

DOI:10.19322/j.cnki.issn.1006-4710.2022.01.012

# 基于全嵌套编码-解码网络的异常检测模型

张学武

(中铁第一勘察设计院集团有限公司, 陕西 西安 710043)

**摘要:** 工程应用中往往异常样本匮乏, 监督学习方法无法应用。针对这一问题, 本文提出了一种只需要正常样本就可进行训练的深度网络模型——基于全嵌套编码-解码器的异常图像检测模型。该模型由一个生成器和一个判别器构成。生成器包含嵌入残差结构的编码-解码网络, 具有很好的特征表达和图像重构能力。判别器是一个分类网络, 用以鉴别输入是否为真实的正常样本。本文在标准数据集 CIFAR-10 和工业设备部件数据集上进行了对比实验, 实验结果表明本文提出的异常检测模型具有更高的检测精度。

**关键词:** 异常检测; 编码-解码; 残差网络; 生成-对抗网络

**中图分类号:** TP391.41

**文献标志码:** A

**文章编号:** 1006-4710(2022)01-0089-07

## A fully-nested encoder-decoder framework for anomaly detection

ZHANG Xuewu

(China Railway First Survey and Design Institute Group Co., Ltd, Xi'an 710043, China)

**Abstract:** In engineering applications, the abnormal samples are often scarce, so the supervised learning method cannot be applied. To solve this problem, this paper proposes a full-nested encoder-decoder anomaly detection model which only needs normal samples. The main part of the model consists of a generator and a discriminator. The generator is composed of an encoder-decoder network with embedded residual structures, which has good ability in feature expression and image reconstruction. The discriminator is a classification network for identifying whether the input is a real normal sample. This paper conducts comparative experiments on the standard dataset CIFAR-10 and the industrial equipment part dataset. The experimental results show that the proposed anomaly detection model has higher detection accuracy.

**Key words:** anomaly detection; encoder-decoder; residual network; generative adversarial network

通过图像识别方法发现工业设备部件的故障或缺陷越来越受到研究者的关注<sup>[1-6]</sup>。卷积神经网络(convolutional neural networks, CNN)的发展为图像异常检测提供了新的思路。从 LeNet<sup>[7]</sup>结构的提出, 到 AlexNet<sup>[8]</sup>, 再到 VGG<sup>[9]</sup> 和 Inception 系列<sup>[10-12]</sup>, CNN 的性能越来越好。在异常检测任务中, 基于 CNN 使用有监督学习的手段对目标故障进行检测已经得到了广泛应用。Ren 等<sup>[13]</sup> 提出 Faster R-CNN, 实现了一个完全意义上的端到端的 CNN 目标检测模型, 有效提高了目标检测的速度和精度。Wei 等<sup>[14]</sup> 将 Faster R-CNN 应用于铁路轨道

紧固件异常检测。Guo 等<sup>[15]</sup> 提出了一种改进的 Faster R-CNN, 对高铁接触网吊弦进行了定位识别。然而, 在某些工程领域, 异常样本匮乏导致基于图像分类的目标检测模型难以训练。因此, 基于正常样本的异常检测方法更值得重视。

近年来, CNN 的发展为基于正常数据的异常检测任务提供了新的思路。Goodfellow 等<sup>[16]</sup> 于 2014 年提出了一种称为对抗生成网络(generative adversarial network, GAN)的非监督学习方法。接下来, LAPGAN<sup>[17]</sup>、CGAN<sup>[18]</sup>、InfoGAN<sup>[19]</sup>、CycleGAN<sup>[20]</sup>等方法相继被提出, 使得生成对抗模型

收稿日期: 2021-03-25; 网络出版日期: 2021-07-16

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.N.20210715.1825.002.html>

基金项目: 2018 年度科技重大专项基金资助项目(18-A02)

通信作者: 张学武, 男, 硕士, 高级工程师, 研究方向为图像识别及其在高铁中的应用(2723622940@qq.com)

性能逐步提升。AnoGAN<sup>[21]</sup>首次将 GAN 应用在异常检测领域,实现了在无异常样本情况下的异常检测。该方法仅利用正常样本训练 DCGAN<sup>[22]</sup>,并设计一种图像距离度量模型来检测异常样本。但在测试阶段 AnoGAN 需要不断地更新潜在向量,计算成本较高。针对 AnoGAN 计算成本高的缺陷,Zenati 等<sup>[23]</sup>提出的 Efficient-GAN 采用图像空间与潜在空间双向同时映射的方法,同时学习编码器、生成器和判别器的参数。ALAD<sup>[24]</sup>在 Efficient-GAN 模型的基础上添加了额外的判别器来改进编码器,使模型训练更加稳定。f-AnoGAN<sup>[25]</sup>用正常样本训练,并提出用编码器快速将图像映射到潜在空间,以便进行快速推断和异常检测。Akçay 等<sup>[26]</sup>提出 GANomaly 方法,运用对抗机制交替训练自编码器,进行图像的重构。另外,他们通过度量输入图像和重构图像及其深层语义特征之间的差异来检测异常样本。Skip-GANomaly<sup>[27]</sup>基于 GANomaly,在生成网络中引入编码网络和解码网络间的跳过连接,来减少编码阶段信息的损失,增强了模型性能。但是在某些小目标的异常类检测任务中,比如 CIFAR-10 数据集上的 cat, bird 等类别上,GANomaly 和 Skip-GANomaly 表现不尽如人意。而且其编码

解码网络在训练过程中缺乏稳定性,鲁棒性较差。

本文提出了一种基于全嵌套编码-解码网络的异常图像检测模型。该模型包含一个生成器和判别器,通过与距离度量模型结合来检测异常图像。在生成器中,设计了多个编码-解码网络的嵌套结构,拥有 1 个共享的编码网络和 4 个并联的解码分支。该模型可以通过反向传播,针对不同尺度的嵌套模型,自主地适应合适的网络深度和尺寸。同时,选取 DCGAN 中的判别网络作为模型的判别器。生成器和判别器通过对抗机制来交替训练。在 CIFAR-10 图像数据集上的实验展示了本文的方法比近期提出的其他模型具有更优良的性能。

### 1 模型结构与训练策略

本文提出了一种全嵌套的编码-解码模型来进行异常图像检测。见图 1,该检测方法的主体包括两部分内容:生成模型(generator)和判别模型(discriminator)。生成模型通过学习正常样本的分布,来重构正常样本。判别模型使用一个分类网络作为判别器,使用生成对抗机制进行训练。进而引入一个距离度量模型,通过计算重构图像和真实图像之间的距离,来判别测试样本是否异常。

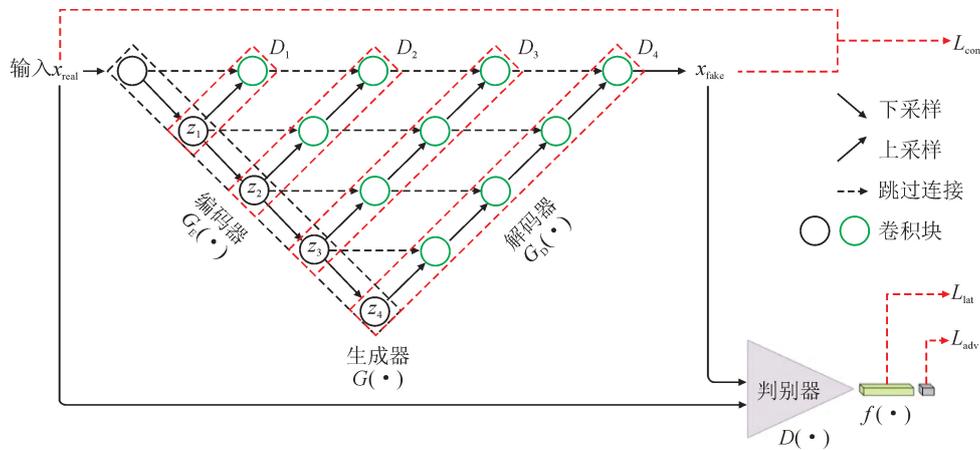


图 1 异常检测模型框架  
Fig. 1 Proposed framework for anomaly detection

#### 1.1 生成模型

生成模型通过学习正常样本的分布,来重构正常样本。在本文中,生成模型中的生成器是一个全嵌套的残差网络,可分为一个编码器和一个解码器。见图 2,该网络可以看作多个不同尺度的编码-解码网络进行嵌套,编码器为共享部分,解码器针对编码器产生的 4 种不同尺度的语义特征图,进行解码操作,产生 4 个并联的解码分支。

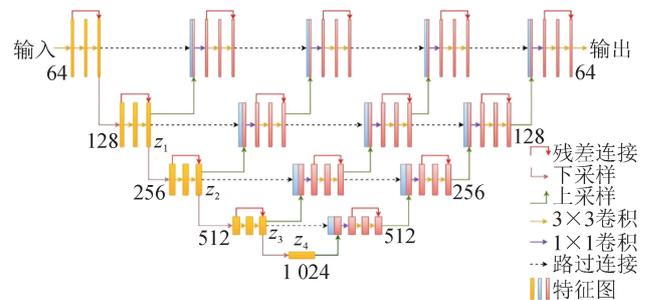


图 2 本文提出的生成器的结构  
Fig. 2 Architecture of the proposed generator

编码器为共享部分,如图1虚线编码器框所示,表示为 $G_E$ ,用来读入输入图像 $x_{\text{real}}$ ,产生深层语义特征图 $z = (z_1, z_2, z_3, z_4)$ :

$$z = G_E(x_{\text{real}}) \quad (1)$$

解码器针对 $(z_1, z_2, z_3, z_4)$ 4种不同尺度的深层语义特征图,进行解码操作,产生4个并行的解码分支 $D_1, D_2, D_3$ 和 $D_4$ ,如图1中虚线解码器框所示,表示为 $G_D$ 。此外,处于内部的解码分支使用密集的跳过连接对邻近的外部解码分支进行特征融合。跳过连接增强了不同分支间细节信息的传递,极大地减少了信息损失。最终外部分支最后一层输出解码器的重构图像 $x_{\text{fake}}$ :

$$x_{\text{fake}} = G_D(z) \quad (2)$$

在编码器和解码器中均加入了残差结构,增强了特征表达能力,减小了过拟合风险。模型可以通过反向传播,针对4种尺度的嵌套模型,自主的适应合适的网络深度和尺寸。

我们在生成器后面加入了一个分类网络,作为模型的判别器,表示为 $D$ ,使用生成对抗机制对生成器和判别器进行交替训练。分类网络用来预测给定输入类别,鉴别真实的正常图像 $x_{\text{real}}$ 以及生成器重构的图像 $x_{\text{fake}}$ 。判别器沿用了DCGAN模型中的判别网络。在整个网络结构中,使用了BN<sup>[28]</sup>和ReLU<sup>[29]</sup>激活函数。

将数据分为 $D_{\text{train}}$ 和 $D_{\text{test}}$ ,其中 $D_{\text{train}}$ 只包含正常数据样本,用于模型的训练, $D_{\text{test}}$ 中包含正常数据样本和异常数据样本,用于模型评估。训练阶段利用正常样本训练生成器和判别器,测试阶段利用生成器生成接近正常样本的重构图像,将输入样本和重构图像进行距离计算,来检测异常图像。

## 1.2 距离度量模型

在测试阶段,为度量图像是否异常,采用计算测试图像异常评分的方式,对于给定测试集输入 $x_{\text{test}}$ ,异常评分定义为 $A(x_{\text{test}})$ 。我们使用了两种距离来度量 $x_{\text{test}}$ 和 $x_{\text{fake}}$ 之间的差距。首先直接对 $x_{\text{test}}$ 和 $x_{\text{fake}}$ 计算 $L_1$ 距离,表示为 $R(x_{\text{test}})$ ,该距离描述了重构图像和输入图像之间的细节差异。其次,计算 $x_{\text{test}}$ 和 $x_{\text{fake}}$ 经判别器特征提取后产生的高维向量 $f(x_{\text{test}})$ 和 $f(x_{\text{fake}})$ 之间的 $L_2$ 距离,表示为 $L(x_{\text{test}})$ ,该距离描述了两者的语义特征差异。 $A(x_{\text{test}})$ ,  $R(x_{\text{test}})$ 和 $L(x_{\text{test}})$ 公式如下:

$$A(x_{\text{test}}) = \lambda R(x_{\text{test}}) + (1 - \lambda)L(x_{\text{test}}) \quad (3)$$

$$R(x_{\text{test}}) = \|x_{\text{test}} - x_{\text{fake}}\|_1 \quad (4)$$

$$L(x_{\text{test}}) = \|f(x_{\text{test}}) - f(x_{\text{fake}})\|_2 \quad (5)$$

式中: $\lambda$ 是用来平衡两种差异分数重要性的权重参

数,在本模型中,设置 $\lambda = 0.9$ 。

通过以上公式,可以计算出测试集 $D_{\text{test}}$ 中所有图像的异常分数集合 $A = \{A_i : A(x_{\text{test},i}), x_{\text{test}} \in D_{\text{test}}\}$ 。接下来对集合 $A$ 进行线性归一化处理,将异常分数压缩到 $[0, 1]$ ,公式如下:

$$A'(x_{\text{test}}) = \frac{A(x_{\text{test}}) - \min(A)}{\max(A) - \min(A)} \quad (6)$$

设定阈值,异常分数 $A'(x_{\text{test}})$ 大于阈值的样本 $x_{\text{test}}$ 判定为异常,小于阈值的样本判定为正常。

## 1.3 训练策略

本模型使用了三种损失函数 Adversarial Loss、Contextual Loss 和 Latent Loss。

Adversarial Loss 的目的是提高模型重构正常图像的能力。该损失函数保证了生成器重构的图像尽可能接近真实样本,同时保证了判别器能够更好地辨别真实样本和重构图像。模型通过 $\min_G \max_D L_{\text{adv}}$ 来交替更新生成器和判别器的参数:

$$L_{\text{adv}} = \log D(x_{\text{real}}) + \log(1 - D(x_{\text{fake}})) \quad (7)$$

式中: $D$ 表示判别器对图像的分类概率。

Contextual Loss 通过计算重构图像 $x_{\text{fake}}$ 和输入正常样本 $x_{\text{real}}$ 的 smoothL1<sup>[30]</sup>损失,使得重构图像 $x_{\text{fake}}$ 充分地学习原始正常样本 $x_{\text{real}}$ 的图像细节信息,拟合 $x_{\text{real}}$ 的数据分布。损失函数定义为:

$$L_{\text{con}} = S_{\text{L1}}(x_{\text{real}} - x_{\text{fake}}) \quad (8)$$

式中: $S_{\text{L1}}$ 表示 smoothL1 损失函数:

$$S_{\text{L1}} = \begin{cases} 0.5 x^2 & |x| < 1 \\ |x| - 0.5 & |x| \geq 1 \end{cases} \quad (9)$$

Latent Loss 通过计算重构图像 $x_{\text{fake}}$ 与输入正常样本 $x_{\text{real}}$ 经判别器特征提取后产生的深层语义特征向量 $f(x_{\text{real}})$ 和 $f(x_{\text{fake}})$ 之间的 smoothL1 损失,使重构图像 $x_{\text{fake}}$ 充分地学习原始正常样本 $x_{\text{real}}$ 的内在语义信息。损失函数定义为:

$$L_{\text{lat}} = S_{\text{L1}}(f(x_{\text{real}}) - f(x_{\text{fake}})) \quad (10)$$

本方法采用和常规的GAN一致的生成对抗机制进行训练,交替优化判别器和生成器。优化判别器时,固定生成器网络的参数。通过将生成器生成的图像作为负样本与存在的正样本输入判别器来训练参数,目标函数为:

$$L_{D\text{-Net}} = \max_D L_{\text{adv}} \quad (11)$$

优化生成器时,固定判别器的参数,目标函数为:

$$L_{G\text{-Net}} = \min_G (\omega_{\text{adv}} L_{\text{adv}} + \omega_{\text{con}} L_{\text{con}} + \omega_{\text{lat}} L_{\text{lat}}) \quad (12)$$

式中: $\omega_{\text{adv}}$ ,  $\omega_{\text{con}}$ ,  $\omega_{\text{lat}}$ 是各损失的权重参数。

## 2 实验

本文的实验环境为:采用 Pytorch1.1.0 深度学习框架,计算服务器配置为:内存 256 GB,主频 3.2 GHz、16 核的 Xeon E5-2664 v4 Gold 的 CPU,16 GB 显存、3584 个核心的 NVIDIA Tesla P100 GPU。

### 2.1 数据集

为了评估提出的异常检测模型,本文在标准数据集 CIFAR-10 和工业设备部件数据集上进行了实验。

#### 1) CIFAR-10 数据集

CIFAR-10 数据集共有 60 000 张彩色图像,这些图像的尺寸为  $32 \times 32$ ,共分为 10 个类,每个类有 6 000 张图像。在对 CIFAR-10 数据集进行异常检测实验时,将其中某一类视为异常类,将其他 9 类视为正常类。具体地,将某类 6 000 张图像作为异常图像,其余 9 类的 54 000 张图像作为正常类图像,其中 45 000 张作为训练样本进行模型训练,9 000 张正常类图像和 6 000 张异常类图像作为测试样本进行模型测试。

#### 2) 工业设备部件数据集

我们挑选了高铁接触网的某个紧固件的图像作为本文方法的工业应用数据集,其正常样本和异常样本示例见图 3。工业设备部件数据集训练集包含 1 600 张正常样本图像,测试集包含 400 张图像,其中正常样本和异常样本各 200 张。

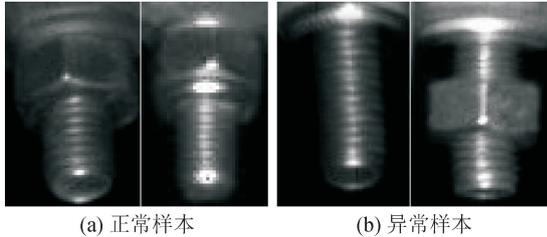


图 3 正常样本和异常样本示例图

Fig. 3 Examples of normal samples and abnormal samples

### 2.2 实验细节

#### 2.2.1 训练过程

实验训练阶段使用由正常样本组成的训练集进行训练,测试阶段使用由正常样本和异常样本组成的测试集进行测试。

实验设置了 15 个 epoch,初始学习率为 0.000 2,采用 lambda 衰减。使用 Adam 作为默认优化器,  $\beta_1 = 0.5$ ,  $\beta_2 = 0.999$ 。损失函数各部分权重参数  $w_{adv} = 1$ ,  $w_{con} = 20$ ,  $w_{lat} = 1$ 。距离度量权重参数  $\lambda = 0.9$ 。

#### 2.2.2 评价指标

本文使用 AUROC、AUPRC、 $F_1$  分数、精确率和召回率来评估所提出方法的性能。

AUROC 是 ROC 曲线下方的面积,ROC 曲线由多种阈值设定下的 FPR 和 TPR 组成。

AUPRC 是 PR 曲线下方的面积,PR 曲线由多种阈值设定下的精确率和召回率组成。

$F_1$  分数为精确率和召回率的调和平均数,其计算方式见式(13)。在本文实验中,我们在 PR 曲线中设置阈值为 0.2 来计算  $F_1$  分数。

$$F_1 = \frac{2 \cdot P \cdot R}{P + R} \quad (13)$$

式中:

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

这里  $P$  是精确率,  $R$  是召回率,  $TP$  为正样本且被正确划分为正样本的数量,  $FP$  为负样本且被错误划分为正样本的数量,  $FN$  为正样本且被错误分为负样本的数量。  $TP + FP$  为全部被分为正样本的数量,  $TP + FN$  为实际的正样本数量。

### 2.3 实验结果及分析

为了更好的测试本文提出方法的性能,在 CIFAR-10 数据集上将所提出的方法与多种方法进行了对比试验。

GANomaly 和 Skip-GANomaly 的参数设置与我们的参数设置完全一致,f-AnoGAN 沿用了文献[25]中的参数设置。

表 1 展示了 CIFAR-10 数据集在 AUROC 指标下的实验结果,表 2 展示了 CIFAR-10 数据集在 AUPRC 指标下的实验结果,图 4 和图 5 为相应的结果比较。可以看出,在 CIFAR-10 数据集的每一类异常情况中,本文提出的方法在 AUROC 和 AUPRC 指标下均达到了更高的精度。并且本文提出的方法在 plane、frog、ship 这三类物体中性能最好,异常检测精度几乎接近 100%。值得注意的是,对于 CIFAR-10 数据集中最具挑战性的异常类 bird 和 horse,先前工作的最佳 AUROC 分别为 0.661 和 0.663,最佳 AUPRC 分别为 0.558 和 0.501,而本文方法的 AUROC 达到了 0.874 和 0.864,精度提升了 21.3% 和 20.1%,AUPRC 达到了 0.818 和 0.775,精度提升了 26.0% 和 27.4%。

表 1 CIFAR-10 数据集 AUROC 结果  
Tab.1 AUROC results for CIFAR-10 dataset

方法	plane	car	bird	cat	deer	dog	frog	horse	ship	truck	Avg
f-AnoGAN	0.529	0.731	0.389	0.482	0.365	0.517	0.431	0.603	0.484	0.697	0.523
GANomaly	0.966	0.691	0.561	0.637	0.745	0.722	0.915	0.632	0.919	0.711	0.750
Skip-GANomaly	0.997	0.869	0.661	0.747	0.927	0.749	0.974	0.663	0.968	0.872	0.843
本文方法	<b>0.999</b>	<b>0.947</b>	<b>0.874</b>	<b>0.877</b>	<b>0.973</b>	<b>0.839</b>	<b>0.995</b>	<b>0.864</b>	<b>0.998</b>	<b>0.901</b>	<b>0.927</b>

表 2 CIFAR-10 数据集 AUPRC 结果  
Tab.2 AUPRC results for CIFAR-10 dataset

方法	plane	car	bird	cat	deer	dog	frog	horse	ship	truck	Avg
GANomaly	0.929	0.516	0.492	0.525	0.666	0.604	0.853	0.501	0.821	0.525	0.643
Skip-GANomaly	0.997	0.770	0.558	0.635	0.911	0.606	0.961	0.494	0.943	0.803	0.768
本文方法	<b>0.999</b>	<b>0.912</b>	<b>0.818</b>	<b>0.825</b>	<b>0.963</b>	<b>0.707</b>	<b>0.993</b>	<b>0.775</b>	<b>0.998</b>	<b>0.836</b>	<b>0.883</b>

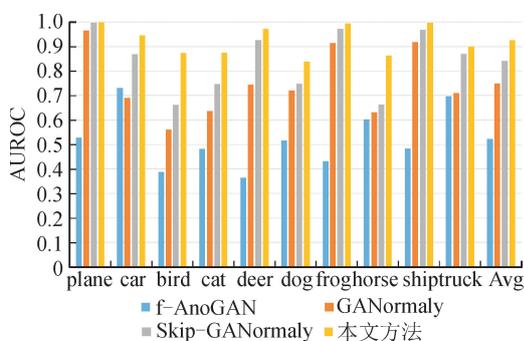


图 4 在 CIFAR-10 数据集上本文方法与其他方法 AUROC 结果的比较

Fig.4 Comparison of AUROC results between our method and other methods on CIFAR-10 dataset

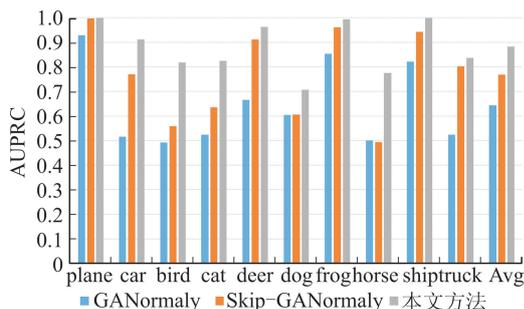
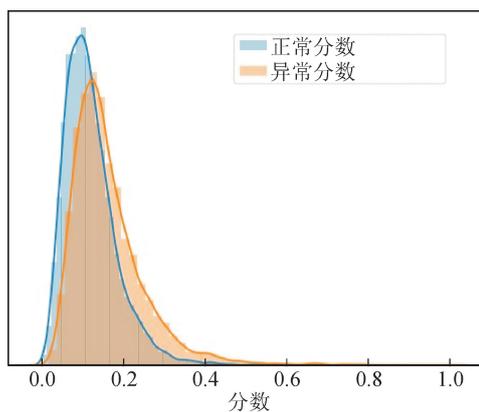


图 5 在 CIFAR-10 数据集上本文方法与其他方法 AUPRC 结果的比较

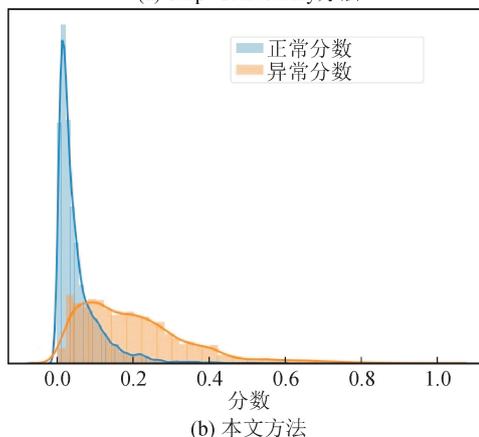
Fig.5 Comparison of AUPRC results between our method and other methods on CIFAR-10 dataset

图 6 展示了 Skip-GANomaly 和本文的方法对 bird 类作为异常类时测试数据正常分数和异常分数的直方图,可以直观地看出与 Skip-GANomaly 相比,本文方法可以更好地将正常类和异常类区别开来,取得很好的异常检测效果。图 7 将 bird 类作为异常类,展示了在测试阶段我们的方法对物体的重

构效果。在标准数据集 CIFAR-10 测试本文方法的表现后,我们在接触网数据集上进一步验证方法在实际工业设备部件图像中的应用效果。同样,我们将提出的方法和 GANomaly 和 Skip-GANomaly 进行了对比试验,测试结果见表 3。



(a) Skip-GANomaly方法



(b) 本文方法

图 6 鸟类作为异常类时测试数据的正常和异常分数直方图

Fig.6 Histograms of the normal and abnormal scores for the test data when bird being used as abnormal class



图 7 CIFAR-10 数据集中的真实物体图像及其重建图像

Fig. 7 Real images of objects in CIFAR-10 dataset and their reconstructed images generated by our method

表 3 工业设备部件数据集的对比实验结果

Tab. 3 Comparative experiment results of industrial equipment part dataset

方法	AUROC	AUPRC	$F_1$	Recall	Precision
GANormaly	0.892	0.887	0.764	0.682	0.870
Skip-GANomaly	0.873	0.828	0.775	0.831	0.733
本文方法	<b>0.987</b>	<b>0.967</b>	<b>0.983</b>	<b>1.000</b>	<b>0.967</b>

可以看出,本文方法在工业设备部件数据集的异常检测任务中,展现了优良的性能,有着巨大的优势。为进一步展现精度对比,在 PR 曲线中,本文设置阈值为 0.2,得到三种方法的  $F_1$  分数、精确率和召回率。如表 3 所示,本文的方法在五种指标上均达到了最高值,分别为 98.7%、96.7%、98.3%、100.0%和 96.7%,对比另外两种方法均有大幅度的精度提升。

综合以上实验效果来看,本文提出的异常检测方法比先前的相关工作具有更好的检测性能,并在工业设备部件图像中表现优异,基本达到了在实际工业场景应用的要求。

### 3 结 论

本文提出了一种基于全嵌套编码-解码网络的异常图像检测模型。模型包含一个生成器和一个判别器,并通过距离度量模型检测异常数据。本文设计了一种新的嵌入残差结构的编码-解码网络作为生成器,具有很好的特征表达和图像重构能力。在标准数据集 CIFAR-10 和工业设备部件数据集上的多组对比实验结果表明本文的方法比新近提出的其他方法在识别精度上有很大的提升,并体现了本文方法的应用有效性。本方法只需要采集一定量的正

常图像就可以训练出精度很高的异常图像检测模型,回避了工业应用中难以获取大量异常图像样本无法进行监督学习的难题。因此,本文所提出的方法具有很强的工程应用价值。

#### 参考文献:

- [1] HODGE V J, AUSTIN J. A survey of outlier detection methodologies[J]. Artificial Intelligence Review, 2004, 22(2): 85-126.
- [2] NIU Zhixian, SHI Shuping, SUN Jingyu, et al. A survey of outlier detection methodologies and their applications[C]// International Conference on Artificial Intelligence and Computational Intelligence, Springer, Berlin, Heidelberg, 2011: 380-387.
- [3] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection: a survey[J]. ACM Computing Surveys, 2009, 41(3): 1-58.
- [4] AHMED M, MAHMOOD A N, HU Jiankun. A survey of network anomaly detection techniques[J]. Journal of Network and Computer Applications, 2016, 60(C): 19-31.
- [5] MA Junjie, DAI Yaping, HIROTA K. A survey of video-based crowd anomaly detection in dense scenes[J]. Journal of Advanced Computational Intelligence and Intelligent Informatics, 2017, 21(2): 235-246.
- [6] KWON D, KIM H, KIM J, et al. A survey of deep learning-based network anomaly detection[J]. Cluster Computing, 2019, 22(5): 949-961.
- [7] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. IEEE, 1998, 86(11): 2278-2324.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[R]// 25th International Conference on Neural Information Processing Systems, Lake Tahoe Nevada,

- 2012; 1097-1105.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// International Conference on Learning Representations, San Diego, 2015:1-14.
- [10] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015: 1-9.
- [11] SZEGEDY C, VANHOUCHE V, IOFFE S, et al. Rethinking the Inception architecture for computer vision[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016; 2818-2826.
- [12] SZEGEDY C, IOFFE S, VANHOUCHE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]//31st AAAI Conference on Artificial Intelligence, San Francisco, California USA, 2017; 4278-4284.
- [13] REN Shaoqing, HE Kaiming, 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, 2017, 39 (6): 1137-1149.
- [14] WEI Xiukun, YANG Ziming, LIU Yuxin, et al. Railway track fastener defect detection based on image processing and deep learning techniques: a comparative study[J]. Engineering Applications of Artificial Intelligence, 2019, 80: 66-81.
- [15] GUO Qifan, LIU Lei, XU Wenjuan, et al. An improved faster R-CNN for high-speed railway dropper detection[J]. IEEE Access, 2020, 8: 105622-105633.
- [16] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [17] DENTON E, CHINTALA S, SZLAM A, et al. Deep generative image models using a Laplacian pyramid of adversarial networks[C]//Proceeding of the 28th International Conference on Neural Information Processing Systems, Montreal Canada 2015; 1486-1494.
- [18] MIRZA M, OSINDERO S. Conditional generative adversarial nets[OL]. <https://arxiv.org/abs/1411.1784>.
- [19] CHEN Xi, DUAN Yan, HOUTHOOFT R, et al. InfoGAN: interpretable representation learning by information maximizing generative adversarial nets [C]// Proceeding of the 30th International Conference on Neural Information Processing Systems, Barcelona, Spain, 2016; 2180-2188.
- [20] ZHU Junyan, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]// 2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017; 2242-2251.
- [21] 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, Springer, Cham, 2017; 146-157.
- [22] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[OL]. <https://arxiv.org/abs/1511.06434>.
- [23] ZENATI H, FOO C S, LECOAT B, et al. Efficient GAN-based anomaly detection[C]// International Conference on Learning Representations (ICLR), 2018.
- [24] ZENATI H, ROMAIN M, FOO C S, et al. Adversarially learned anomaly detection[C]// 2018 IEEE International Conference on Data Mining (ICDM), Singapore, 2018; 727-736.
- [25] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. f-AnoGAN: fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 54: 30-44.
- [26] AKÇAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. GANomaly: semi-supervised anomaly detection via adversarial training[C]// Asian Conference on Computer Vision. Springer, 2018; 622-637.
- [27] AKÇAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Skip-GANomaly: skip connected and adversarially trained encoder-decoder anomaly detection[C]// 2019 International Joint Conference on Neural Networks (IJCNN), Budapest, Hungary, 2019; 1-8.
- [28] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//32nd International Conference on International Conference on Machine Learning, Lille, France, 2015; 448-456.
- [29] GLOTOT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks[C]//14th International Conference on Artificial Intelligence and Statistics (AISTATS), Ft. Lauderdale, FL, USA, 2011; 315-323.
- [30] GIRSHICK R. Fast R-CNN[C]// 2015 IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 2015, 1440-1448.

(责任编辑 王绪迪)