DOI: 10.13382/j.jemi.B2306479

基于对比学习生成对抗网络的无监督工业品表面异常检测*

张 玥[1] 陈锡伟[1] 陈梦丹[1] 周新龙[2] 张宏伟[1]
(1.西安工程大学电子信息学院 西安 710048;2.陕西摩迈信息科技有限公司 西安 710075)

摘 要:在工业品表面异常检测中,由于异常的未知性和无规则性,人工标注异常样本难度大、成本高,有监督的深度学习算法在工业品表面异常检测任务中存在局限性。针对上述问题,提出一种基于对比学习生成对抗网络(contrastive learning generative adversarial network,CLGAN)的无监督工业品表面异常检测算法。首先,建立基于无监督学习算法的 CLGAN 模型;其次,采用对比学习加强潜在特征空间正负例样本约束,使得输入与输出图像对应 Patch 之间的互信息最大化,增强正负样本特征向量区分度,使模型重构异常样本图像能力得到进一步提升;然后,在检测阶段,利用训练好的模型得到待测工业品的无异常重构图像,并计算得到待测样本与其对应重构图像之间的残差图像;最后,结合双阈值分割的后处理方法和数学形态学处理,实现工业品表面异常区域地快速检测和准确定位。通过在公共数据集 MVTec AD 上进行实验,与其他的无监督深度学习模型算法相比,所提算法具有更好的识别效果和更强的泛化能力。

关键词: 异常检测;深度学习;无监督学习;对比学习;重构图像;特征空间
中图分类号: TP391.41 **文献标识码**:A **国家标准学科分类代码**: 540.10

Unsupervised surface anomaly detection of industrial products based on contrastive learning generative adversarial network

Zhang Yue[1] Chen Xiwei[1] Chen Mengdan[1] Zhou Xinlong[2] Zhang Hongwei[1]
(1. School of Electronics and Information, Xi′an Polytechnic University, Xi′an 710048, China;
2. Shaanxi Momai Information Technology Co., LTD., Xi′an 710075, China)

Abstract: In the anomaly detection of industrial surfaces, due to the unknown and irregular nature of the abnormalities, it is difficult and costly to manually label abnormal samples, and the supervised deep learning algorithms have limitations in the task of anomaly detection on the surface of industrial products. To address the above problems, an unsupervised surface anomaly detection algorithm based on contrastive learning generative adversarial network (CLGAN) is proposed. Firstly, the CLGAN model based on unsupervised learning algorithm is established. Secondly, contrastive learning is used to strengthen the positive and negative sample constraints of the potential feature space, maximizing the mutual information between the corresponding patches of the input and output images, enhancing the differentiation of positive and negative sample feature vectors, and further improving the ability of the model to reconstruct abnormal sample images. Then, in the detection stage, the trained model is used to obtain the anomaly-free reconstruction image of the industrial product to be tested, and the residual image between the sample to be measured and its corresponding reconstructed image is calculated. Finally, combined with the double threshold segmentation method and mathematical morphology processing, the rapid detection and accurate location of abnormal areas on the surface of industrial products are realized. Experimental results on the public dataset MVTec AD demonstrate that the proposed algorithm has a better recognition effect and stronger generalization ability compared with other unsupervised deep learning model algorithms.

Keywords: anomaly detection; deep learning; unsupervised learning; contrastive learning; reconstructed image; feature space

收稿日期: 2023-04-27 Received Date: 2023-04-27
*基金项目:国家自然科学基金(61803292)、中国纺织工业联合会科技指导性项目(2020111)资助

0 引 言

工业品表面异常不仅直接影响产品的外观和质量，甚至可能在使用过程中产生安全隐患。因此，异常检测是工业生产检测领域中重要环节之一[1-2]。人工目视检测容易受工人视觉疲劳、困乏等生理状态影响，速度慢、成本高、难以覆盖工业大规模质检需求。传统机器视觉的检测方法过度依赖人为设计的图像特征提取与分类方法，准确率受外界环境波动较大[3-4]。基于深度学习的检测方法能自动学习人工难以设计的特征[5-6]，在处理背景复杂、异常微弱的工业图像时展现出卓越的性能优势[7-8]。

在有监督深度学习异常检测领域中，采用卷积神经网络（convolutional neural networks，CNN）的分类网络已成为表面异常分类中最常见的模式[9]。如李良福等[10]提出一种基于 CNN 和 DDBC（deep bridge crack classify）的分类模型，用于桥梁背景面元和桥梁裂缝面元的识别。但有监督深度学习算法在进行数据分类预测时，通常需要大量的标注样本数据进行训练，以学习良好的特征表示和分类决策。然而在实际制造业检测现场，面对表面异常种类的不平衡性、未知性和无规则性，获取大量人工标注过的异常样本来训练神经网络相对困难，因而有监督的深度学习算法在异常检测领域存在较大局限性[11]。

自监督深度学习算法要设计辅助任务来挖掘数据自身的表征特性作为监督信息，设计方案复杂。无监督深度学习算法和无监督学习算法都不需要标签数据，但无监督学习算法通常应用于传统机器学习任务，而无监督深度学习算法通常与深度神经网络结合使用，模型设计方案更加简单、高效，同时可以解决有监督方法需要大量标注数据的问题，因而广受欢迎。如 Schlegl 等[12]提出的基于 GAN 的异常检测模型从随机变量开始，计算变量生成的图像和待测图像之间的差异，通过梯度下降的方式迭代优化该随机变量，使得生成的图像逐渐接近待测图像，由于生成器仅使用正常样本进行训练，当表面异常情况复杂时，准确率不高。Deecke 等[13]从多个点开始尝试对待测图像进行重构，而且在迭代优化过程中，同时优化隐变量和生成器内部参数，以此来提升图像重构的质量。但在检测阶段需要进行多次的迭代优化来生成合适的正常图像作为参考，增加算法的执行时间，难以满足工业品生产的实际需求。Wei 等[14]提出了一种基于变分自编码器（variational auto-encoder-structural similarity，VAE-SSIM）的实时织物缺陷检测方法，该方法使用均方差和结构相似度的组合损失函数衡量重构图像和输入图像的相似性。张宏伟等[15]还提出一种 U 型去噪卷积自编码器（U-shaped denosing convolutional auto-encoder，UDCAE）的方法，对待测图像与其重构图像的残差图像进行处理，实现色织物缺陷的检测及定位。但该方法只适用于背景纹理较为简单的色织物，泛化性差。

针对有监督的深度学习算法人工标注异常样本难度大、成本高，本文提出一种基于对比学习生成对抗网络的无监督工业品表面异常检测算法，其核心思想是通过训练大量的无异常工业品样本图像，学会创建图像的低维表示，完成重构图像，并与原始图像进行分析比较实现异常检测[16]。在模型训练过程中，通过生成器和判别器完成工业品图像深层高维特征提取和全局视图特征表达。特征向量经 4 层感知器（multilayer perceptron，MLP）二次映射到特征度量式隐空间中，进行正负实例向量与查询向量之间相似度的计算。在隐空间中引入对比学习，增强对正负例样本特征向量约束，减少无关特征信息参数和浮点计算，学习基于 Patch 图像内容的相关交互，建立重构图像的每个 Patch 区域与输入图像对应 Patch 区域的关联性，进一步提升主干网络的重构修复能力。最终结合双阈值分割的后处理方法和数学形态学处理，实现工业品表面异常区域快速检测和准确定位。

1 算 法

1.1 基于 CLGAN 的模型训练

基于自监督的对比学习算法主要思想是模型自动构造相似实例和不相似实例，通过对比学习得到像素级重构表示学习模型，使得相似实例在投影空间中距离拉近，不相似实例在投影空间中距离拉远。输入图像与重构图像之间存在对应的像素联系，这种关联性在对比表征学习领域称为互信息，可以作为图像特征相似度的目标函数，值越大表明两个图像特征之间的相似度越高，反之表明相似度较低[17]。对比学习通过最大化输入输出互信息，增加输入图像与重构图像之间的关联性，使得重构图像的全局视图得到高效表征。因此，为了有效提取工业品表面图像的深层特征信息，使得图像重构修复效果好，构造一种基于 CLGAN 的工业品图像重构模型，使用对比学习来最大化输入工业品图像 Patch 和输出工业品图像 Patch 之间的互信息，完成 Patch 级别的图像重构修复。CLGAN 模型主要包含生成器 G、判别器 D、潜在特征空间对比学习框架 3 个部分，其中生成器又分为编码器 G_{enc} 和解码器 G_{dec} 两个部分，模型总体架构如图 1 所示。

编码器结构与解码器结构对称。编码时对图像进行下采样，分辨率逐层减半，解码时分辨率逐层倍增。通过特征层叠加，既保留了所有层的重要信息，又能输出与编码器输入尺寸大小一致的重构图像。在模型训练阶段，具体过程如下：首先分辨率为 256×256 的 3 通道无异常样本图像 Real_A 输入生成器，通过 3 层卷积编码器进行

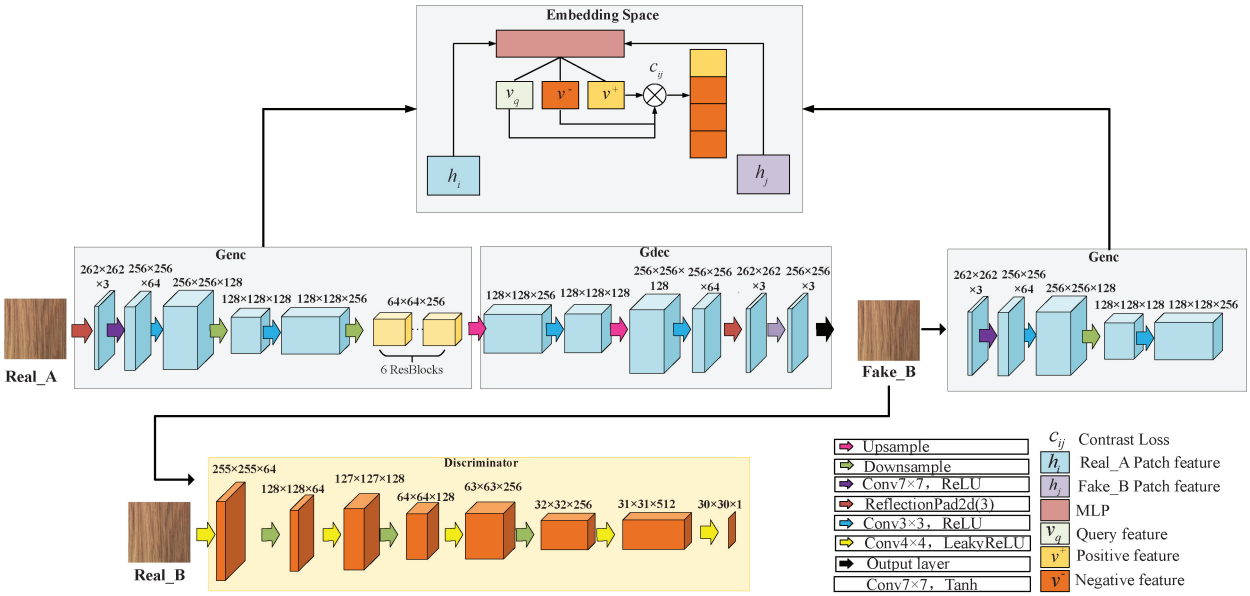

图 1　CLGAN 模型结构

Fig. 1　Model structure of CLGAN

深层高维特征提取;其次通过残差块网络延深编码器结构,提升编码器对特征向量的容纳能力,进一步加快网络收敛速度;然后利用 3 层反卷积解码器完成图像重构修复,最终输出与输入层尺寸大小相同的重构修复图像 Fake_B。

判别器的作用是通过感知重构图像和真实图像之间的差异,指导生成器进行对抗训练,有效区分重构图像或真实图像。本文设计判别器结构采用 PatchGAN 网络结构,与普通 GAN 判别器不同的是,PatchGAN 输出的是感知域,提升判别捕获输入与输出图像之间对应区域的差异性,如纹理、色彩、边缘信息等,进一步指导生成器的训练。PatchGAN 网络结构由 5 层卷积层构成,最终输出 30×30×1 的感知域,其结构如表 1 所示。

表 1　判别器结构

Table 1　Discriminator structure

网络层	类型	卷积核	输出维度
输入	-	-	256×256×3
Conv2D_1	Conv+BN+LeakyReLU	4×4	256×256×64
Conv2D_2	Conv+BN+LeakyReLU	4×4	127×127×128
Conv2D_3	Conv+BN+LeakyReLU	4×4	63×63×256
Conv2D_4	Conv+BN+LeakyReLU	4×4	31×31×512

为了使原始输入图像 Real_A 和重构修复图像 Fake_B 具有相似的内容和外观特征,同时保证输入图像的结构不变,对判别器 D 采用对抗损失,如式(1)所示:

$$L_{GAN}(G,D,X,Y) = E_{y\sim Y}\log D(y) + E_{x\sim X}\log(1 - D(G(x))) \quad (1)$$

式中:G 表示生成器,D 表示判别器,X 表示重构修复图像 Fake_B,Y 表示 Real_B,$E(*)$ 表示分布函数的期望值。

潜在特征空间对比学习框架由 4 层全连接层组成,其结构如表 2 所示。在 CLGAN 网络模型中复用编码器 G_{enc} 结构,首先,原图像 Real_A 和重构修复图像 Fake_B 经过结构相同的编码器 G_{enc} 后,得到的 Patch 特征向量分别被编码为 v^+、v^-、v_q,其中 v^+从输入图像 Real_A 中对应块生成,v^-从 Real_A 中非对应块生成,v_q 从重构修复图像 Fake_B 中随机生成,同时映射到 N 个 K 维的矢量矩阵中,其中 v_q、$v^+ \in R^K$,$v^- \in R^{N\times K}$。再经过 4 层 MLP 将特征向量投影到一个共享的嵌入潜在特征空间,然后对原图像和重构修复图像相对应的图像块特征向量求互信息,使编码器学会将对应的图像块之间相互联系起来,与不相关的图像块分离。最后学习到原图与重构修复图对应图像块之间的深层共性。

表 2　潜在特征结构

Table 2　Potential feature structure

网络层	类型	卷积核	输出维度
MLP_1	FC+ReLU	3×3	256
MLP_2	FC+ReLU	3×3	256
MLP_3	FC+ReLU	3×3	256
MLP_4	FC+ReLU	3×3	256

采用噪声对比估计框架,最大化 v_q 和 v^+的互信息,最小化 v_q 和 v^-的互信息,实现相同实例相似性最大化,不同实例相似性最小化。如式(2)所示:

$$L(v_q, v^+, v^-) = -\log\left[\frac{\exp(v_q \cdot v^+ / \tau)}{\exp(v_q \cdot v^+ / \tau) + \sum_{n=1}^{N}\exp(v_q \cdot v^- / \tau)}\right] \tag{2}$$

式中：τ 是控制点积灵敏度的超参数，取 0.07 使得训练的嵌入更加均匀分布。将 v_q 和 v^+ 的相似度标记为 1，将 v_q 和 v^- 的相似度标记为 0，最后对特征向量对求 Softmax 交叉熵损失。

特征向量对进行对比学习时，需要在潜在特征堆栈空间将重构图像 Fake_B 中的 Patch 和原图像 Real_A 对应的 Patch 相匹配，学会捕捉对应特征向量不变性，由 PatchNCE[18] 损失函数约束来实现，如式(3)所示：

$$L_{PatchNCE}(G, H, X) = E_{x\sim X}\sum_{l=1}^{L}\sum_{s=1}^{S_l}\ell(\hat{z}_l^s, z_l^s, z_l^{S/s}) \tag{3}$$

$$z_l = H_l(G_{enc}^l(x)) \tag{4}$$

$$\hat{z}_l = H_l(G_{enc}^l(\hat{y})) \tag{5}$$

式中：G_{enc}^l 表示生成器 G_{enc} 的第 l 层，$l \in \{1,2,\cdots,L\}$。H 表示全连接层 MLP，x 表示输入图像 Real_A，z_l 是 x 经过 MLP 后转化成的多个特征向量的集合，每个特征向量代表图像的一个小块(Patch)，x 经过生成器的重建图像 Fake_B 也经过相同的过程转化为多个特征向量。$\hat{y}$ 代表重构图像 Fake_B，$\hat{z}_l$ 是 $\hat{y}$ 经过 MLP 转化成的特征向量的集合，$s \in \{1,2,\cdots,L\}$，$l \in \{1,2,\cdots,L\}$，S_l 表示网络每层特征向量的最大数量。$\hat{z}_l^s$ 是在 $\hat{y}$ 网络第 l 层的第 S 个特征向量，z_l^s 表示 x 与 $\hat{y}$ 对应位置的特征向量，$z_l^{S/s}$ 表示其他位置的特征向量。

最终总损失函数 L_{total} 如式(6)所示，其中 $\lambda_x = 1$，$\lambda_y = 1$，通过模型训练使得该损失函数最小化，从而最大化对应图像块特征向量互信息。

$$L_{total} = \lambda_x L_{PatchNCE}(G, H, X) + \lambda_y L_{PatchNCE}(G, H, Y) + L_{GAN}(G, D, X, Y) \tag{6}$$

1.2　基于 CLGAN 模型的异常检测

训练完成后，CLGAN 模型即可用于工业品表面异常检测。检测阶段，将判别器和投影头丢弃，编码器的输出作为对比学习的特征表征，完成对异常图像的修复重构。其中，模型通过对比学习最大化编码异常图像与重构图像对应的 Patch 特征互信息，进一步提升模型的重构修复性能。同时为了克服后处理对色彩不敏感的局限，在定位异常时，直接对输入图像和重构图像进行残差计算，本文提出一种双阈值分割的后处理方法，采用三通道的自适应阈值分割算法保留色彩差异，提高检测精度，其流程如图 2 所示。

CLGAN 模型异常检测步骤如下：

步骤 1) 对待检测图像 I 输入训练完成的模型，得到重构修复图像 I_r；

步骤 2) 对待检测图像 I 和重构修复图像 I_r 进行高斯滤波并计算残差得到残差图像，然后通过高斯滤波平滑残差图像，得到图 2 中的 I_{D1}，如式(7)所示：

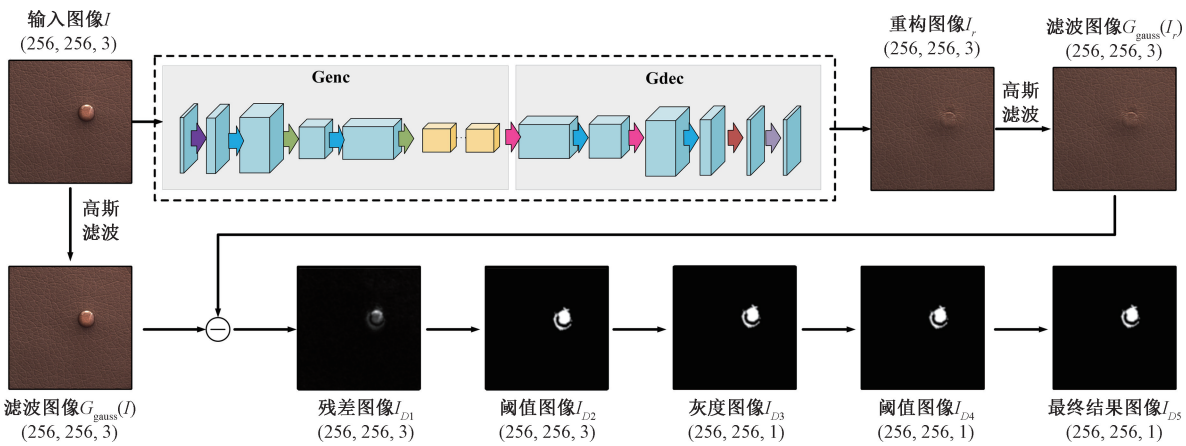

图 2　基于 CLGAN 模型的三通道自适应阈值异常检测过程

Fig. 2　Process diagram of three channel adaptive threshold anomaly detection based on CLGAN model

$$I_{D1} = G_{gauss}(G_{gauss}(I) - G_{gauss}(I_r)) \tag{7}$$

式中：I_{D1} 是经过高斯滤波后的残差图像，$G_{gauss}(I)$ 和 $G_{gauss}(I_r)$ 分别表示经过高斯滤波的输入图像和重构图像。

步骤 3) 对 I_{D1} 进行三通道的自适应阈值分割，消除图像中分布离散、数值较小的随机噪声，如式(8)所示：

$$P_{(x,y)}^c = \begin{cases} 0, P_{(x,y)}^c < T = \mu + k\sigma \\ 1, P_{(x,y)}^c \geqslant T = \mu + k\sigma \end{cases} \tag{8}$$

式中：$P_{(x,y)}^c$ 是图像 I_{D1} 在通道 c，像素 (x,y) 处的值，T 是自适应阈值 μ 和 σ 分别是图像 I_{D1} 在通道 c 的均值和标准差。k 是阈值分割的标准差系数，它代表不同的噪声敏感度和分割能力。在本文中，设置 k 为 3。三通道阈值

分割后的图像为图 2 的 I_{D2}。

步骤 4)使用图像灰度化加权平均法对图像 I_{D2} 进行灰度化处理,得到单通道灰度图像 I_{D3},加权平均法定义如式(9)所示:

$$I_{D3} = \omega_r \cdot I^r_{D2} + \omega_g \cdot I^g_{D2} + \omega_b \cdot I^b_{D2} \tag{9}$$

式中:I_{D3} 为灰度化后的图像,I^r_{D2},I^g_{D2} 和 I^b_{D2} 分别是图像 I_{D2} 对应的 3 个 RGB 颜色通道。ω_r,ω_g 和 ω_b 分别是 3 个通道的权重,根据人眼对绿色敏感最高,对蓝色敏感最低,一般设置 ω_r 为 0.299,ω_g 为 0.587,ω_b 为 0.114。

步骤 5)对 I_{D3} 进行单通道阈值分割,由于第 1 次阈值分割已经消除了大部分噪声,并且 I_{D3} 为单通道的灰度图像,所以第 2 次分割直接使用均值加标准差即可,参数 c 和 k 都为 1,阈值分割如式(8)所示。阈值分割后的图像为图 2 中的 I_{D4}。

步骤 6)为了保证检测区域的完整性,对二值图像 I_{D4} 进行先膨胀后腐蚀的闭运算操作,从而得到检测结果 I_{D5},如式(10)所示:

$$I_{D5} = (I_{D4} \oplus E) \ominus E \tag{10}$$

式中:E 为 3×3 的结构元素;⊕为膨胀操作,⊖为腐蚀操作。移动 E,若 E 与被操作图像存在重叠区域,则保留 E 内所有位置点;若 E 与被操作图像的交集完全属于被操作图像的区域,则保留该位置点。

2　实　验

2.1　实验数据集

本文选取的实验数据集为 MVTec AD 数据集,该数据集是一个全面的、包含多种物体、多种异常的工业品数据集,有 5 354 张不同领域中的 5 种纹理以及 15 种物体的高分辨率彩色图像,其中有 3 629 张正常图像用于模型训练和验证,1 725 张图像用于模型测试。所有图像的分辨率都是 700×700~1 024×1 024 的三通道彩色图像。本文使用该数据集的 bottle、carpet、grid、hazelnut、leather、metal_nut、tile、wood 8 种类别进行验证,部分样本如图 3 所示。

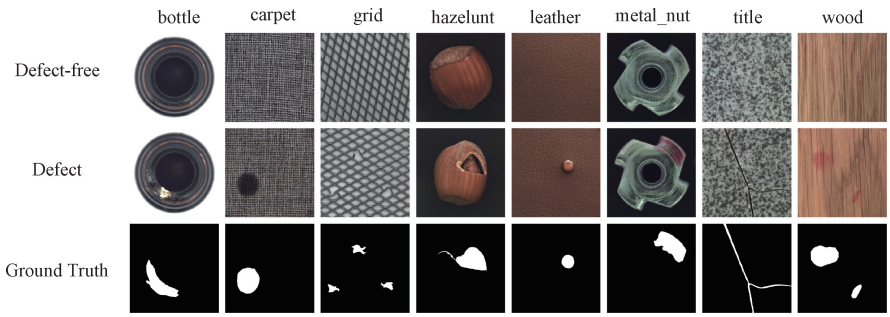

图 3　MVTec AD 数据集部分样本

Fig. 3　Partial samples of MVTec AD dataset

2.2　评价指标

经典的像素级别的指标例如准确率(P)、召回率(R)、分数($F1$)、平均交并比(IoU)和准确率(ACC)被用于评估提出的方法和比较方法。其中,P 和 R 之间存在反比关系,可以以减少一个为代价来增加另一个。因此,P 和 R 不被孤立讨论。分数 $F1$ 和 IoU 更被关注。这些像素级评价指标的定义如式(11)~(15)所示:

$$P = \frac{TP}{TP + FP} \times 100\% \tag{11}$$

$$R = \frac{TP}{TP + FN} \times 100\% \tag{12}$$

$$F1 = 2 \times \frac{P \times R}{P + R} \times 100\% \tag{13}$$

$$IoU = \frac{TP}{TP + FN + FP} \times 100\% \tag{14}$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \tag{15}$$

式中:TP 表示异常区域中被检测为异常的像素数;TN 表示正常区域中被检测为正常的像素数;FP 表示正常区域中被检测为异常的像素数;FN 表示异常区域中被检测为正常的像素数。

2.3　实验结果与分析

为了验证本文提出的无监督异常检测模型 CLGAN 对于工业品表面异常的检测性能,将其与 VAE-SSIM[14]、UDCAE[15]、DCGAN[19]3 种无监督异常检测模型进行定量和定性比较。

1)CLGAN 重构结果分析

在测试阶段,CLGAN 将输入的有异常图像重构为无异常图像。模型的重构能力是影响最终检测结果的重要因素,该能力主要体现在模型对图像异常区域的修复能力和对无异常区域图案细节的保留能力。图 4 为 VAE-SSIM、UDCAE、DCGAN、CLGAN 4 种检测模型在 hazelunt、leather、wood 3 种工业品图像的重构效果,第 1 列是未被

重构的异常图像,后 4 列为 4 种模型对这些异常图像的重构结果。从图中可以看出,VAE-SSIM 完全无法正确重构出 leather 工业品,且对其他物品表面纹理的重构效果也不好。UDCAE 重构出的 hazelunt 工业品外形十分模糊,对异常部分进行了保留,且在 leather 工业品的重构图中存在大面积阴影。DCGAN 的重构图有明显的拼接痕迹,且完全无法重构出 hazelunt 工业品外形。本文提出的 CLGAN 模型能够较好地保留非异常区域的纹理,正确重构出工业品外观地同时去除异常区域。

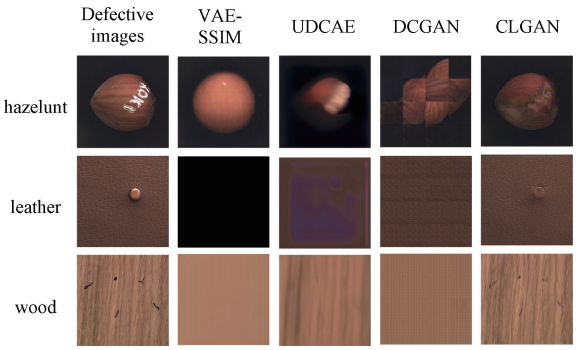

图 4　4 种检测模型对部分异常图像的重构效果

Fig. 4　Reconstruction images of four detection models on partial abnormal images

2)异常检测结果定性分析

图 5 为 UDCAE、VAE-SSIM、DCGAN、CLGAN 4 种模型在 MVTec AD 数据集中 8 种工业品异常检测性能的部分检测结果。图中第 1 行为原始异常图像,第 2 行为异常图像的真值图,第 3 行~第 6 行分别为 UDCAE、VAE-SSIM、DCGAN、CLGAN 模型的部分异常检测结果。UDCAE 模型完全无法检测出 carpet 和 title 的表面异常,对 bottle 的异常存在明显的过检现象,且对 hazelunt 和 metal_nut 的异常存在漏检现象。VAE-SSIM 模型完全无法检测出 carpet、grid、metal_nut 和 title 的表面异常,对 bottle 的异常存在漏检现象。DCGAN 模型的检测结果存在大量噪声,对 carpet、hazelunt 和 leather 的异常能够基本检测。CLGAN 模型能够检测出所有异常并进行准确定位,且结果与真值图相似度最高。实验结果表明,本文提出的 CLGAN 模型对工业品表面异常检测效果明显优于 UDCAE、VAE-SSIM、DCGAN 模型。

3)异常检测结果定量分析

表 3 为 UDCAE、DCGAN、VAE-SSIM、CLGAN 这 4 种模型在 MVTec AD 数据集中 8 种工业品异常检测性能的定量结果,表中最后一列为平均值。分析表 3 可得,对表 3 中的数据进行分析可得,CLGAN 的 P、R、ACC、$F1$、

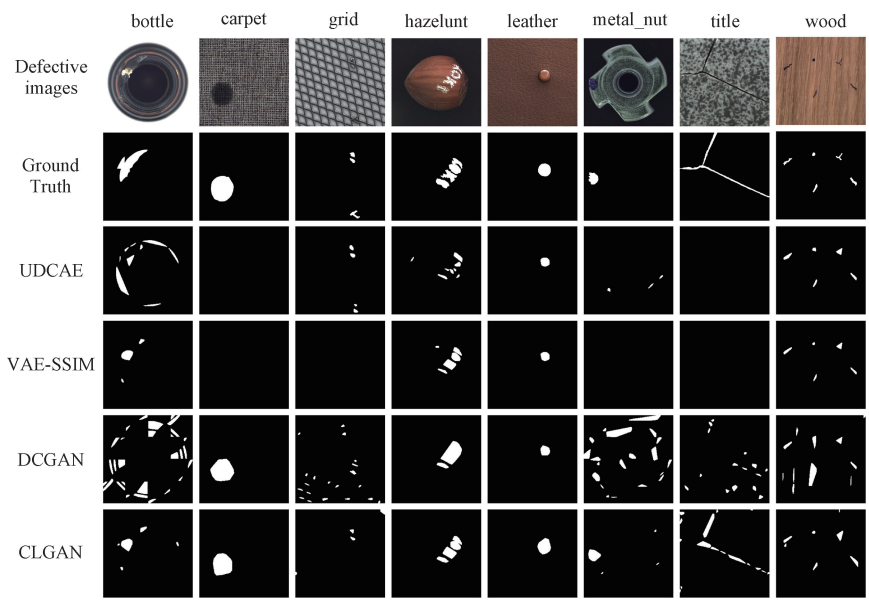

图 5　4 种检测模型对部分异常图像的检测结果

Fig. 5　Result of four detection models on partial abnormal images

IoU 5 种指标均比其他 3 种模型要高,在 MVTec AD 上实现了 $F1$ 和 IoU 分别为 32.03%和 21.77%,并且在 5 种工业品上取得了最好的检测性能。表明对比学习能够加强潜在特征空间正负例样本约束,最大化输入输出图像对应 Patch 之间的互信息,增强正负样本特征向量区分度,使模型重构异常样本图像的能力得到有效提升。

4)阈值分割系数实验

在异常检测阶段,阈值分割系数被用于调节噪声敏感度和分割能力。为了获得最优的分割阈值,选取 3 种工业品 hazelunt、leather、matal_nut,在 2~3 范围内以 0.1

为步长的不同阈值用于后处理中,得到异常检测结果,如表 4 所示。从表中最后一列值可以得出当阈值系数为 3.0 时,*F*1 和 *IoU* 达到最大,此时 CLGAN 模型的异常检测效果最好。实验结果表明本文所提出的双阈值分割后处理方法中使用的阈值是最优阈值。

表 3　4 种模型在 MVTec AD 数据集中 8 种工业品表面异常的定量检测结果

Table 3　Quantitative detection results of eight industrial products surface anomalies using four models in the MVTec AD dataset　(%)

指标	模型	瓶子	地毯	网格	榛子	皮革	螺母	瓷砖	木材	平均值
P	UDCAE	32.53	22.22	**69.52**	39.90	29.22	0.35	7.74	43.29	30.60
	DCGAN	17.89	**43.12**	3.58	30.24	10.71	3.30	25.28	2.64	17.10
	VAE-SSIM	42.00	0	0	**49.91**	28.39	1.08	18.28	34.77	21.80
	CLGAN	**61.88**	41.35	30.56	40.22	**28.92**	**42.14**	**46.95**	**37.64**	**41.21**
R	UDCAE	16.26	8.34	**30.51**	39.11	18.28	1.23	0.99	23.80	17.32
	DCGAN	11.46	**39.87**	5.48	57.93	19.36	16.81	23.14	5.94	22.50
	VAE-SSIM	**28.71**	0	0	**57.32**	14.55	0.76	1.44	19.41	15.27
	CLGAN	26.82	18.36	24.11	37.40	52.66	**42.12**	**24.42**	**28.32**	**31.78**
ACC	UDCAE	90.71	98.34	**99.16**	98.00	99.00	97.40	0.96	96.67	85.03
	DCGAN	80.80	**98.71**	96.95	95.67	97.78	91.66	**96.72**	93.54	93.98
	VAE-SSIM	90.47	98.30	98.95	**99.00**	98.67	97.79	93.59	**96.67**	96.68
	CLGAN	**92.67**	98.47	98.70	97.68	**99.74**	**97.32**	94.12	96.38	**96.89**
*F*1	UDCAE	17.35	11.25	**39.11**	35.59	20.63	0.52	1.65	26.90	19.13
	DCGAN	13.26	**40.05**	4.06	38.02	10.72	5.5	23.29	3.21	17.26
	VAE-SSIM	28.35	0	0	**50.73**	18.25	0.75	2.50	21.98	15.32
	CLGAN	**33.01**	22.51	25.27	43.26	**33.79**	**42.12**	**26.19**	**30.11**	**32.03**
IoU	UDCAE	9.76	7.54	**27.76**	25.22	13.84	0.26	0.98	18.50	12.98
	DCGAN	7.31	**30.81**	2.96	27.67	6.81	2.84	13.66	1.83	11.74
	VAE-SSIM	17.81	0	2.17	**40.11**	12.34	0.39	1.44	15.44	11.21
	CLGAN	**21.21**	16.31	15.52	30.28	**23.53**	**30.22**	**16.53**	**20.54**	**21.77**

表 4　不同分割阈值系数实验结果

Table 4　Experimental results of different segmentation threshold　(%)

指标	种类	2.0	2.1	2.2	2.3	2.4	2.5	2.6	2.7	2.8	2.9	3.0
*F*1	榛子	33.83	35.80	36.29	37.44	37.94	38.67	39.50	40.15	41.40	42.12	**43.40**
	皮革	22.29	23.14	24.53	25.51	26.75	28.55	29.29	30.12	31.42	32.35	**33.15**
	螺母	33.84	34.83	35.90	37.32	37.79	38.78	39.15	39.79	39.99	40.48	**40.63**
IoU	榛子	23.85	25.44	25.88	26.92	27.35	27.99	28.63	29.15	30.17	30.21	**31.74**
	皮革	15.59	16.17	17.09	17.78	18.71	20.04	20.63	21.29	22.47	23.24	**23.70**
	螺母	22.78	23.71	24.76	26.16	26.77	27.81	28.24	29.05	29.39	30.01	**30.21**

3　结　论

针对工业产品表面异常种类的不规则性和未知性,有监督深度学习异常检测算法难以获得充足的标注样本供模型训练,本文提出一种基于对比学习生成对抗网络的无监督工业品表面异常检测算法。通过采用对比学习加强潜在特征空间正负例样本约束,最大化输入输出图像对应 Patch 之间的互信息,增强正负样本特征向量区分度,从而提升对有异常样本图像的重构能力。在异常检测阶段,结合双阈值分割的后处理方法和数学形态学处理,来获得最终的异常检测结果,其中,阈值分割系数被用于调节噪声敏感度和分割能力,当阈值系数为 3.0 时,*F*1 和 *IoU* 达到最大,此时 CLGAN 模型的异常检测效果最好。实验结果表明,本文所提算法与其他的无监督深度学习异常检测算法相比,具有更好的识别效果;与有监督异常检测算法相比,在具有大量异常样本或缺少异常样本的生产场景下均能检测出异常,具有更强的泛化能力。本文提出的基于对比学习生成对抗网络的无监督工业品表面异常检测算法,由于只采用卷积结构,而忽略了对图像全局信息的学习。在今后的研究中将会引入 transformer 架构,增强模型捕捉图像全局结构和上下文信息的能力,进一步提高模型的检测精度和泛化能力,使该算法能够更好地运用到工业生产现场,有效降低工人工作量和产品生产成本。

参考文献

[1] 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.

[2] 葛路,何仕荣. 深度学习在工业表面缺陷检测领域的应用研究[J]. 计算技术与自动化, 2022, 41(1):59-65.
GE L, HE SH R. Research on application of deep learning in field of industrial surface defects detection[J]. Computer Technology and Automation, 2022, 41(1):59-65.

[3] LIU K, WANG H, CHEN H Y, et al. Steel surface defect detection using a new haar-weibull-variance model in unsupervised manner[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(10):2585-2596.

[4] 王冬云, 唐楚, 鄂世举,等. 基于导向滤波 Retinex 和自适应 Canny 的图像边缘检测[J]. 光学 精密工程, 2021, 29(2):443-451.
WANG D Y, TANG CH, E SH J, et al. Image edge detection based on guided filter Retinex and adaptive Canny[J]. Optics and Precision Engineering, 2021, 29(2):443-451.

[5] KRIZHEVSKY A, SUTSKEVER I, GEOFFREY H. ImageNet classification with deep convolutional neural networks[J]. Communication of the ACM, 2017, 60(60):84-90.

[6] 周飞燕,金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6):1229-1251.
ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6):1229-1251.

[7] 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 Informationis, 2022, 52(6):1002-1039.

[8] 张顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用[J]. 计算机学报, 2019, 42(3):453-482.
ZHANG SH, GONG Y H, WANG J J. The development of deep convolution neural network and its application on computer vision[J]. Chinese Journal of Computers, 2019, 42(3):453-482.

[9] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述. 自动化学报, 2021, 47(5):1017-1034.
TAO X, HOU W, XU D. A survey of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5):1017-1034.

[10] 李良福, 马卫飞, 李丽,等. 基于深度学习的桥梁裂缝检测算法研究[J]. 自动化学报, 2019, 45(9):1727-1742.
LI L F, MA W F, LI L, et al. Research on detection algorithm for bridge cracks based on deep learning[J]. Automatica Sinica, 2019, 45(9):1727-1742.

[11] 张宏伟,糜红敏,陆帅,等. 基于生成对抗网络的色织物缺陷检测[J]. 西安工程大学学报, 2022, 36(1):1-9.
ZHANG H W, MI H M, LU SH, et al. Defect detection of yarn-dyed fabric based on generative adversarial networks[J]. Journal of Xi′an Polytechnic University, 2022, 36(1):1-9.

[12] SCHLEGL T, SEEBOCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[C]. Proceedings of the International Conference on Information Processing in Medical Imaging. Boone: Springer, 2017:146-157.

[13] DEECKE L, VANDERMEULEN R, RUFF L, et al. Image anomaly detection with generative adversarial networks[C]. Proceedings of European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases. Dublin: Springer, 2018:3-17.

[14] WEI W, DENG D, ZENG L, et al. Real-time implementation of fabric defect detection based on variational automatic encoder with structure similarity[J]. Journal of Real-Time Image Processing, 2021, 18(3):807-823.

[15] 张宏伟, 谭全露, 陆帅,等. U 型去噪卷积自编码器色织衬衫裁片缺陷检测[J]. 西安电子科技大学学报, 2021, 48(3):123-130.
ZHANG H W, TAN Q L, LU SH, et al. Yarn-dyed shirt piece defect detection based on an unsupervised reconstruction model of the U-shaped denoising convolutional auto-encoder[J]. Journal of Xidian University, 2021, 48(3):123-130.

[16] 周新龙, 张宏伟, 吴燕子,等. 基于 ContrastGAN 的色织物缺陷检测[J]. 棉纺织技术, 2022, 50(11):1-7.
ZHOU X L, ZHANG H W, WU Y Z, et al. Defect detection of yarn-dyed fabric based on ContrastGAN[J]. Cotton Textile Technology, 2022, 50(11):1-7.

[17] LI G B, YU Y. Deep contrast learning for salient object detection[C]. IEEE Conference on Computer Vision and

Pattern Recognition. Las Vegas: IEEE, 2016:478-487.
[18] PARK T, EFROS A, ZHANG R, et al. Contrastive learning for unpaired image-to-image translation [C]. European Conference On Computer Vision. Glasgow: Springer, 2020:319-345.
[19] HU G, HUANG J, WANG Q, et al. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network[J]. Textile Research Journal, 2020, 90(3):247-270.

作者简介

张玥,2013 年于重庆科技学院获得学士学位,2016 年于西北工业大学获得硕士学位,现为西安工程大学工程师,主要研究方向为机器视觉、图像处理。
E-mail: zhangyue@xpu.edu.cn

Zhang Yue received her B. Sc. degree from Chongqing University of Science and Technology in 2013, M. Sc. degree from Northwestern Polytechnical University in 2016. Now she is an engineer of Xi′an Polytechnic University. Her main research interests include machine vision and image processing.

陈锡伟,分别在 2020 年和 2023 年于西安工程大学获得学士学位和硕士学位,主要研究方向为机器视觉、图像处理。
E-mail: 18956019342@163.com

Chen Xiwei received his B. Sc. and M. Sc. degrees both from Xi′an Polytechnic University in 2020 and 2023. His main research interests include machine vision and image processing.

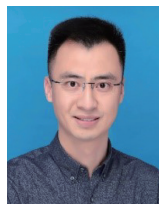

张宏伟(通信作者),分别在 2006 年和 2009 年于西安工程大学获得学士学位和硕士学位,2013 年于浙江大学获得博士学位,现为西安工程大学副教授,主要研究方向为人工智能、机器视觉、图像处理与模式识别。
E-mail: zhanghongwei@zju.edu.cn

Zhang Hongwei received his B. Sc. and M. Sc. degrees both from Xi′an Polytechnic University in 2006 and 2009, and Ph. D. degree from Zhejiang University in 2013. Now he is an associate professor of Xi′an Polytechnic University. His main research interests include artificial intelligence, machine vision, image processing and pattern recognition.