

9DOI: 10.19650/j.cnki.cjsi.J2311887

基于相似度对比学习的连接器零样本异常检测方法*

王月¹, 银兴行¹, 郑帅², 刘永旭¹, 王鹏¹

(1. 重庆邮电大学先进制造工程学院 重庆 400065; 2. 西安交通大学软件学院 西安 710049)

摘要:连接器是电子装备不可或缺的功能部件,其工作接触面的洁净无异物是电子装备正常工作的必要条件。针对连接器种类和样式繁多、异物样本少且形态不固定导致的误检、漏检频发问题,本文提出了一种新颖的零样本异常检测方法,通过在无关背景图片上合成随机异常,构建正常-异常样本图片对,经过网络预测得到表征样本对之间的像素级相似度的差异度分数图,以此对异常进行检测和定位。通过异常区域掩码监督,使网络专注于正常-异常样本之间的像素差异,弱化网络对图片自身语义信息的关注,同时减少真实样本的需求量,提升检测器的泛化能力。为验证算法有效性,仅使用合成数据训练网络,在DeepPCB数据集上进行了评估,方法取得88.2%的mAp,迁移学习之后取得99.1%的mAp,为该数据集上目前最好的效果。实验结果表明本文提出的零样本异常检测方法具有良好的泛化能力。

关键词: 异常检测; 卷积神经网络; 零样本学习; 小样本学习; 域自适应

中图分类号: TH166 TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2060

A zero-shot connector anomaly detection approach based on similarity-contrast learning

Wang Yue¹, Yin Xinghang¹, Zheng Shuai², Liu Yongxu¹, Wang Peng¹

(1. School of Advanced Manufacturing Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China; 2. School of Software Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Connectors are essential components of electronic devices, and the cleanliness of their working contacts is a necessary condition for the normal operation of electronic equipment. To address the frequent issues of false positives and false negatives caused by the diverse types and styles of connectors, as well as the limited and variable foreign object samples, this article proposes a novel zero-shot anomaly detection method. By synthesizing random anomalies on unrelated background images, it constructs pairs of normal-anomaly sample images. Through network prediction, a discrepancy score map representing the pixel-level similarity between sample pairs is obtained, enabling anomaly detection and localization. By employing anomaly region mask supervision, the network focuses on the pixel differences between normal and anomaly samples, reducing the network's attention to the semantic information of the images themselves and minimizing the need for real samples. Thus, the generalization ability of the detector is enhanced. To evaluate the effectiveness of the algorithm, the network is trained solely on synthesized data and evaluated on the DeepPCB dataset, achieving a mAP (mean average precision) of 88.2%. After transfer learning, the mAP increases to 99.1%, which is the best performance on this dataset to date. Experimental results demonstrate the strong generalization ability of the proposed zero-shot anomaly detection method.

Keywords: anomaly detection; deep learning; zero-shot learning; few-shot learning; domain adaptation

0 引言

连接器在电子装备中担负着电能传输、信号控制和传递的任务,是保证电信号及电能准确可靠地传输到电子装备的主要基础元件之一,其连接可靠性直接关系到整个系统工程的成败。由于电子设备制造过程中有装配、焊接等多个工艺过程,生产过程中残余的金属微颗粒、线头等异物易掉落在连接器的内部,人眼难以观测^[1]。假如连接器带异物插装,极易造成:1)链路不通,产品的功能不可用,需要进行大量的调试测试排查问题;2)通信不稳定或光信号幅相不稳,产品性能受影响,造成返工返修;3)如异物未在插装前及时发现,将对电子装备的可靠性造成极大的隐患。因此,连接器之间无异物对确保电子装备质量具有重大意义。

传统异常检测方法^[2-5]一般基于精心的图像预处理、特征提取和参数选择才能保证检测效果,普适性较差,对光照和阴影变化,异常噪声比较敏感,难以推广到其它场景。随着计算机技术和硬件的发展,深度学习成为异常检测的热点,常用于异常检测的深度学习主要可以分为以下3种:

1) 基于目标检测的方法

一般异常定义为意外变化超出其局部或全局规范的可测量结果^[6]。对于异常种类已知且缺陷样本获取容易的场景,先对大量缺陷样本进行人为标注,将主流目标检测框架(如YOLO^[7]、Faster-RCNN^[8]、SSD^[9]等)作为检测器进行端到端训练。彭雨诺等^[10]基于YOLO进行了改进,通过在大量真实样本上的训练使网络学习检测局部或全局离群点的能力,提升了桥梁表面的缺陷检测效果。

2) 基于重建的方法

为了克服缺陷样本少的问题,文献[11-12]先让网络学习正常样本的重建,然后根据待检图片的重建误差来判断是否为缺陷样本。Zavrtanik等^[13]将表面异常检测主要视为一个判别问题,并提出一个判别训练的重构异常嵌入模型(DR $\mathcal{E}$ M)。该方法学习异常图像的联合表示及其无异常重构,同时学习正常和异常样本的决策界。

3) 基于预训练模型的方法

为了增加异常检测网络的泛化能力,一系列利用预训练模型进行异常检测的方法被提出。Reiss等^[14]提出PANDA,直接使用ImageNet上预训练的ResNet先对所有正常样本(训练集)都进行多层级特征提取后拼接并存入特征池,而无需在训练集上微调,在测试过程提取到特征后,在特征池中检索到K个最近的模板特征,计算异常得分得到异常图用于异常定位,PANDA不需要大量的异常样本,但测试时的时间复杂度与特征池大小呈正相关。

Jeong等^[15]利用多模态预训练模型Clip^[16]

(contrastive language-image pre-training)进行零样本/少样本异常检测任务,提出了WinCLIP,借助CLIP丰富的预训练知识,使用状态(state)和模板(template)的提示集来制作文本提示,并引入额外的线性层对异常区域进行定位,在少样本异常检测任务上取得了非常好的效果。但CLIP是通过庞大的数据集来尽可能的覆盖下游任务,正如原论文所说,它在未见过的数据上(例如MINIST)表现非常不理想,仍然需要在新样本上进行微调。

综上所述,数据驱动下深度学习强大的学习能力能够在一定程度上克服传统方法的缺点,然而,现实中光是单个大型电子设备的连接器就有数十种,为每种连接器收集大量的训练数据,并针对不同类别部署不同模型实行起来不仅周期较长且成本较高。因此,不使用(零样本, zero-shot)或使用少量真实样本(few-shot)图像构建冷启动模型在应用时显得尤为必要。构建一个可以在没有或只有少量正常图像的情况下,快速适应众多类别的模型是一种理想的解决方案。

针对连接器异常检测中的场景多变、异常样本少的问题,论文提出了零样本异常检测器,本研究的主要贡献有以下3点:

1) 本文的训练数据只需要使用现有的公共数据集作为背景的合成数据,不需要花费大量时间采集和标注真实样本。

2) 将传统异常检测网络中依赖大量真实场景数据训练的离群点判断问题转化为输入样本对之间有差异与否的二分类问题,更易于训练与推广。

3) 本文方法在全新应用场景下仍然表现出色。

1 理论分析

1.1 网络输入

神经网络结构的选择和输入数据的形式有关。受到文献[17-19]的启发,本文采用两帧图像作为网络输入,其中一张图像为待检图片,另一张为无异物情况下的模板图片,图像大小为640×480,两张图像在通道维度上拼接后作为网络输入,网络根据两张图像在时间维度(通道)上的上下文变化情况,预测出像素级差异度分数图,通过每个像素位置处的差异分数来判断和定位异常。

1.2 网络结构

本文采用带有跨层连接的编码器-解码器架构,网络结构如图1所示,其中,编码器部分包含10个卷积块,每个卷积块包含1个卷积层,1个归一化层(normalization, Norm)层和1个高斯误差线性单元(gaussian error linear units, GeLU)层。解码器部分由4个反卷积块,5个卷积层和5个转置卷积层组成,每个反卷积块包含1层转置

卷积和 1 层 GeLU 激活函数。网络在解码阶段会融合编码器特征提取部分的输出,结合多尺度特征进行掩

码预测,这样的连接贯穿整个网络,网络中有 4 次融合过程。




图 1 零样本异常检测器网络结构

Fig. 1 Architecture of zero-shot anomaly detector

1.3 归一化

归一化技术被用于解决神经网络训练过程中协变量偏移的问题,其公式如下所示:

$$Normalization(x) = \gamma \times \left(\frac{x - \mu(x)}{\sigma(x)} \right) + \beta \quad (1)$$

其中, γ 与 β 为可训练参数, μ 和 σ 为输入的均值和方差。

本文通过实例归一化通过分别对输入中每一个样本的每一个通道进行归一化来保证数据分布的一致性,其均值和方差如下所示:

$$\mu(x) = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w x_{n,c,i,j} \quad (2)$$

$$\sigma(x) = \sqrt{\frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w (x_{n,c,i,j} - \mu(x))^2 + \varepsilon} \quad (3)$$

其中, n, c, h 和 w 分别为输入特征 x 的样本数量、通道数、高和宽, i 和 j 为输入在高宽维度上的坐标值, ε 为防止 $\sigma(x) = 0$ 的极小正值。

实例归一化把一批样本中不同图片的每一个通道视为一个分布,并将其标准化,没有混合批量和通道之间的数据,保留了不同样本和不同通道之间的独立性,适用于提取序列间关系的任务。

1.4 差异度分数图

网络最后一层的输出特征图经过 Sigmoid 函数之后得到像素级的差异度分数图,如图 2 所示。




图 2 差异度分数图

Fig. 2 Discrepancy score map

其表征了待检图片和模板图片在空间维度上的差异度,两张图片在该位置处越相似,分数越接近 0,反之越接近 1,说明两张图越可能在该位置处存在明显不同,即很有可能存在异物。

差异度分数的标签可用如下公式表示:

$$target_{i,j} = \begin{cases} 1, & inp_{i,j} \neq temp_{i,j} \\ 0, & inp_{i,j} = temp_{i,j} \end{cases} \quad (4)$$

其中, i, j 为像素坐标, $target$ 为对应像素标签, inp 为测试图像, $temp$ 为模板图像。

1.5 异常判断及定位

通过网络预测检测图像和模板图像同一位置处的像素差异度(归一化到 0~1), 并借助差异度分数图对异常进行判断及定位, 具体方法为: 1) 对差异度分数图进行二值化(本文异常阈值参数设置为大于等于 0.1)得到掩码图像, 掩码图像中的各个连通域即为潜在的异常区域, 也就是检测图片与模板图片间存在较大不同的区域。2) 求各连通域的最小包围框, 根据相机参数计算出异常区域的实际大小。根据实际检测要求, 将包围框长径大于阈值的确定为异常。

2 实验验证

2.1 训练输入构建

由于真实场景下的连接器异常样本稀缺, 为了让网络学习到“差异”, 而不是拟合某种特定的异常形态, 本文通过在各种不同背景的图像上添加形态各异的异常区域作为训练样本, 其流程如下:

1) 模板选择: 以现有的公共图像数据集为基础, 随机选择一张图片作为模板图像, 并将其缩放到 640×480 的尺寸。

2) 标签生成: 对于每个模板图片, 生成一张大小为 640×480 的掩码作为标签。在掩码内部随机生成多个不规则多边形区域, 并将该区域像素值置为 1, 其余为 0。

3) 异常生成: 复制一份模板图像作为待检图片。在这里本文采用了两种不同的异常生成方法, 其效果如图 3 所示, 1) 第 1 种是使用随机颜色将待检图片中的凸多边形填充为小色块作为异常区域; 2) 第 2 种是随机选择训练数据集中的一张图片, 并结合掩码标签将该图片与待检图片进行融合生成异常区域。




图3 异常生成效果
Fig.3 Anomaly generation effects

为了提高网络对待检图片和模板图片之间的光线变化、相机抖动等外界干扰的鲁棒性, 如表 1 所示, 本文还对训练数据作了特定增强。

表 1 训练数据增强方式 Table 1 Augmentation methods on training data		
增强方式	增强内容	应用对象
亮度增强	随机提高或降低亮度	模板图片/待检图片
旋转增强	将图像随机旋转一定角度	模板图片/待检图片、 标签掩码图片
抖动增强	将图像随机平移一定像素	模板图片/待检图片、 标签掩码图片
光照增强	模拟光线照射效果	模板图片/待检图片
高斯噪声	添加随机强度的高斯噪声	模板图片/待检图片

以上数据增强各自独立, 可以同时添加。训练数据增强后的效果如图 4 所示。




图4 训练样本
Fig.4 Samples for training

2.2 推理输入构建

推理时的输入构建过程如图 5 所示。




图5 推理输入构建过程
Fig.5 Process of input construction in inference

在推理过程中, 我们使用机械手搭载 5472×3648 像素的工业相机进行图像采集(模板图像和检测图像采集流程为: 1) 模板图像: 使用夹具将含有无异常连接器的

产品固定;控制机械臂到连接器上方采集模板图像并保存。2) 检测图像:使用夹具将含有连接器的待检测产品固定;控制机械臂移动至模板采集时相同的位置处,获取当前图像作为检测图像并保存。

夹具和机械臂对于位姿的精准控制能够保证模板图像和待检图像的大致对齐,大幅度减轻测试图像相对于模板图像的缩放,旋转和平移程度。

2.3 标签平滑

为了减轻模型过于自信而过拟合于某些特定异常的概率,论文采用平滑系数对真实标签进行加权来改变标签的分布,即标签平滑正则化(label smoothing regularization)^[20]。通过标签平滑减轻过拟合,提高网络的鲁棒性,其公式如下:

$$q_{smoothed}(k|X) = (1 - \alpha) \times q(k|X) + \alpha \times u(k) \quad (5)$$

其中, X 为训练样本, $q(k|X)$ 为原始标签分布, $u(k)$ 为独立于 X 的均匀分布, k 为类别数目 2, α 为平滑系数, $q_{smoothed}(k|X)$ 为平滑后的标签分布,平滑后的标签如下:

$$target_{i,j} = \begin{cases} 1 - \alpha, & inp_{i,j} \neq temp_{i,j} \\ \alpha, & inp_{i,j} = temp_{i,j} \end{cases} \quad (6)$$

2.4 损失函数

本文将异常检测任务的目标优化为了与背景无关的像素二分类问题,所以本文的损失函数采用二值交叉熵误差,其定义如下:

$$L_{bce} = -\frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w [target_{i,j} \times \ln(pred_{i,j}) + (1 - target_{i,j}) \times \ln(1 - pred_{i,j})] \quad (7)$$

其中, $pred$ 为网络预测的对应标签的概率值。

2.5 网络预训练

本文采用 VOC2017 作为背景数据集,共有 17 125 张背景各异的图片,每次训练从数据集中随机选取图片作为模板生成训练样本。训练过程以及下文的实验都在一台配备图像处理器的计算机上进行,具体配置如表 2 所示。

表 2 计算机系统配置

Table 2 Computer system configuration	
配置内容	规格/型号/参数
系统	Windows 10 专业版
内存	32 GB
图形处理器	NVIDIA GeForce RTX 3080
中央处理器	12th Gen Intel(R) Core(TM) i9-12900K 3.20 GHz
深度学习框架	Pytorch 1.10.0, CUDA 11.7, CUDNN 8.4.1

训练过程中的超参数设置为:批数大小为 8,梯度优化器为 AdamW,学习率为 0.001,迭代次数为 10 000 次,权重衰减因子为 0.000 5。

2.6 对比实验

为了验证零样本条件下本文算法在连接器异常检测任务上的有效性,本文在真实场景下的连接器图像上与结构相似性异物检测算法^[21]进行了对比,如图 6 所示,从检测结果可以看出,本文的零样本异常检测器仅在合成数据集上经过训练之后,在真实场景下的连接器图片上的表现仍然出色,且鲁棒性优于基于结构相似性的传统异常检测算法。




图 6 检测结果对比
Fig. 6 Comparison of detection results

由于连接器异常样本数量不足以支撑其他深度学习异常检测算法的训练要求,但是为了验证本文提出的零样本检测器的泛化能力,本文在公共数据集 DeepPCB 上进行了评估。DeepPCB 数据集是一个 PCB 板缺陷数据集,所有图像均来自面阵 CCD 相机,模板和测试图像分辨率大小为 640×640。DeepPCB 共包含 1 500 组图像,其中训练集 1 000 组,测试集 500 组,每组图像均包含无缺陷的模板图像和待测试图像,并带有标注。

本文对 2 种不同的差异生产方式、3 种不同的归一化方式和标签平滑与否对预训练效果的影响作了 5 组对比实验,以在 DeepPCB 数据集上的表现为基准,使用平均精度(mean average precision, mAp)指标来评估异常检测模型的性能,结果如表 3 所示,实验结果表明实例归一化、随机图像融合的异常生成方式和标签平滑对模型检测效果都有一定程度的提升。

文献[22]在该数据集上进行了 500 个周期的训练,为了与之对比,本文在该数据集上进行 4 组对照实验:第 1 组仅使用预训练权重,不在 DeepPCB 数据集上进行任

表 3 预训练消融实验

Table 3 Ablation experiment of pretraining

归一化方式	平滑系数	异常生成方式	平均精度/%
层归一化	0.05	随机颜色块	78.2
层归一化	0	随机图片融合	81.4
层归一化	0.05	随机图片融合	85.5
批归一化	0.05	随机图片融合	80.8
实例归一化	0.05	随机图片融合	88.2

何操作;第 2 组在 DeepPCB 的训练集上进行 10 个周期的迁移学习;第 3 组进行 100 个周期的迁移学习;第 4 组进行 500 个周期的迁移学习。迁移学习过程中的超参数设置为:不使用标签平滑,批数大小为 16,梯度优化器为 AdamW,学习率为 0.000 5,权重衰减因子为 0.001。

如图 7 所示,从检测结果可以看出,本文方法在零样本条件下也能检测出数据集中的大部分异常,达到和真实样本训练同样的精度。




图 7 在 DeepPCB 数据集上的测试效果图
Fig. 7 Inference results on DeepPCB dataset

在 DeepPCB 数据集上的实验结果如表 4 所示,其中 ft-n 表示迁移到 DeepPCB 数据集上微调(fine-tune) n 轮。从实验结果可以看出,零样本异常检测器即使在完全没有见过的 DeepPCB 数据集上,依然能够取得高达 88.2% 的平均精度,经过 10 个周期的学习便能达到 DeepPCB-AP(AP 表示使用平均池化,MP 表示最大池化)500 个周期的学习效果,500 个周期之后取得了高达 99.1% 的平

均精度,这是该数据集上我们所知的最好效果。本文方法与机器学习中的一些经典缺陷检测算法在 DeepPCB 数据集上的检测效果对比如图 8 所示。由于某些异常会与正常样本的结构高度相似,如检测结果第 3 行图中左上角的孔洞形状与 PCB 板本身结构中的圆孔形状接近,语义信息相似,但 PCB 板中的异常是相对于所有部件都存在的正常电路板来定义的,传

表 4 DeepPCB 数据集上的评估

Table 4 Evaluation on DeepPCB dataset

算法	查准率/%	查全率/%	平均精度/%	F1 分数/%
本文	78.0	88.3	88.2	82.8
SSD-FPN	94.9	96.9	—	95.8
YOLO	—	—	92.6	93.1
Faster	—	—	97.6	97.8
Ours-ft-10	93.7	97.7	97.7	95.7
DeepPCB-AP-500	—	—	97.1	—
DeepPCB-MP-500	98.2	98.1	98.6	98.2
Ours-ft-500	97.8	99.0	99.1	98.4

统的机器学习算法会将中间的圆形孔洞判断为正常而导致漏检,本文的检测算法借助模板图片的信息,可以很容易判断出该部分相对于模板图像而言是异常的。

由于是像素级的异常分类,由图 8 可以看出本文方法得到的检测框的定位精度高,都很贴近于异常区域,但同时也让算法对像素上的变化更加敏感,如检测结果第 4 行第 6 列的图片所示,一方面,对于图片中结构的边缘和角点位置处,会更容易受图片中携带的噪声影响,另一方面,训练过程中的图像抖动增强会在提高网络对于“未对齐”情况下的鲁棒性的同时,降低对于边缘和角点处的小尺寸异常和正常的区分能力而出现误检和漏检。




图 8 检测效果对比图

Fig. 8 Comparison of detection results

3 结 论

为了解决电子装备连接器场景多变,表面异物形态不固定的问题,本文提出了一种在全新场景下依然能够有效进行异常检测任务的 U 型连接网络,其中编码器对图片样本对进行特征提取,解码器预测样本对之间粗略的差异度分数图,将其上采样并与编码器中的特征融合后预测得到更精确的差异度分数图,经过 4 次不同尺度的特征融合后最终预测得到像素级的差异度分数图,通过差异度分数图对异常进行准确定位。在真实场景下的连接器图像上对本文提出的零样本异常检测器进行了有效性验证,同时在公共数据集 DeepPCB 上与其它方法作

了对比实验,结果表明本文提出的零样本异常检测器在无真实训练样本条件下仍能取得较好的效果,并且本文的方法在迁移学习后在 DeepPCB 数据集上达到了目前最好的效果。本文代码可在: <https://github.com/wangyuecqupt/Zero-shotanomaly-detector> 处获取。

本文仅针对样本图片对已经粗略对齐的情况进行了实验和分析,在未来研究工作中,将针对目标场景中单独某个区域发生旋转、缩放和仿射变换的情况进行探索,并在此基础上降低网络的显存占用量。

参考文献

[1] 花诗燕,李大伟,贾书一,等. 基于卷积-反残差和组合注意力机制的航天器多余物检测[J]. 计算机集成

- 制造系统, 2022, 28(11): 1-19.
- HUA SH Y, LI D W, JIA SH Y, et al. Convolution-inverted residual and combined attention mechanism[J]. Computer Integrated Manufacturing Systems. 2022, 28(11): 1-19.
- [2] 贺振东,王耀南,毛建旭,等. 基于反向 P-M 扩散的钢轨表面缺陷视觉检测[J]. 自动化学报, 2014, 40(8): 1667-1679.
- HE ZH D, WANG Y N, MAO J X, et al. Research on Inverse P-M diffusion-based rail surface defect detection[J]. Acta Automatica Sinica, 2014, 40(8): 1667-1679.
- [3] ZHANG H, JIN X T, WU Q M J, et al. Automatic visual detection system of railway surface defects with curvature filter and improved gaussian mixture model[J]. Transactions on Instrumentation and Measurement, 2018, 67(7): 1593-1608.
- [4] 吕承侃,沈飞,张正涛,等. 图像异常检测研究现状综述[J]. 自动化学报, 2022, 48(6): 1402-1428.
- LYU CH K, SHEN F, ZHANG ZH T, et al. Review of image anomaly detection[J]. Acta Automatica Sinica, 2022, 48(6): 1402-1428.
- [5] VAIKUNDAM S, HUNG T Y, CHIA L T. Anomaly region detection and localization in metal surface inspection [C]. Proceedings of the International Conference on Image Processing. Phoenix, USA, 2016: 759-763.
- [6] COOK A A, MISIRLI G, ZHONG F. Anomaly detection for iot time-series data: A Survey[J]. Internet of Things Journal, 2020, 7(7): 6481-6494.
- [7] REDMON J, DIVVALA S K, GIRSHICK R B, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the Computer Vision and Pattern Recognition, 2016: 779-788.
- [8] REN S Q, HE K M, GIRSHICK R B, et al. Faster r-cnn: Towards real-time object detection with region proposal networks[C]. Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Proceedings of the European Conference on Computer Vision, Amsterdam, The Netherlands, 2016: 21-37.
- [10] 彭雨诺,刘敏,万智,等. 基于改进 YOLO 的双网络桥梁表观病害快速检测算法[J]. 自动化学报, 2022, 48(4): 1018-1032.
- PENG Y N, LIU M, WAN ZH, et al. A dual deep network based on the improved yolo for fast bridge surface defect detection [J]. Acta Automatica Sinica, 2022, 48(4): 1018-1032.
- [11] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. GANomaly: Semi-supervised anomaly detection via adversarial training [C]. Proceedings of the Asian Conference on Computer Vision, Perth, Australia, 2018: 622-637.
- [12] 戴俊,王俊,朱忠奎,等. 基于生成对抗网络和自动编码器的机械系统异常检测[J]. 仪器仪表学报, 2019, 40(9): 16-26.
- DAI J, WANG J, ZHU ZH K, et al. Anomaly detection of mechanical systems based on generative adversarial network and auto-encoder [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 16-26.
- [13] VITJAN Z, MATEJ K, DANIJEL S. DRÆM-A discriminatively trained reconstruction embedding for surface anomaly detection [C]. Proceedings of the International Conference on Computer Vision, Montreal, Canada, 2021: 8310-8319.
- [14] REISS T, COHEN N, BERGMAN L, et al. PANDA: adapting pretrained features for anomaly detection and segmentation [C]. Proceedings of the Conference on Computer Vision and Pattern Recognition, Virtual, 2021: 2806-2814.
- [15] JEONG J, ZOU Y, KIM T, et al. WinCLIP: Zero-/few-shot anomaly classification and segmentation [C]. Proceedings of the International Congress on Pattern Recognition, 2023.
- [16] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision [C]. Proceedings of the International Conference on Machine Learning, 2021: 8748-8762.
- [17] DOSOVITSKIY A, FISCHER P, ILG E, et al. FlowNet: Learning optical flow with convolutional networks [C]. Proceedings of the International Conference on Computer Vision, 2015: 2758-2766.
- [18] CHOPRA S, HADSELL R, YANN L C. Learning a similarity metric discriminatively, with application to face verification[C]. Proceedings of Conference on Computer Vision and Pattern Recognition, 2005: 539-546.
- [19] 董静怡,庞景月,彭宇,等. 集成 LSTM 的航天器遥测数据异常检测方法[J]. 仪器仪表学报, 2019, 40(7): 22-29.

- DONG J Y, PANG J Y, PENG Y, et al. Spacecraft telemetry data anomaly detection method based on ensemble LSTM [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 22-29.
- [20] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision[C]. Proceedings of the Conference on Computer Vision and Pattern Recognition, 2016: 2818-2826.
- [21] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity[J]. Transactions on Image Processing, 2004. 13(4): 600-612.
- [22] HE F, TANG S L, MEHRKANOON S, et al. A real-time pcb defect detector based on supervised and semi-supervised learning [C]. Proceedings of the European Symposium on Artificial Neural Networks, 2020: 527-532.

作者简介



王月(通信作者),2011年获西北工业大学学士学位、2013年获兰州理工大学硕士学位、2018年获西北工业大学博士学位,现为重庆邮电大学副教授,主要研究方向为图像处理、增强现实/虚拟现实。

E-mail:wang_yue@cqupt.edu.cn

Wang Yue (Corresponding author) received his B. Sc. degree from Northwestern Polytechnical University in 2011, received his M. Sc. degree from Lanzhou University of Technology in 2013, and received his Ph. D. degree from Northwestern Polytechnical

University in 2018. He is currently an associate professor at Chongqing University of Posts and Telecommunications. His main research interests include image processing, mixed reality, and virtual reality.



银兴行,2021年于重庆邮电大学获得学士学位,现为重庆邮电大学硕士研究生,主要研究方向为机器学习、增强现实。

E-mail:S212101026@stu.cqupt.edu.cn

Yin Xinghang received his B. Sc. degree from Chongqing University of Posts and Telecommunications in 2021. He is currently a master student at Chongqing University of Posts and Telecommunications. His main research interests include machine learning, and augmented reality.



郑帅,2008年、2011年、2017年于西安交通大学分别获得学士学位、硕士学位、博士学位,现为西安交通大学副教授,主要研究方向为计算机图形学、智能制造、智能系统。

E-mail:shuaizheng@xjtu.edu.cn

Zheng Shuai received his B. Sc. degree from Xi'an Jiaotong University in 2008, received his M. Sc. degree from Xi'an Jiaotong University in 2011, and received his Ph. D. degree from Xi'an Jiaotong University in 2017. He is currently an associate professor at Xi'an Jiaotong University. His main research interests include computer graphics, intelligent manufacturing, and intelligent systems.