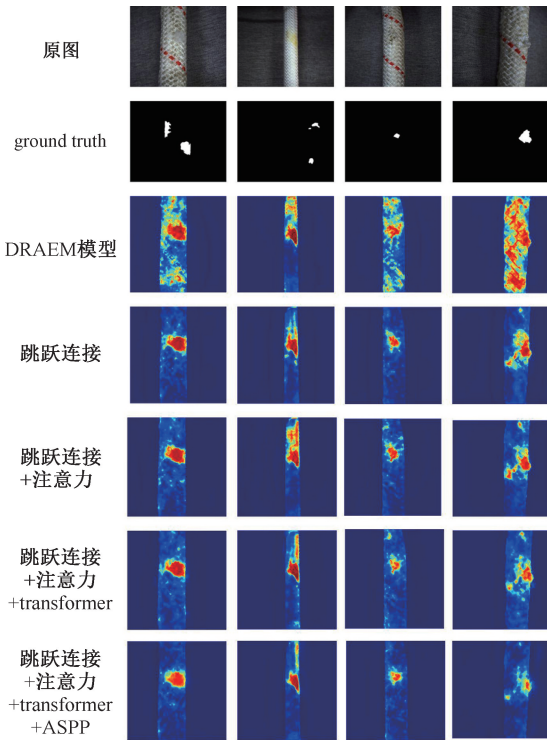


图 15 绳索缺陷检测效果对比

Fig. 15 Comparison of rope defect detection performance

实验对比结果表明,通过对 DRAEM 模型架构及训练策略的逐步优化与改进,本方法在缺陷像素的定位精度方面取得了显著提升,能够更加精准地识别缺陷在图像中的具体位置与边界。此外,如图 15 中第 4 张绳索图像所示,改进后的模型在减少误检方面同样展现出优越性能,有效避免了将背景或正常区域错误分类为缺陷区域的情况,从而进一步提高了缺陷检测的准确性与可信度。

为了证明本文针对绳索图像复杂背景造成的误检及漏检的问题进行了解决,本文进行了背景去除对比实验,实验对比效果如图 16 所示。针对绳索图像中因复杂背景干扰导致的误检问题,本文设计了背景干扰对比实验以评估所提方法的鲁棒性。如图 16 所示,实验结果直观展示了本文方法在抑制背景噪声降低误检率方面的效果。

由于纤维绳索表面缺陷多为小目标缺陷,本文通过提高纹理重构效果以及网络分割精度来提高小目标缺陷的检测精度以及检测率;为了验证本文对小目标缺陷的检测效果,进行了对比实验,结果如图 17 所示。

从实验效果对比可以看出,在没有加入图像预处理的情况下,DRAEM 模型无法对绳索表面的小目标缺陷进




图 16 基于背景分割的缺陷检测效果对比

Fig. 16 Comparison of defect detection performance based on background segmentation

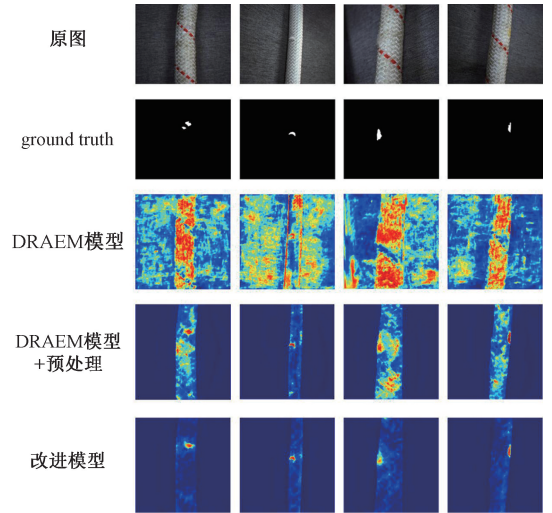


图 17 小目标缺陷检测效果对比

Fig. 17 Comparison of small defect detection performance

行像素级的识别;同时可以看出即便去除背景噪声的影响,也会出现小目标缺陷误检以及无法精准定位缺陷;相比之下,本文改进模型通过优化纹理重建与分割网络结构,显著增强了对小目标缺陷的特征感知与语义理解能力,能够准确识别小尺度缺陷区域,并实现更为精准的像素级定位。

### 3 结论

本文基于 DRAEM 算法进行改进提出了一种新的纤维绳索表面缺陷检测模型,以解决细小纹理以及背景复杂的场景中小目标漏检率高、检测精度低和算法鲁棒性不足等问题。通过 GrabCut 分割算法对绳索图像进行分割,对重构子网络添加跳跃连接以及异常适配模块以强

调对异常区域重建的能力,对判别子网络添加 Transform 模块和 ASPP 空洞空间金字塔池化来优化网络的特征融合为最后的分割创建足够的语义信息,通过以上改进来提高模型对纤维绳索表面缺陷的检测精度。实验结果表明,相对于原 DRAEM 模型,I-AUROC 提高了 4.4%,P-AUROC 提高了 4.43%,P-AP 提高了 21.86%,同时与主流的几种非监督异常检测模型进行对比。实验结果表明,所提出的模型在像素级缺陷定位与图像级缺陷检测任务上均展现出卓越的性能。有效解决了小尺度缺陷易被漏检、绳索表面重构过程中细小纹理信息丢失、背景噪声干扰引发的误检问题,同时显著提升了整体检测精度。这些改进体现了模型在复杂场景下对微小异常的精准感知与鲁棒检测能力。更能满足复杂背景等场景中高精度和高稳定性的纤维绳索缺陷检测的需要。

### 参考文献

- [ 1 ] BOŽIČ J, TABERNIK D, SKOČAJ D. Mixed supervision for surface-defect detection: From weakly to fully supervised learning[J]. *Computers in Industry*, 2021, 129: 103459.
- [ 2 ] 万伟彤, 李长峰, 朱华波, 等. 轻量化 CenterNet 网络的二维条码定位算法[J]. *电子测量与仪器学报*, 2022, 36(5): 128-135.  
WAN W T, Li CH F, ZHU H B, et al. Lightweight centerNet network based 2D barcode localization algorithm[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(5), 128-135.
- [ 3 ] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习方法综述[J]. *中国科学: 信息科学*. 2022, 52(6): 1002-1039.  
LUO D L, CAI Y X, YANG Z H, et al. Survey on industrial defect detection with deep learning [ J ]. *SCIENTIA SINICA Informations*, 2022, 52: 1002-1039.
- [ 4 ] SUN L, TAN CB, HU S J, et al. Quality detection and classification for ultrasonic welding of carbon fiber composites using time-series data and neural network methods[J]. *Journal of Manufacturing Systems*, 2021, 61: 562-575.
- [ 5 ] DIKE H, ZHOU Y M, DEVEERASETTY K K, et al. Unsupervised learning based on artificial neural network: A review[C]. *IEEE International Conference on Cyborg and Bionic Systems*, 2018: 322-327.
- [ 6 ] LIU Z K, ZHOU Y M, XU Y S, et al. SimpleNet: A simple network for image anomaly detection and localization [ C ]. *IEEE/CVF Conference on Computer Vision*, 2023: 20402-20411.
- [ 7 ] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery [ C ]. *International Conference on Information Processing in Medical Imaging*, 2017: 146-157.
- [ 8 ] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. GANomaly: Semi-supervised anomaly detection via adversarial training[C]. *Asian Conference on Computer Vision*, 2018: 622-637.
- [ 9 ] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Skip-GANomaly: Skip connected and adversarially trained encoder-decoder anomaly detection [ C ]. *International Joint Conference on Neural Networks*, 2019: 1049-1056.
- [ 10 ] DEFARD T, SETKOV A, LOESCH A, et al. PaDiM: A patch distribution modeling framework for anomaly detection and localization [ J ]. *ArXiv preprint arXiv: 2011.08785*, 2020.
- [ 11 ] BERGMANN P, FAUSER M, SATTLEGGER D. MVTec AD: A comprehensive real-world dataset for unsupervised anomaly detection [ C ]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2019: 9592-9600.
- [ 12 ] ROTH K, PEMULA L, ZEPEDA J, et al. Towards total recall in industrial anomaly detection [ C ]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 14318-14328.
- [ 13 ] ZAVRTANIK V, KRISTAN M, SKOČAJ D. DRAEM: A discriminatively trained reconstruction embedding for surface anomaly detection [ C ]. *IEEE/CVF International Conference on Computer Vision*, 2021: 8330-8339.
- [ 14 ] PERLIN K. An image synthesizer[J]. *ACM SIGGRAPH Computer Graphics*, 1985, 19(3): 287-296.
- [ 15 ] ZAGORUYKO S, KOMODAKIS N. Wide residual networks [ C ]. *British Machine Vision Conference*, 2016: 87.1-87.12.
- [ 16 ] ROLIH B, FUČKA M, SKOČAJ D. SuperSimpleNet: Unifying unsupervised and supervised learning for fast and reliable surface defect detection [ J ]. *ArXiv preprint arXiv: 2408.03143*, 2024.
- [ 17 ] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [ C ]. *Advances in Neural Information Processing Systems*, 2017: 5998-6008.
- [ 18 ] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [ J ]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [ 19 ] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [ C ].

International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.

- [20] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [21] RUDOLPH M, WEHRBEIN T, ROSENHAHN B, et al. Asymmetric student-teacher networks for industrial anomaly detection[C]. IEEE/CVF Winter Conference on Applications of Computer Vision, 2023: 2592-2602.
- [22] BATZNER K, HECKLER L, KÖNIG R. EfficientAD: Accurate visual anomaly detection at millisecond-level latencies [ C ]. IEEE/CVF Winter Conference on Applications of Computer Vision, 2024: 128-138.
- [23] LUO W, CAO Y K, YAO H M, et al. Exploring intrinsic normal prototypes within a single image for universal anomaly detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2025: 10-17.
- [24] CHEN Q Y, LUO H Y, GAO H, et al. Progressive boundary guided anomaly synthesis for industrial anomaly

detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2024: 1193-1208.

## 作者简介



**方忠志**, 2022 年于湘潭大学获得学士学位, 现为河北工业大学硕士研究生, 主要研究方向为计算机视觉与图像处理。

E-mail: 1975235547@qq.com

**Fang Zhongzhi** received his B. Sc. degree from Xiangtan University in 2022. Now he is a M. Sc. candidate in Hebei University of Technology. His main research interests include computer vision and image processing.



**陶友瑞**(通信作者), 2010 年于湖南大学获得博士学位, 现为河北工业大学教授, 主要研究方向为复杂系统可靠性分析与设计理论和工业机器人技术。

E-mail: taoyourui@hebut.edu.cn

**Tao Yourui** (Corresponding author) received his Ph. D. degree from Hunan University in 2010. Now he is a professor in Hebei University of Technology. His main research interests include reliability analysis and design theory of complex system and industrial robot technology.