

无监督电子连接器异常检测方法<sup>\*</sup>

唐善成 杨继清 李恒

(西安科技大学通信与信息工程学院 西安 710000)

**摘要:** 由于电子连接器异常样本稀缺,使得有监督模型难以捕捉异常样本特征,很大程度上限制了有监督学习方法的检测性能。并且现有无监督模型存在重建图像模糊、缺陷残留的问题,严重影响检测精度。为此,提出一种仅需无异常样本训练的一步去噪单纯形扩散模型电子连接器异常检测方法。由于高斯去噪扩散概率模型在图像重建任务中存在特征投影误差导致重建位置偏差,因此引入单纯形噪声构建单纯形噪声去噪扩散概率模型,并重新制定去噪范式使推理时间降低至 0.09 s。此外,研究得到一种图像预处理方法,消除冗余特征干扰,使模型高效学习电子连接器表面特征,提高模型学习效率。实验结果表明,在异常检测标准评估度量 AUROC 准则下,所提方法显著优于现有无监督模型。图像级检测准确率达 99.71%,像素级精度达到 93.86%,展现出卓越的异常检测性能。

**关键词:** 电子连接器;无监督学习;异常检测;扩散模型;计算机视觉

**中图分类号:** TN911.73 **文献标识码:** A **国家标准学科分类代码:** 510.99

## Unsupervised electronic connectors anomaly detection method

Tang Shancheng Yang Jiqing Li Heng

(College of Communication and Information Technology, Xi'an University of Science and Technology, Xi'an 710000, China)

**Abstract:** The scarcity of abnormal samples of electronic connectors makes it difficult for supervised models to capture abnormal sample features, which largely limits the detection performance of supervised learning methods. Moreover, the existing unsupervised models have the problems of blurred reconstructed images and defects remaining, which seriously affect the detection accuracy. To this end, a one-step denoising simplex denoising diffusion probabilistic model electronic connector anomaly detection method that requires only anomaly-free sample training is proposed. Since Gaussian denoising diffusion probabilistic model has feature projection error in the image reconstruction task that leads to reconstruction position deviation, simplex noise is introduced to construct a simplex noise denoising diffusion probabilistic model, and the denoising paradigm is reformulated so that the inference time is reduced to 0.09 s. In addition, the research obtains an image preprocessing method that eliminates the interference of redundant features, so that the model learns the surface features of the electronic connector efficiently and improves the model learning efficiency. The experimental results show that the proposed method significantly outperforms the existing unsupervised models under the AUROC criterion, a standard evaluation metric for anomaly detection. The image-level detection accuracy reaches 99.71% and the pixel-level accuracy reaches 93.86%, demonstrating excellent anomaly detection performance.

**Keywords:** electronic connectors; unsupervised learning; anomaly detection; diffusion model; computer vision

## 0 引言

电气化和自动驾驶推动了当前汽车行业的范式转变,使电子系统在现代汽车中变得越来越重要。那么支持电子系统信号传输的线束就成为了汽车内部重要的基础设施,保证电子连接器质量问题至关重要。目前电子连接器的异

常检测<sup>[1-2]</sup>主要以人工检测为主,该方法具有灵活度高、技术门槛低、短期成本低等优势,但也存在效率低,易受检测者主观因素等问题,例如在电子连接器的生产装配过程中容易漏装组件,当异常较小时易发生漏检。为了降低人力成本和漏检率,引入高精度和高效率的车用电子连接器异常检测系统显得尤为重要,不仅可以提升产品质检效率,还

能减少劳动成本。

近几年来,机器视觉<sup>[3]</sup>被广泛应用于各项异常检测任务中,但是传统的方法<sup>[4-6]</sup>往往达不到很高的检测精度。目前,基于深度学习的无监督检测<sup>[7]</sup>最常用的是基于重建的方法。Saeedi 等<sup>[8]</sup>提出了一种基于块的自编码器和单类深度特征分类的异常检测方法。王月等<sup>[9]</sup>提出了一种零样本异常检测方法,通过在样本上合成随机异常,预测样本对像素级差异度分数图来检测异常。刘应桃等<sup>[10]</sup>改进 Faster RCNN 网络,在轮对踏面缺陷检测中表现出色平均精度达 97.3%,平均检测速度为 68 ms。Tang 等<sup>[11]</sup>提出一种基于(progressive mask repair model, PMRM)模型的无监督织物表面缺陷检测方法,通过引入结构相似性约束和渐进式掩膜修复技术,显著提高了缺陷检测的准确性和效率,但部分重建图像存在纹理不一致的现象。Zhang 等<sup>[12]</sup>在(generative adversarial network, GAN)的基础上融合注意力机制,提升模型对良品信息的特征表征能力,获得更佳的重建效果。但是 GAN 的学习过程可能发生崩溃问题<sup>[13]</sup>生成器开始退化总是生成同样的样本,无法继续训练。Zavrtanik 等<sup>[14]</sup>利用纹理数据集 DTD<sup>[15]</sup>综合各种纹理异常,实现卓越的异常检测性能,但在面对特定的结构异常时(部分缺失或错位的样本)存在一定局限性。现有无监督重建模型存在重建图像模糊和缺陷残留等问题,影响检测精度和异常定位。而本文基于扩散模型<sup>[16]</sup>(denoising diffusion probabilistic model, DDPM)提出一种能够更精细地捕捉样本纹理特征与结构的异常检测方法得到更高质量的重建图像,显著提升电子连接器异常检测的可靠性。

本文的贡献主要包括:

1)为了提高模型提取电子连接器表面特征的效率,研究得到一套图像预处理方法,去除复杂背景且统一电子连接器姿态;

2)提出面向一步去噪单纯形扩散模型(one-step denoising simplex denoising diffusion probabilistic model, OSDSD-DDPM)的异常检测框架,摒弃高斯噪声引入单纯形噪声提升图像重建质量。并重新制定去噪范式使推理时间满足实际检测需求;

3)提出基于频率调谐显著性、高斯模糊的图像后处理方法,提高异常定位精度。

## 1 特征提取

### 1.1 电子连接器图像预处理

去除电子连接器图像背景、调整其姿态,可以显著提高模型对电子连接器图像特征的提取效率。本文在 SAM<sup>[17]</sup>、图像变换基础上,研究并得到一套图像背景去除方法。整体流程如图 1 所示。

采用 SAM 分割得到精确掩膜去除背景来提取主体,可避免传统方法出现的问题保留主体边完整信息。整个预处理流程可简述为 4 个步骤:1)将待处理图像输入至 SAM




图 1 电子连接器预处理流程图

Fig. 1 Electronic connector pre-processing flowchart

获得精确掩膜。2)输入图像和对应精确掩膜做与操作去除背景。3)对图像做腐蚀处理排除无关干扰以寻找最小外接矩形特征(minimum bounding rectangle, MBR)。4)利用仿射变换(affine transformation, AT)将电子连接器调整至同一姿态。

### 1.2 前向过程

去噪扩散概率模型是受非平衡热力学启发的生成模型,训练后可以使用模型来生成高质量且接近训练图像数据,从而捕获电子连接器表面特征。扩散模型由前向过程和逆向过程组成。前向过程是逐步向图像中添加高斯噪声直到变为纯高斯噪声图像,逆向过程是通过预训练的 U-net 从纯噪声图像中恢复出原始数据。

电子连接器的特征提取旨在学习一个与数据分布  $q(x)$  非常类似的分布  $p_\theta(x)$ , 如图 2(a)所示。前向过程是逐步向原始输入图像  $x_0$  添加高斯噪声  $\epsilon \sim \mathcal{N}(0, \mathbf{I})$  的过程,  $x_0 \rightarrow x_1 \rightarrow \dots \rightarrow x_T$  是经过  $T$  次添加噪声的过程,潜在噪声变量  $x_1, \dots, x_T$  与输入数据  $x \sim q(x)$  具有相同的维度;  $x_T$  为纯噪声图像,通常分布是均值为 0, 方差为 1 的正态分布。给定一个预定义的方差表,其中  $\beta_1 < \beta_2 < \dots < \beta_T$  且  $\beta_i \in (0, 1)$ 。前向过程的定义如下:

$$q(x_{1:T} | x) = \prod_{t=1}^T q(x_t | x_{t-1}) \quad (1)$$

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t | x_{t-1} \sqrt{1 - \beta_t}, \beta_t \mathbf{I}) \quad (2)$$

其中,  $\mathbf{I}$  是单位矩阵,表明每个维度都有相同的标准偏差  $\beta_t$ ,  $q(x_t | x_{t-1})$  表示正态分布,其均值是  $x_{t-1} \sqrt{1 - \beta_t}$ , 方差为  $\beta_t \mathbf{I}$ 。鉴于可加性性质,合并多个高斯分布会得到一个高斯分布。因此,在任意的时间步骤  $t$  可以通过扰动输入图像  $x_0$  来直接计算  $x_t$ , 可以通过  $x_0$  和固定值序列  $\{\beta_i \in (0, 1)\}_{i=1}^T$  得到:

$$q(x_t | x_0) = \mathcal{N}(x_t | x_0 \sqrt{\alpha_t}, (1 - \alpha_t) \mathbf{I}) \quad (3)$$

$$x_t = x_0 \sqrt{\alpha_t} + \epsilon_t \sqrt{1 - \alpha_t}, \epsilon_t \sim \mathcal{N}(0, \mathbf{I}) \quad (4)$$

其中,  $\alpha_t = 1 - \beta_t, \alpha_t = \prod_{i=1}^t \alpha_i$ 。通过上式若得到  $x_0$  和固定序列  $\{\beta_i \in (0, 1)\}_{i=1}^T$ , 再从标准分布  $\mathcal{N}(0, 1)$  采样出一个高斯噪声,那么不需要繁琐的迭代步骤,就能得到  $x_t$ , 可以更快的生成噪声图像从而提高前向过程效率。

### 1.3 逆向过程

逆向过程恰好与前向过程相反,如图 2(a)所示将纯噪声图像还原为初始输入图像。由于需要从完整数据集中找到数据分布,就需要通过 U-net 学习一个模型  $p_\theta$  来近似模拟  $q(x_{t-1} | x_t)$  从而实现逆向过程,定义如下:

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \sum_\theta(x_t, t)) \quad (5)$$

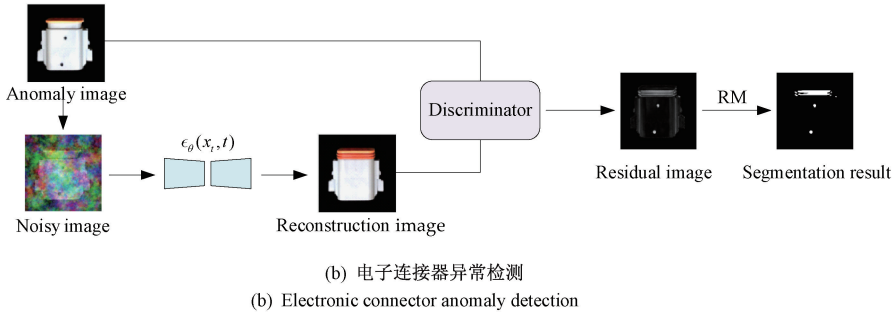
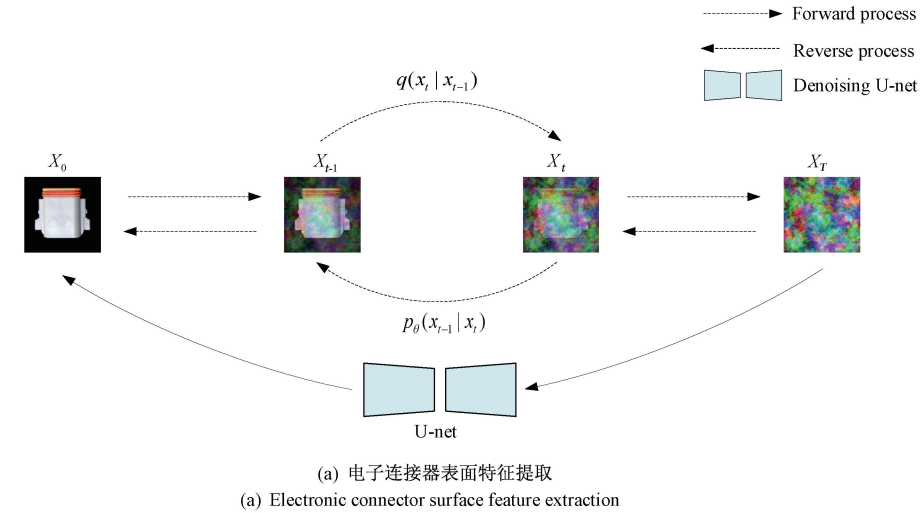


图 2 面向一步去噪单纯形扩散模型的电子连接器无监督异常检测框

Fig. 2 A framework for unsupervised anomaly detection in electronic connectors for OSDS-DDPM

在已知  $x_0$  条件下,由贝叶斯公式可得:

$$q(x_{t-1} | x_t, x_0) = \mathcal{N}(x_{t-1}; \tilde{\mu}_t(x_t, x_0), \tilde{\beta}_t I) \quad (6)$$

$$\text{其中, } \tilde{\beta}_t = \frac{1 - \bar{\alpha}_{t-1}}{1 - \bar{\alpha}_t} \beta_t, \tilde{\mu}_t(x_t, x_0) = \frac{\sqrt{\alpha_t}(1 - \bar{\alpha}_{t-1})}{1 - \bar{\alpha}_{t-1}} x_t +$$

$\frac{\sqrt{\bar{\alpha}_{t-1}} \beta_t}{1 - \bar{\alpha}_t} x_0$ , 由于前向过程因此可以得到:

$$\tilde{\mu}_t = \frac{1}{\sqrt{\alpha_t}} \left( x_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_t \right) \quad (7)$$

因此需要通过训练模型  $\mu_\theta(x_t, t)$  以预估  $\tilde{\mu}_t$ , 而  $x_t$  在训练阶段作为输入, 可以让模型去预估噪声  $\epsilon_t$ 。

## 2 一步去噪单纯形扩散模型异常检测

### 2.1 单纯形噪声

在二维情况下, Perlin<sup>[18]</sup> 是通过以下步骤产生的: 首先在网格上随机取样一个梯度, 计算候选点与 4 个最近网格点的偏移量与梯度的内积, 然后进行插值和平滑处理得到噪声。单纯形噪声 (simplex noise)<sup>[19]</sup> 是其改进版, 用等边三角形的单形网格代替网格, 以降低维度相关的复杂性和方向性伪影。

第一步是坐标转换。通过倾斜将单形坐标转换到相应

空间的正超网格体空间, 从而确定其所在网格顶点的坐标, 以获得梯度值和输入点到顶点的距离, 如下:

$$x' = x + (x + y) \times F \quad (8)$$

$$y' = y + (x + y) \times F \quad (9)$$

其中,  $x$  和  $y$  为原始超晶格体的坐标,  $x'$  和  $y'$  是正超晶格体的坐标,  $F$  计算如下:

$$F = \frac{\sqrt{n+1}-1}{n} \quad (10)$$

其中,  $n$  为空间维度, 由于处理的数据都属于二维情况, 所以将  $n$  设置为 2。

然后确定单纯形格, 对像素点的向量从大到小进行排序, 得到一个新的向量, 并依次取维度中的最大值, 直到得到 3 个顶点。根据得到的顶点, 可以确定顶点梯度向量梯度, 以排列序列为索引, 得到顶点梯度值, 与柏林噪声相同。为获得像素点与顶点之间的距离矢量距离, 可采用歪斜式  $F$  中的反函数  $G$ ,  $G$  可表示为:

$$G = \frac{1 - \frac{1}{\sqrt{n+1}}}{n} \quad (11)$$

$dist$  可表示为:

$$dist = (x - 1 + 2G, y - 1 + 2G) \quad (12)$$

最后,应用径向衰减函数计算各顶点的贡献值式(12),并对其求和。

$$(\max(0, r^2 - |dist|^2))^4 \times dot(dist, grad) \quad (13)$$

当  $r^2 = 0.6$  时,可以获得质量更高的图像。

更高级的单纯形噪声则用等边三角形构成的简单形网格替换了晶格。这样做减少了与维度相关的复杂性,并减少了典型基于梯度的柏林噪声中的方向性伪影。对于电子连接器图像来说,干扰呈现出更明显的结构性特征,去噪过程在不破坏正常区域纹理的情况下逐步重建异常区域。

## 2.2 去噪 U-net

如图 3 所示,去噪 U-net 采用了编码器-解码器(encoder-decoder)架构<sup>[20]</sup>,其中右侧部分负责特征提取,而左侧部分执行上采样操作。在编码器阶段,通过连续的下采样步骤,捕获不同尺度的特征。这一过程使得网络能够从图像的底层细节,如点、线和梯度等低级特征开始,逐步提取并向高级特征,例如轮廓和抽象信息过渡。该网络能够综合细节与全局信息,提取出更为全面的特征表示。

去噪 U-net 通过引入跳跃连接(skip connection)进一步增强了这一过程。这些连接允许在上采样的每个阶段,

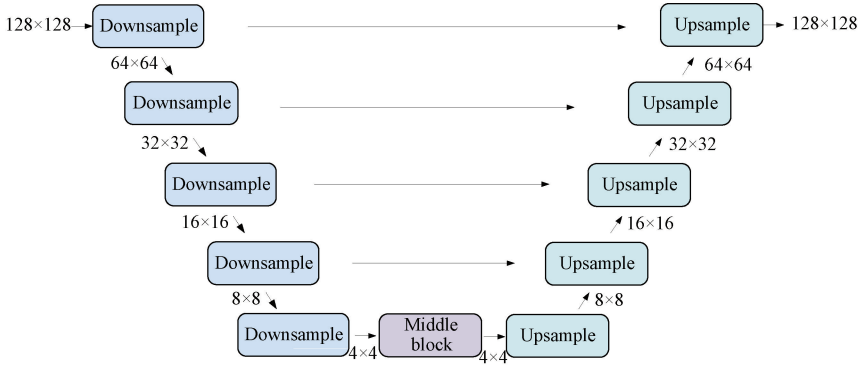


图 3 去噪 U-Net

Fig. 3 Denoising U-Net

## 2.3 一步去噪范式

所提出的基于生成模型的无监督异常检测方法主要是通过一步去噪单纯形扩散模型学习电子连接器表面特征、重建图像异常区域及异常检测与定位。本文的异常检测方法探索了使用高斯或单纯形噪声的 DDPM。最初输入图像  $x_0$  在  $t$  个时间步中被损坏  $x_t$ , 然后再去噪回到  $\hat{x}_0$ 。由于异常的大小不一,将  $x_t$  设为  $x_\lambda$ , 其中较大的  $\lambda$  值可以去除的异常区域越大。此外,单纯形噪声有一个固定的频率,可以对其进行调整,以允许使更大面积的图像受到破坏,并重建为无异常图像。

在扩散模型中,逆向过程的每次迭代都对应着一轮网络推理,这就需要大量的计算时间和计算资源,对于实时推理来说是一个重大挑战。为此,本文提出了一步去噪的方式来解决这个问题。

将编码器中相应层的特征图与解码器中的特征图在通道维度上进行合并。通过这种底层与高层特征的结合,网络能够更好地保留来自高层特征图的高分辨率细节,从而显著提升图像重建的质量。

为了让模型可以预估噪声,需要最大化模型预测分布的对数似然,使用变分下限优化负对数似然,可得到:

$$\mathcal{L}_{V\mathcal{L}_B} = \mathcal{L}_T + \mathcal{L}_{T-1} + \dots + \mathcal{L}_0 \quad (14)$$

$$\mathcal{L}_T = D_{KL}(q(x_T | x_0) || p_\theta(x_T)) \quad (15)$$

$$\mathcal{L}_t = D_{KL}(q(x_t | x_{t-1}, x_0) || p_\theta(x_t | x_{t+1})), 1 \leq t \leq T-1 \quad (16)$$

$$\mathcal{L}_0 = -\mathcal{L} \log p_\theta(x_0 | x_1) \quad (17)$$

由于前向扩散没有可学习参数,而  $x_t$  则是纯噪声,可以作为常量忽略,因此损失函数可简化表示为:

$$\mathcal{L}_t^{simple} = \mathbb{E}_{x_0, t, \epsilon} [ || \epsilon - \epsilon_\theta(\sqrt{\bar{\alpha}_t} x_0 + \sqrt{1-\bar{\alpha}_t} \epsilon, t) ||^2 ] \quad (18)$$

通过上述公式可预测每个时间点的噪声,最终损失函数的目标是通过度量预测噪声和真实噪声之间的差异来让模型学习预测准确的噪声,并使其与真实噪声保持一致。

$$q(x_t | x_0) = \mathcal{N}(x_t; \sqrt{\bar{\alpha}_t} x_0, (1 - \bar{\alpha}_t) I) \quad (19)$$

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, t) \quad (20)$$

$$x_0 = \frac{x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, t)}{\sqrt{\bar{\alpha}_t}} \quad (21)$$

将上式重写为:

$$\hat{x}_0 = \frac{1}{\sqrt{\bar{\alpha}_t}} (x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, t)) \quad (22)$$

其中,  $\hat{x}_0$  是指无异常重建的结果。本文先是使用 U-net 直接预测  $x_t$  的噪声,接着本文通过式(22)得到无异常重建。这种一步预测比传统迭代预测快  $t$  倍,显著节省了计算资源和推理时间。

## 2.4 异常检测

在上一节中,获得了无异常重建图像,为了确定输入



图像中是否存在异常使用判别器。本文使用 Z-score 方法统计分析了无异常图像的 (peak signal-to-noise ratio, PSNR) 值, 得出判定阈值。Z-score 方法定义如下:

$$Z = \frac{\bar{x} - \mu}{\sigma / \sqrt{n}} \quad (23)$$

其中,  $\bar{x}$  为样本平均值,  $\mu$  为总体平均值,  $\sigma$  为总体标准偏差, 为样本大小。通过这种方法, 本文可以得到一个完全由正常图像的 PSNR 值组成的集合。该集合之外的值被视为异常值。本文选择  $\bar{\xi} = 29.76$  作为阈值。若所得重建图像  $PSNR < \bar{\xi}$ , 就需要通过联合异常图像和重建的无异常图像进行异常定位。异常定位主要通过图像差分以及频率调谐显著性等图像后处理实现。

首先对输入图像和重建图像做差分, 得到的结果是灰度图像。差分可以描述为:

$$D(x, y) = |I_1(x, y) - I_2(x, y)| \quad (24)$$

其中,  $D(x, y)$  是做完差分的结果在位置  $(x, y)$  的像素值。  $I_1(x, y)$  是原图在位置  $(x, y)$  的像素值,  $I_2(x, y)$  是重建图像在位置  $(x, y)$  的像素值。

最后通过对差分图像做频率调谐显著性 (FT), 从而得到精确异常定位结果, 如图 4 所示。具体流程如下:




图 4 后处理过程  
Fig. 4 Post-processing

第 1 步, 计算差分图像的直流分量即图像的平均强度值。同时通过高斯核对差分图像进行模糊处理, 可以实现对图像的平滑处理并有效降低噪声水平。采用  $5 \times 5$  的卷积核, 高斯核可用式 (25) 表示:

$$K_{\sigma}(x, y) = \frac{1}{2\pi\sigma^2} \cdot \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (25)$$

其中,  $\sigma$  是高斯分布的标准差, 决定了核的大小。

第 2 步, 将经过平滑处理的图像从 RGB 颜色空间转换到 LAB 颜色空间。分别计算转换后平滑图像的 L、A、B 3 个通道的像素平均值  $L_{\mu}$ 、 $a_{\mu}$  和  $b_{\mu}$ , 得到平滑图像的平均图像特征向量  $I_{\mu}$  以及像素矢量值  $I_{hc}(x, y)$ 。通过计算每个像素与图像平均像素之间的差异, 从而得到显著性图  $S(x; y)$ , 其公式可以表示为:

$$S(x; y) = |I_{\mu} - I_{hc}(x; y)| \quad (26)$$

利用亮度特征, 并且考虑到本文只关注差异的大小, 这里选择应用 L2 范数, 对上述公式进行重新整理:

$$S(x; y) = ||I_{\mu} - I_{hc}(x; y)|| \quad (27)$$

通过计算这两个向量的欧氏距离并归一化, 得到最终的显著图像, 从而得到异常定位结果。

### 3 实验与结果

#### 3.1 实验环境与数据集

本文采用公开的电子连接器 (electric connectors dataset, ECD) 数据集。该数据集共有 611 张正常样本和 391 张异常样本, 其中包含 C1、C2、C3、C4 四种型号电子连接器, 图像都为  $1024 \text{ pixel} \times 1024 \text{ pixel}$  的 RGB 图像。该数据集包括 4 种类型的表面异常样本, 如带缺失 (band missing), 多个组件缺失 (multiple components missing), 橙色部件缺失 (orange missing), 孔洞 (spots)。该数据集样本稀少, 非常考验深度模型的泛化能力。

数据集中的所有电子连接器图像都被调整为  $224 \text{ pixel} \times 224 \text{ pixel}$ 。在模型训练过程中, 采用基于无监督学习的方法, 只采用无异常电子连接器图像进行训练。对于去噪过程, 采用 U-net 架构来估计  $\epsilon_{\theta}$ 。这种架构主要基于 PixelCNN<sup>[21]</sup> 和 WideResNet<sup>[22]</sup>, 并使用正弦位置编码来表示时间步长  $t$ 。噪声表设置为线性, 将基础通道设置为 128, 注意力分辨率设置为 32、16、8, 并设置头的数量为 4。本文使用批次大小为 1 的训练数据进行训练, 共训练 1000 epochs。使用 Adam 优化器进行优化, 初始学习率设置为 0.0001。实验环境为 NVIDIA V100。试验平台为 Python3.8, Pytorch2.1.2。

#### 3.2 评价指标

通过峰值信噪比 (PSNR) 和感知相似度<sup>[23]</sup> (LPIPS) 作为重建图像衡量指标。本文所用图像像素由 8 位二进制表示值为 255。PSNR 单位为 dB, 一般来说值越大表示重建图像越接近原始图像, 模型重建细节的能力也就越强。学习感知图像块相似度也称为感知相似度, 通过深度学习模型来评估重建图像的质量。LPIPS 比传统方法, 更符合人类感知情况, LPIPS 的值越低表示重建质量越好。

对于异常检测的性能本文采用受试者工作特性曲线下方的面积 AUROC 作为评估指标。通过将真阳性率 (TPR) 和假阳性率 (FPR) 作为横纵坐标来描绘分类器在不同阈值下的性能。TPR 是分类器正确识别正例的能力, TPR 定义为:

$$TPR = \frac{TP}{TP + FN} \quad (28)$$

其中, TP (true positive) 表示正确识别的正例数量, FN (false negative) 表示错误地将正例识别为负例的数量。假阳性率 (FPR) 是指在所有实际为负例的样本中, 模型错误地预测为正例的样本比例, FPR 定义为:

$$FPR = \frac{FP}{FP + TN} \quad (29)$$

其中, FP (false positive) 表示错误地将负例识别为正例的数量, TN (true negative) 表示正确识别的负例数量。AUC 值为 ROC 曲线与其横轴之间的面积。

#### 3.3 实验结果和讨论

现存文献中几乎没有讨论采用无监督学习方法进

行车用电子连接器的异常检测。为了评估本文所提异常检测模型的性能,将本文方法与经典图像重建网络 DCAE、CycleGAN<sup>[24]</sup>、MAE (masked autoencoder)<sup>[25]</sup>、DRAEM 进行比较。上述方法均在 ECD 数据集进行对比实验。

### 1) 重建图像质量对比

无监督异常检测模型检测异常的准确性直接取决于模型的重构能力。为了实验的严谨性,本文其他无监督对比模型也采用预处理后的电子连接器图像。4种无监督模型对待测图像的重建结果如图5所示。




图5 各无监督模型的重建结果

Fig. 5 Reconstruction results for each unsupervised model

可以观察到,DCAE和MAE的重建结果都存在异常区域残留的问题,且部分重建结果不仅没有得到无异常重建图像,而且破坏了正常区域纹理。CycleGAN虽然在异常区域的重建上表现较好,但部分重建结果会出现畸变,且在无异常区域的重建上存在颜色差异。DRAEM在处

理部分组件缺失的重建任务时,存在较大局限。相比于上述3种模型,本文的模型在重建能力上展现了显著的优势。为了定量比较各模型的重建能力,引入PSNR和LPIPS作为图像重建质量的评价指标。结果如表1所示,本文的模型相较于其他模型获得最佳结果。

表1 各无监督模型对4种电子连接器型号的重建图像质量定量比较结果

Table 1 Results of quantitative comparison of reconstructed image quality of each unsupervised model for four electronic connector models

指标	模型	C1	C2	C3	C4	平均值
PSNR ↑	DCAE	<b>29.621 1</b>	22.922 3	22.213 8	23.633 1	24.597 6
	CycleGAN	23.559 3	24.773 1	17.915 0	<b>27.693 6</b>	23.485 2
	MAE	26.923 8	<b>25.516 5</b>	25.439 8	26.406 6	26.071 7
	DRAEM	25.898 6	24.910 4	28.628 7	25.565 3	26.250 8
	OSDS-DDPM	29.532 1	25.106 6	<b>30.293 6</b>	26.497 6	<b>27.857 5</b>
LPIPS ↓	DCAE	<b>0.089 0</b>	0.228 3	0.248 1	0.168 3	0.183 4
	CycleGAN	0.119 0	0.111 2	0.170 8	<b>0.056 6</b>	0.114 4
	MAE	0.097 7	0.122 0	0.105 9	0.116 4	0.110 5
	DRAEM	0.112 5	0.135 6	0.041 2	0.061 9	0.087 8
	OSDS-DDPM	0.105 1	<b>0.110 0</b>	<b>0.053 8</b>	0.058 9	<b>0.082 0</b>

### 2) 异常检测结果

为了验证所提出的模型能否在像素级实现精确的异常定位,采用热力图展示检测结果如图6所示。可以观察

到,因为可以获得高质量的重建结果,本文的模型对无异常区域的检测结果几乎没有影响,此外还可以通过频率调谐显著性检测突出异常区域,实现精确定位。

本文对测试结果进行了定量分析,客观地评估所提出的模型在异常检测和定位精度方面的性能,结果汇总如表 2 所示。与之前的方法相比,本文提出的异常检测方法在异常检测和定位方面分别提高了 3.75% 和 0.92%。

3.4 消融实验

1) 预处理必要性实验

图像预处理的核心目标是消除背景以及形态特征干扰。通过综合运用形态学技术、颜色空间转换以及仿射变换等方法,实现对电子连接器姿态的标准化处理。这一步骤提升了模型对于电子连接器表面特征的提取效率,并显著提高了异常检测的准确性。如图 7 所示,证实了预处理步骤的有效性。

表 2 图像级和像素级异常检测精度结果

Table 2 Image-level and pixel-level anomaly detection accuracy results

指标/%	模型	C1	C2	C3	C4	平均值
AUROC	DCAE	(88.61,51.39)	(78.39,62.43)	(81.32,10.75)	(90.80,28.20)	(84.78,38.19)
	CycleGAN	(98.38,97.36)	(99.45,82.69)	(92.2,81.21)	(91.2,97.25)	(95.31,89.63)
	MAE	(98.83,97.53)	(100,89.86)	(94.92,87.43)	(90.08,96.93)	(95.96,92.94)
	DRAEM	(95.83,96.56)	(99.92,85.87)	(100,90.08)	(98.92,92.21)	(98.67,91.18)
	Ours	(98.85,98.28)	(100,93.13)	(100,86.56)	(99.99,97.48)	(99.71,93.86)




图 6 热力图异常定位结果

Fig. 6 Heatmap anomaly location results

为了评估图像预处理前后的重建质量,采用结构相似性指数(structure similarity index measure, SSIM)<sup>[26]</sup>作为衡量标准。通过表 3 展示了 4 种不同型号:C1、C2、C3、C4 的电子连接器在预处理前后重建图像的 SSIM 平均值。这些数据直观地反映了预处理过程对图像重建质量的显著提升。

表 3 预处理前后 4 个型号电连接器平均重建质量

Table 3 Average reconstruction quality of four models of electrical connectors before and after pretreatment

SSIM	C1	C2	C3	C4
预处理前	0.723	0.782	0.75	0.779
预处理后	0.885	0.902	0.96	0.925

2) 高斯噪声与单纯形噪声

如图 8 所示,分别选取了  $\lambda = 250, \lambda = 500, \lambda = 750$  的




图 7 预处理前后重建结果

Fig. 7 Reconstruction results before and after preprocessing

单纯形扩散模型结果与高斯扩散模型的重建结果,很明显高斯噪声可产生较高质量的样本但是会改变无缺陷区域正常纹理,然而在将图像迭代次数增加后,发生了严重的畸变,在  $\lambda = 750$  处生成了差异很大的样本,这些将严重影响异常定位结果。相反,图 8 中的单纯形噪声捕获了噪声频率对异常检测的影响。结果表明,随着多尺度噪声最大频率的增加,更多的异常区域被破坏,然后重建为无异常图像。最佳释放时间  $t$  不仅仅取决于异常区域的大小,通过执行网格搜索,据经验可得  $\lambda = 250$  对于这个特定的数据集是最优的。

最后,计算了 Recall, F1 分数, IoU 值, 以及接收器工作特性曲线(AUROC)来定量衡量高斯扩散与一步去噪单纯形扩散模型的性能,如表 4。本文使用平方误差概率( $x - \hat{x}^2$ )来找到真阳性率和假阳性率。对于 ECD 数据集, Gaussian-DDPM 取得了优异的结果,而 OSDS-DDPM 显示出了更高的性能。此外加入了图像后处理方法的 OSDS-DDPM+RM, 显著提升了异常定位的精度。

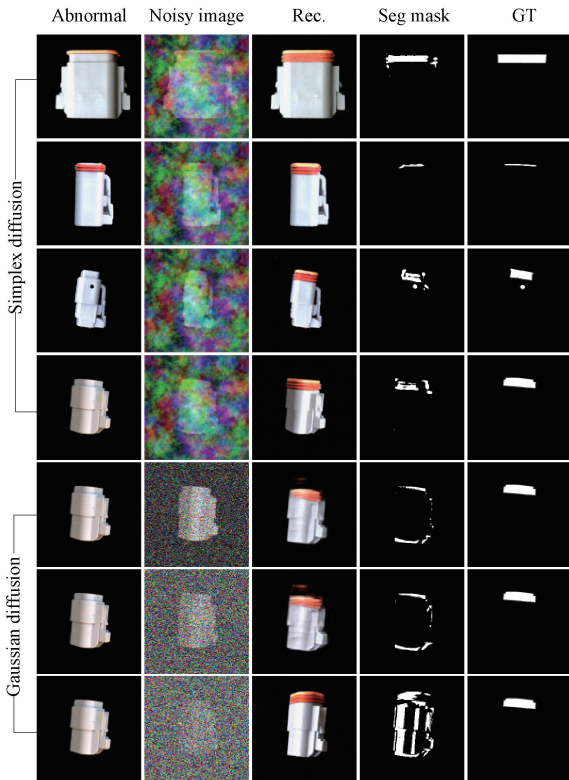


图8 单纯形噪声与高斯噪声的异常定位结果

Fig. 8 Anomalous localization results for single-form noise and Gaussian noise

表4 Gaussian-DDPM, OSDS-DDPM 以及 OSDS-DDPM+RM 的定量结果

Table 4 Quantitative results of Gaussian-DDPM, OSDS-DDPM and OSDS-DDPM+RM

模型	R $\uparrow$	F1 $\uparrow$	IoU $\uparrow$	AUROC $\uparrow$
Gaussian-DDPM	61.10	55.45	36.27	85.57
OSDS-DDPM	74.66	59.59	47.25	89.15
OSDS-DDPM+RM	<b>76.63</b>	<b>61.43</b>	<b>49.41</b>	<b>93.86</b>

表5对比了迭代去噪(Ite.)与一步去噪范式在图像重建质量和推理速度上的表现。SSIM作为衡量图像重建质量的指标。选取电子连接器正常样本进行测试,结果表明一步去噪范式更符合真实场景的应用。

表5 扩散模型与自适应加噪单步去噪扩散模型重建时间对比

Table 5 Comparison of reconstruction time between diffusion model and adaptive noise-adding single-step denoising diffusion model

指标	Ite. 200	Ite. 400	Ite. 600	本文
SSIM	0.92	0.93	0.82	0.97
推理时间/s	11.40	22.89	34.34	0.09

## 4 结 论

本文提出了面向一步去噪单纯形扩散模型的电子连接器无监督异常检测框架。该方法训练过程只需要电子连接器的正常样本。首先,利用SAM精确分割目标前景与背景,统一电子连接器姿态,去除冗余特征。然后引入单纯形噪声捕获更大的异常区域,通过预训练的U-net直接预测 $x_t$ ,当前 $\epsilon_t$ 将异常区域重建为正常纹理。为了达到实际推理需求,本文提出了一步去噪范式,在保障重建质量的前提下,达到最快的推理速度。实验结果显示,本文的方法在重建图像质量以及异常检测精度上具有显著优势。在未来,将进一步研究不同类型的噪声在异常检测中的应用。

## 参考文献

- [1] PANG G S, SHEN CH H, CAO L B, et al. Deep learning for anomaly detection: A review[J]. ACM Computing Surveys(CSUR), 2021, 54(2): 1-38.
- [2] TAO X, GONG X Y, ZHANG X, et al. Deep learning for unsupervised anomaly localization in industrial images: A survey[J]. IEEE Transactions on Instrumentation Measurement, 2022, 71: 1-21.
- [3] LIU J Q, XIE G Y, WANG J B, et al. Deep industrial image anomaly detection: A survey[J]. Machine Intelligence Research, 2024, 21(1): 104-135.
- [4] LUO Q W, FANG X X, LIU L, et al. Automated visual defect detection for flat steel surface: A survey[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(3): 626-644.
- [5] SILVA M I, MALITCKII E, SANTOS T G, et al. Review of conventional and advanced non-destructive testing techniques for detection and characterization of small-scale defects[J]. Progress in Materials Science, 2023, 138: 101155.
- [6] TULBURE A A, TULBURE A A, DULF E H. A review on modern defect detection models using DCNNs-Deep convolutional neural networks [J]. Journal of Advanced Research, 2022, 35: 33-48.
- [7] NONNENMACHER J, GÓMEZ J M. Unsupervised anomaly detection for internal auditing: Literature review and research agenda[J]. International Journal of Digital Accounting Research, 2021, 21. DOI: 10.4192/1577-8517-v21\_1.
- [8] SAEEDI J, GIUSTI A. Semi-supervised visual anomaly detection based on convolutional autoencoder and transfer learning [J]. Machine Learning with Applications, 2023, 11: 100451.



- [9] 王月, 银兴行, 郑帅, 等. 基于相似度对比学习的连接器零样本异常检测方法[J]. 仪器仪表学报, 2024, 44(10): 201-209.  
WANG Y, YING X H, ZHENG SH, et al. A zero-shot connector anomaly detection approach based on similarity-contrast learning [J]. Chinese Journal of Scientific Instrument, 2024, 44(10): 201-209.
- [10] 刘应桃, 郭世伟, 付孟新, 等. 基于改进 Faster RCNN 的轮对踏面缺陷检测[J]. 电子测量技术, 2023, 46(12): 34-41.  
LIU Y T, GUO SH W, FU M X, et al. Defect detection of wheelset tread based on improved Faster RCNN [J]. Electronic Measurement Technology, 2023, 46(12): 34-41.
- [11] TANG SH CH, JIN Z CH, DAI F H, et al. Progressive mask-oriented unsupervised fabric defect detection under background repair [J]. Coloration Technology, 2024, 140(3): 422-439.
- [12] ZHANG L, DAI Y, FAN F Y, et al. Anomaly detection of GAN industrial image based on attention feature fusion[J]. Sensors, 2022, 23(1): 355.
- [13] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview [J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [14] 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.
- [15] CIMPOI M, MAJI S, KOKKINOS I, et al. Describing textures in the wild[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 3606-3613.
- [16] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems, 2020, 33: 6840-6851.
- [17] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything [C]. IEEE/CVF International Conference on Computer Vision, 2023: 4015-4026.
- [18] PERLIN K. An image synthesizer[J]. ACM Siggraph Computer Graphics, 1985, 19(3): 287-296.
- [19] PERLIN K. Improving noise [C]. 29th annual Conference on Computer Graphics and Interactive Techniques, 2002: 681-682.
- [20] ASADI A, SAFABAKHSH R. The encoder-decoder framework and its applications [J]. Deep learning: Concepts and Architectures, 2020: 133-167, DOI: 10.1007/978-3-030-31756-0\_5.
- [21] SALIMANS T, KARPATHY A, CHEN X, et al. Pixelcnn++: Improving the pixelcnn with discretized logistic mixture likelihood and other modifications[J]. ArXiv preprint arXiv:1701.05517, 2017.
- [22] ZAGORUYKO S, KOMODAKIS N. Wide residual networks[J]. ArXiv preprint arXiv:1605.07146, 2016.
- [23] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric[C]. Conference on Computer Vision and Pattern Recognition, 2018: 586-595.
- [24] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [25] HE K M, CHEN X L, XIE S, et al. Masked autoencoders are scalable vision learners[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 16000-16009.
- [26] WANG ZH, 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.

### 作者简介

唐善成, 副教授, 主要研究方向为人工智能、深度学习、自然语言理解。

杨继清(通信作者), 硕士, 主要研究方向为机器视觉、工业缺陷检测。

E-mail: yangjiqingstudy@163.com

李恒, 硕士, 主要研究方向为缺陷检测、目标检测。