

DOI:10.19651/j.cnki.emt.2211920

自监督瓷砖表面异常检测与定位^{*}

王飞州¹ 程凡永¹ 张明艳² 张红²

(1. 安徽工程大学电气工程学院 芜湖 241000; 2. 安徽工程大学 芜湖 241000)

摘要: 针对瓷砖表面异常检测中人工检测效率低、成本高和自动检测标记样本不足、漏检率高等问题,提出了一种自监督学习模型,无需大量缺陷样本,即可实现瓷砖表面常见异常的检测与定位。自监督学习通过样本扩充产生负样本,利用分布增强对比学习提高数据不规则性和扩展样本分布,进而降低对比表示的均匀性,使表示特征分布与分类目标保持一致。在自监督学习表示基础上,构建一类分类器实现了准确的异常检测与定位。实验结果表明,在异常检测标准评估度量(AUROC)准则下,该方法相比其他两种先进方法异常检测率分别提高了3.71%和2.74%;异常定位率分别提高了1.22%和4.01%,且具有更可靠的检测性能。

关键词: 自监督;瓷砖;分布增强对比学习;异常检测

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 510.40

Self-supervised learning for anomaly detection and location of ceramic tile surface

Wang Feizhou¹ Cheng Fanyong¹ Zhang Mingyan² Zhang Hong²

(1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China;

2. Anhui Polytechnic University, Wuhu 241000, China)

Abstract: Aiming at the problems of low efficiency, high cost, insufficient automatic detection label samples and high missed detection rate in the surface defect detection of ceramic tiles, a self-supervised learning model is proposed, without a large number of defect samples, the detection and location of common defects on the surface of ceramic tiles can be realized. Self-supervised learning generates negative samples through sample expansion, and uses distribution-augmented contrastive learning to improve data irregularity and expand sample distribution, thereby reducing the consistency of comparative representation and making the representation feature distribution consistent with the classification target. Based on self-supervised learning representation, a class of classifiers is constructed to achieve accurate anomaly detection and localization. The experimental results show that compared with the other two advanced methods, under the standard evaluation criterion (AUROC) of anomaly detection, the anomaly detection rate is increased by 3.71% and 2.74% respectively; the abnormal location rate increased by 1.22% and 4.01% respectively, with more reliable detection performance.

Keywords: self-supervised;ceramic tile;distributed-augmented contrast learning;anomaly detection

0 引言

广东佛山是国内最大的瓷砖生产制造基地,瓷砖生产线基本实现了无人化,但是在瓷砖质量检测方面仍然需要大量人工投入。一条普通生产流水线上需要安排3~7名娴熟的质检员,在粉尘含量高和高光照下挑选出表面异常的瓷砖^[1]。这种人工检测方法,一方面无法保证产品的检

测一致性和稳定性,导致产品质量参差不齐,同一批次产品抽检的不确定性大;另一方面受环境影响较大、检测速度慢,影响生产效率。自动异常检测与定位技术,不仅可以获取图像中存在的缺陷类型,而且能够标明缺陷的区域大小和具体位置,这些信息能够辅助产品实现质量评估,例如优劣等级的判断。

目前,机器视觉被广泛应用于自动瓷砖表面异常检

收稿日期:2022-11-02

* 基金项目:国家自然科学基金(61976005)、安徽工程大学-鸠江区协同创新专项基金(2022cyxtb10)、芜湖市重点研发项目(2022yf42)、检测技术与节能装置安徽省重点实验室开放研究基金(JCKJ2021B06)、安徽省教育厅重点项目(2022AH050981)资助

测^[2]。张军等^[3]提出了一种复合纹理瓷砖表面缺陷检测方法,利用颜色空间分布的方差特征和色斑面积权重特征对瓷砖表面缺陷进行检测,实现了对瓷砖的破损、裂纹、斑点和划痕缺陷种类的检测任务,但是随着瓷砖表面颜色和纹理类型的增加,检测效果会降低。权小霞等^[4]提出了一种基于局部方差加权信息熵的瓷砖表面缺陷检测算法,该算法的瓷砖缺陷检测识别率达到 93%,解决了因瓷砖表面背景复杂导致的误检率问题,但是对微型斑点等缺陷识别度不高。李军华等^[5]提出了一种多特征融合检测算法对瓷砖表面进行缺陷检测,该方法使用颜色矩融合特征和改进的尺度不变特征转换,表示瓷砖局部图像的综合特征,然后把该特征通过支持向量机分类器完成缺陷分类,对复杂线性和点状纹理缺陷瓷砖具有较好分类检测效果,但是在高曝光率条件下,检测准确度较差。王淑青等^[6]提出了一种基于 YOLOv5(you only look once v5)生产线瓷砖表面缺陷检测算法,其平均检测精度高达 96%,但模型泛化性能较弱,无法有效识别无标签类型缺陷。以上这些算法虽然能够较好地检测瓷砖表面区域缺陷,但是只能针对特定类型缺陷进行检测,存在一定局限性,在缺陷样本少和不规则的工业过程中检测精度差。

本文针对以上问题,提出了一种自监督瓷砖表面异常

检测和定位模型,首先通过代理任务构造负样本,解决工业缺陷样本少的问题;然后利用分布增强对比学习(distribution-augmented contrastive learning, DA)扩展样本分布,提高样本的不规则性,降低表征学习均匀性和冲突性,进而提升异常检测准确率,并使用异常得分分布实现缺陷定位;最后,结合产品生产指标,筛选出高品质瓷砖。

1 自监督异常检测与定位

1.1 自监督学习

本文设计了两阶段框架实现自监督异常检测与定位,如图 1 所示,首先自监督学习表示,然后对学习到的表示构建分类器用于异常检测与定位。在自监督学习表示阶段,如图 1(a)所示,训练卷积神经网络(convolutional neural networks, CNN)把正常样本(蓝色)和增强样本(黄色)区分开,对整个图像或局部区域进行表征学习,其中增强样本是从正常样本中切割出一个矩形条(红色虚线框)并将其粘贴到随机位置;在异常检测与定位阶段,如图 1(b)所示,图像整体决策利用梯度加权类激活^[7](gradient-weighted class activation mapping, Grad-CAM)输出可视化定位缺陷图;补丁决策利用补丁提取密集图像特征生成异常分数,通过高斯平滑和上采样进行定位^[8],生成可视化热图。

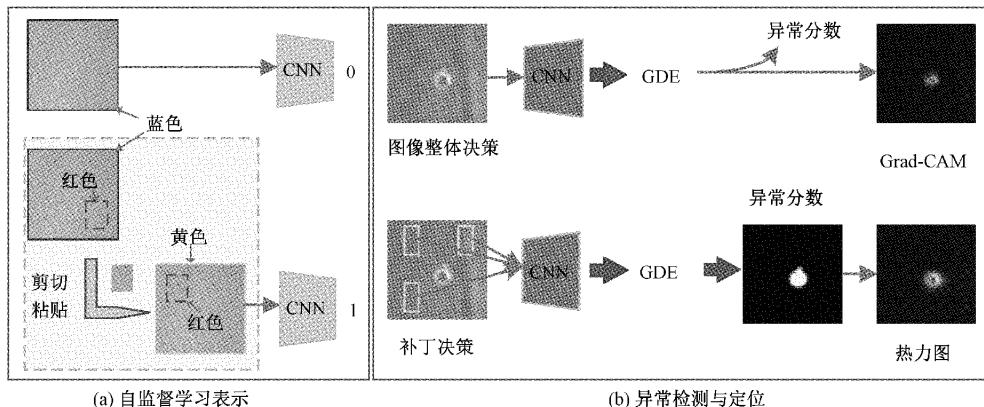


图 1 异常检测与定位的框架图

图 1(a)的“剪切粘贴”操作是自监督数据增强,其训练目标公式为:

$$L_{CP} = E_{x \in X} \{CE(g(x), 0) + CE(g(CP(x)), 1)\} \quad (1)$$

式中: X 是正常无缺陷数据集, $CP(\cdot)$ 是自监督增强, $CE(\cdot, \cdot)$ 是交叉熵损失, g 是二进制分类器。在 x 输入 g 或者 CP 之前实现数据增强,例如平移。

由于瓷砖表面的异常大小不一,且分布不规则,通过代理任务增强过的图像仍缺乏不规则性,导致表示学习差。为了提高图像的不规则性,Cutpaste^[9]通过在正常图像上切割出不同纵横比的矩形条,修改其像素值,并粘贴到随机位置,但是有可能将背景区域矩形条再次粘贴到背景上,产生将背景区域识别为异常的错误检测。为避免该

错误检测损害表征学习,本文使用分布增强对比学习扩充样本分布,增加图像的不规则性和实例数量。

1.2 分布增强对比学习

对比学习^[10]通过区分自身与其他数据实例的不同视图来学习特征,其损失公式为:

$$L_{clr} = -E_{x, x_i \sim P_X, A, A'} \left[\log \frac{\exp(\Psi)}{\exp(\Psi) + \sum_{i=1}^{M-1} \exp(T)} \right] \quad (2)$$

式中: $\Psi = \frac{1}{\tau} \phi(A(x))^T \phi(A'(x))$, A 和 A' 是相对于 x 的两个不同视图来自一个独立同分布的随机增强过程, $T = \frac{1}{\tau} \phi(A(x))^T \phi(A(x_i))$, L_{clr} 将使同一实例 x 具有不同视

图表示 $(A(x), A'(x))$ 为相似, 而不同实例 x, x' 的视图表示 $(A(x), A'(x'))$ 差异大。

但是对比学习对一类分类是存在两方面问题的: 第 1 个问题是类冲突^[11]。式(2)中的对比损失最小化, 需要最大化负样本对 (x, x_i) 表示的距离 ($x \neq x_i$), 应用于一类分类^[12]时, 只有正常样本参与训练, 对比学习会使同一个类别的样本的

表示距离尽可能远, 这与一类分类要求同一类样本的表示距离最小产生冲突; 第 2 个问题是表示的均匀性^[13]。式(2)的最优解是 M (批量数)趋近无穷具有完全均匀性, 即 $\phi(x)$ 服从均匀分布, 如图 2(a)所示。但是异常数据与邻近的正常数据间距小, 难以区分。相比之下, 当均匀性降低时, 更容易把离群值从正常数据分离开来, 如图 2(b)所示。

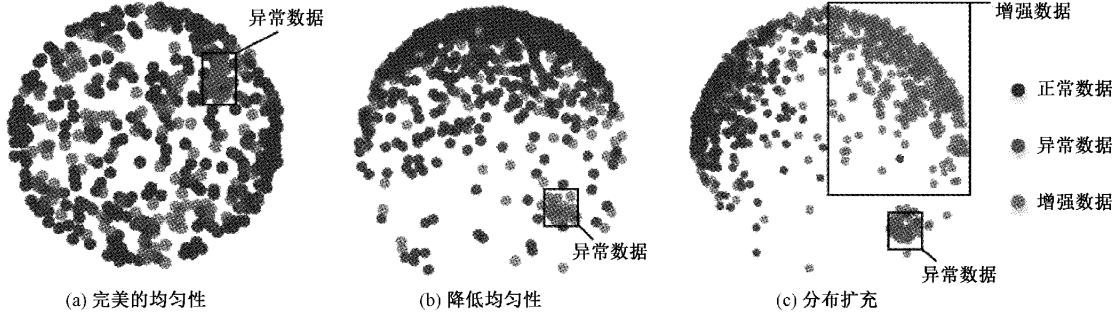


图 2 不同内部均匀度的一类分布

综合来说, 表示的均匀性对异常检测的影响包括 3 种情况: 第 1 种是当表示完全均匀时, 分离离群值是很困难的; 第 2 种是当均匀性降低时, 正常数据与离群值之间的界限变得清晰; 第 3 种是当数据分布扩充时, 内部分布更加紧凑。因此均匀性指标降低, 有利于拉近正样本、推开负样本, 保留最高的分布信息熵, 从而提高异常检测的准

确率。

自监督学习方法由深度神经网络参数化的特征提取器 f 和代理损失组成, f 可以在训练时选择使用投射头 g 计算代理损失^[14], 如图 3 所示。该自监督表示学习网络结构为 $g \circ f(x)$, 其中 g 是用于计算代理损失的投射头, f 是用于下游任务的输出表示, 使用其构建一类分类器。

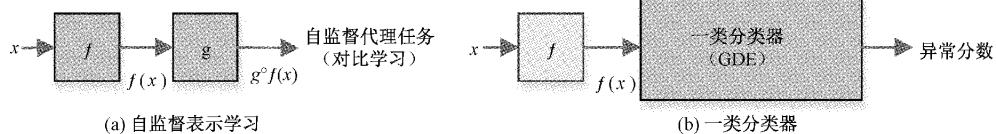


图 3 一类分类器的两阶段框架

为了降低均匀分布程度, 本文使用分布增强用于一类对比学习, 利用几何变换的方式(例如水平翻转和旋转)来增强分布^[15], 主要通过把式(2)中建模训练数据分布 P_χ , 改为建模增强训练分布 $P_{\cup_a} a(\chi)$, 其中 $a(\chi) = \{a(x) | x \in \chi\}$, 用于增强分布的增强 a 与用于生成视图的数据增强 a 是不相交的。如图 4 所示, W 部分和 W_1 部分(旋转 90°的 W 部分)被视作两个独立的实例, 在表示空间上保持距离, 不仅增加了要训练的数据实例的数量(通过旋转 90°, 180°, 270°增加了 4 倍的数据集), 而且降低了超球面表示的均匀性。如图 2(c)所示, 由于数据增强使内部分布变得更加紧凑, 把不同样本的表示从超球面上推远, 相同样本的表示拉近, 从而降低类冲突和表示均匀性。此外分布增强对比学习, 不仅能学习区分原始分布中的不同实例(W 部分和 B 部分), 还能学习区分增强的不同分布实例(例如旋转, 同一瓷砖具有不同旋转度的两幅图像)。

综合来说, 标准对比学习训练投射头 $g \circ f$ 的表示, 更加接近均匀分布, 而 DA 的投射头 $g \circ f$, 学习到的表示分布不均匀, 使得分离异常值的性能显著增强, 可以减少分类器对同一类示例的冲突性和均匀性。

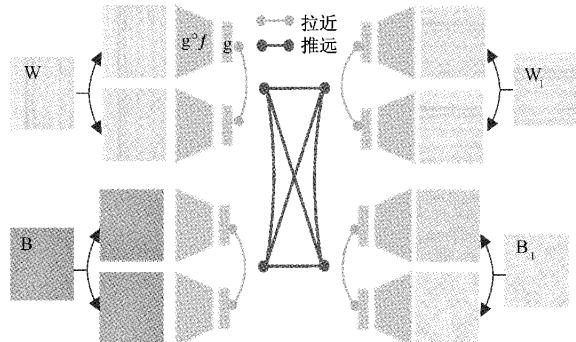


图 4 分布增强对比学习

t 分布随机邻居嵌入(t -distributed stochastic neighbor embedding, t-SNE)是一种非线性降维算法^[16], 在数据从高维转向低维过程中会保持所携带的分布特征, 对于较大(较低)相似度的点, t 分布在低维空间中的距离更近(远), 也就是会把原本高维空间上距离近的点聚集在一起。为了验证自监督模型生成的增强样本具有很强的不规则性, 对网络提取的高维数据进行降维可视化, 得到不同样本的密度分布, 如图 5 所示。

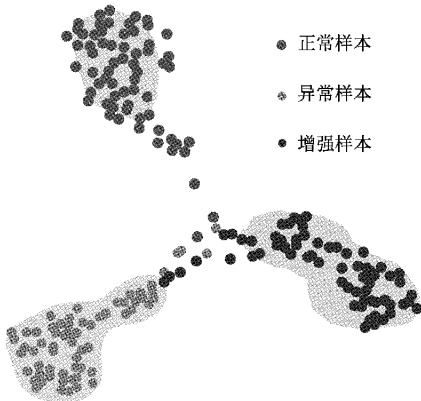


图 5 表征学习 t-SNE 图

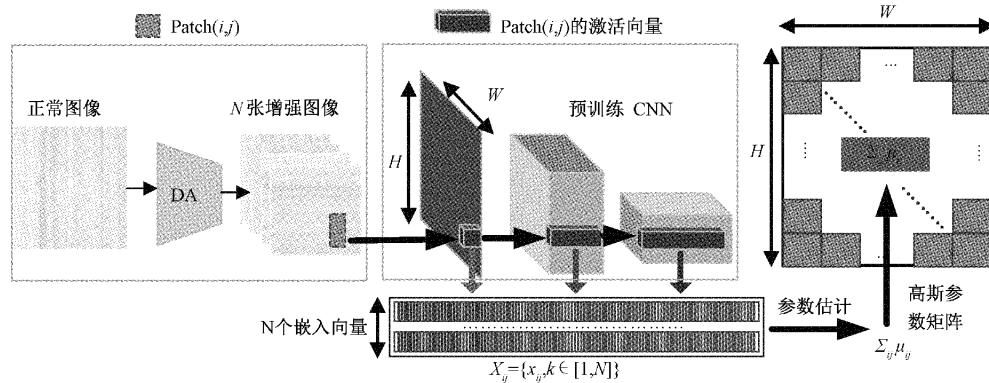


图 6 Patch 分布建模

格可以划分输入图像,其中 $W \times H$ 是用于生成嵌入的最大激活映射的分辨率,最后网格中每个 Patch 的位置 (i, j) 会与计算的嵌入向量 x_{ij} 相关联。

为了学习位置 (i, j) 处的图像特征,从分布增强对比学习后生成的 N 张增强图像中,计算出 (i, j) 处的 Patch 嵌入向量集合,即 $X_{ij} = \{x_{ij}^k, k \in [1, N]\}$ 。在图 6 中,为了归纳该集合携带的信息,本文假设 X_{ij} 是由一个多元高斯分布簇 $\mathcal{N}(\mu_{ij}, \Sigma_{ij})$ 产生,其中 μ_{ij} 为 X_{ij} 的样本均值,则样本协方差 Σ_{ij} 的估计如下:

$$\Sigma_{ij} = \frac{1}{N-1} \sum_{k=1}^N (X_{ij}^k - \mu_{ij})(X_{ij}^k - \mu_{ij})^T + \epsilon I \quad (3)$$

式中: 正则化项 ϵI 使样本协方差矩阵 Σ_{ij} 满秩且可逆。最后,使用高斯参数矩阵把具有可能的 Patch 位置与如图 6 中的多元高斯分布相关联。

由于多元高斯分布 $\mathcal{N}(\mu_{ij}, \Sigma_{ij})$ 能从不同语义层次上捕获信息, Σ_{ij} 则包含了层次间的相关性,有助于提高异常定位性能。

1.4 异常检测得分计算

一类分类器计算异常分数值方法很多,例如高斯密度估计(gaussian density estimate, GDE)^[18]或者核密度估计器(kernel density estimation, KDE)^[19]。但是考虑到 KDE 是用于未知的密度函数,不会因分布假设的变化而变化,需要很多的训练实例进行准确估计,从而会产生很高的计

不同样本的密度分布相互独立,表明网络学习到的表征能够有效的区分开异常样本、增强样本和正常样本,其中增强样本与异常样本之间有相交部分,表明网络可以对原始缺陷特征进行加强,学习增强样本与其他样本的不相交区域,可以更好的发现不规则性,模拟瓷砖表面罕见的异常。

1.3 融合分布增强对比学习的表示学习

在训练阶段,如图 6 所示,将增强样本的每个 Patch 与预训练的 CNN 激活图中其空间对应的激活向量相关联^[17],由于输入图像的分辨率高于激活图,导致很多像素会具有相同的嵌入向量,然后形成与原始图像分辨率没有重叠的像素块。因此 $(i, j) \in [1, W] \times [1, H]$ 位置的网

算成本。所以本文采用 GDE 计算测试图像 Patch 处嵌入向量的异常情况,其对数密度函数如下:

$$\log p_{gde}(x) \propto \left\{ -\frac{1}{2}(f(x) - \mu)^T \Sigma^{-1} (f(x) - \mu) \right\} \quad (4)$$

式中: μ 和 Σ 从正常训练数据中学习得到的。

1.5 异常定位得分计算

在图像可视化定位中,使用图像和补丁决策得到异常得分热图。

本文在图像决策定位中,将每个特征映射乘以其权重执行求和,生成 Grad-CAM 得分结果图;补丁决策定位中,在测试瓷砖图片 (i, j) 位置的 Patch 使用马氏距离 $M(x_{ij})$ 计算出异常评分值,其中 $M(x_{ij})$ 是测试 Patch 嵌入 x_{ij} 和学习分布 $\mathcal{N}(\mu_{ij}, \Sigma_{ij})$ 之间的距离, $M(x_{ij})$ 的计算公式如下:

$$M(x_{ij}) = \sqrt{(x_{ij} - \mu_{ij})^T \Sigma_{ij}^{-1} (x_{ij} - \mu_{ij})} \quad (5)$$

$$M = \max_{i,j} (M(x_{ij})) \quad 1 < i < W \quad 1 < j < H \quad (6)$$

式中: M 是异常图的马氏距离矩阵,最大值是最终图像的异常得分。

2 实验结果与分析

2.1 实验配置及数据获取

在实际表面缺陷检测实验中,具体实验环境和参数配

置如表 1 所示。

表 1 实验环境和参数配置

名称	配置信息
操作平台	Windows10
语言	Python, Pytorch
GPU	GeForce RTX 3090
CPU	Inter core i7-10700
加速环境	CUDNN8.3.3, CUDA11.5
学习速率	0.03%
Patch 的最大值	0.15
Patch 的最小值	0.02
投射头深度	8
批量次数	4

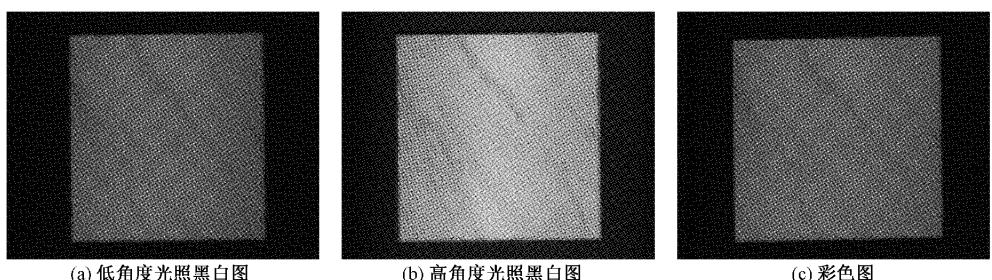


图 7 CCD 专业相机拍摄图片

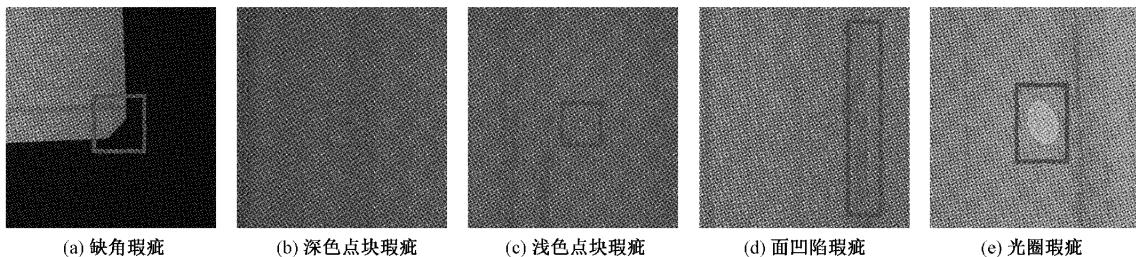


图 8 瓷砖缺陷类型

2.2 自监督网络训练与评估指标

本文训练模型采用的交叉熵损失函数,如式(7)所示。

$$Loss_fn = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i -[y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)] \quad (7)$$

式中: p_i 表示预测样本 i 是正类的概率; y_i 表示样本的标签,正类标注为 1,负类标注为 0。

训练好的网络模型对瓷砖测试集进行测试验证,分别计算得到召回率(Recall),查准率(Precision)的值,如式(8)所示。

$$\left\{ \begin{array}{l} \text{Precision} = \frac{TP}{TP + FN} \\ \text{Recall} = \frac{TP}{TP + FP} \end{array} \right. \quad (8)$$

本文瓷砖数据集拍摄于佛山某瓷砖生产厂,使用工业线阵相机(charge couple device,CCD)一共收集到 3 801 张瓷砖照片用于训练(2 790 张)和测试(1 011 张),图片的分辨率为 4096×3500 ,如图 7 所示,每张瓷砖拍摄了 3 种类型图片:低角度光照黑白图、高角度光照黑白图和彩色图。该瓷砖厂生产的瓷砖缺陷种类主要包括:缺角瑕疵、浅色点块瑕疵、光圈瑕疵、面凹陷瑕疵和深色点块瑕疵。其中缺角瑕疵 315 张照片,浅色点块瑕疵 207 张照片,光圈瑕疵 99 张照片,面凹陷瑕疵 156 张照片,深色点块瑕疵 234 张照片。

由于工业 CCD 相机拍摄的缺陷图片分辨率过高,而被检测异常区域的长宽尺寸远小于原始图像尺寸,所以本文对缺陷图片进行预处理,根据异常特征中心所在位置对原始图像做切图处理,将含有缺陷区域的切图尺寸设置为 460×460 ,此时获得的图片异常特征明显,如图 8 所示。

式中: TP 为成功预测的正类数; FN 为被误判为负类的正类数; FP 为被错误预测为正类的负类数。

根据训练测试数据可视化绘图,其训练损失值、训练准确率、召回率及测试准确率,如图 9 所示,损失值随着迭代次数增加逐渐减少,在迭代 100 次时,损失值 < 1.1265 ;模型的训练准确率最终稳定在 95.09%;模型的测试准确率稳定在 94.56%;模型的召回率稳定在 97.84%,这些性能指标表明,网络模型具有良好的训练效果和泛化性能。通过预训练网络 CNN 有助于提高模型的异常检测定位性能。

该方法在异常检测和异常定位上进行评估,考虑到测试集中正负样本分布变换时,ROC 曲线(以召回率为横坐标,查准率为纵坐标)能够保持不变,所以采用 ROC 曲线以下的面积作为图像异常检测和异常定位的评价指标,记

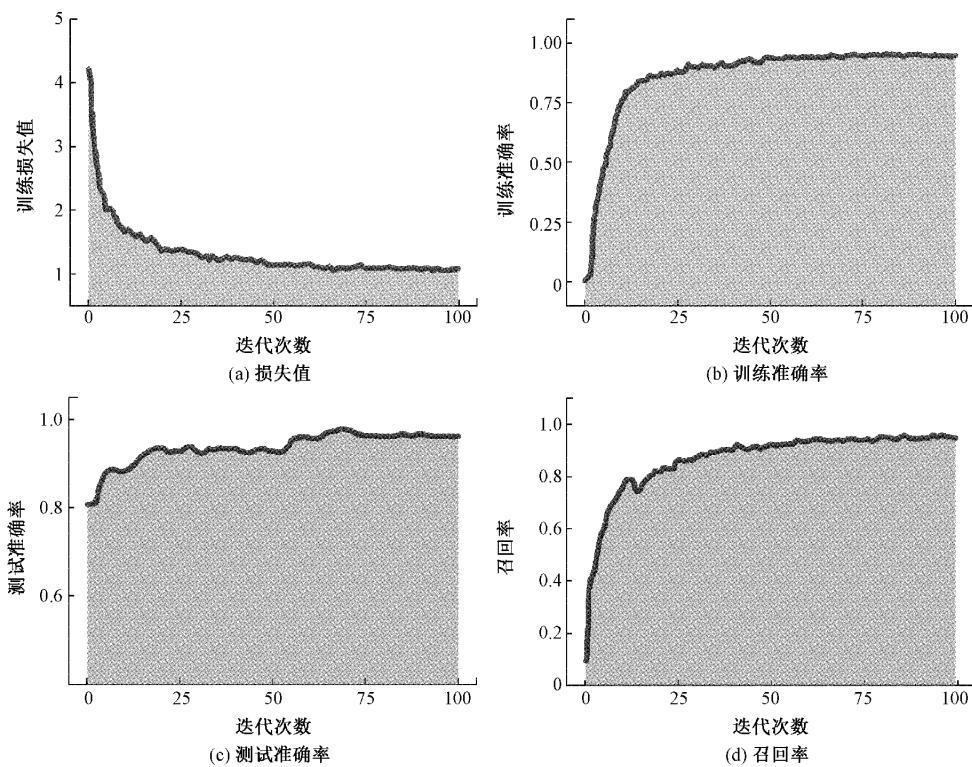


图 9 性能评估

作标准评估度量 (area under the receiver operating characteristic, AUROC)。将本文的方法与其他最先进的异常检测方法 RAID^[20], GANomaly^[21], Cutpaste, ITAE^[22] 和 US^[23] 进行比较, 对异常定位能力与其他最先进的异常定位方法 AnoGAN^[24] 和 VEVVAE^[25] 等进行比较, 并对瓷砖的不同类别给出 AUROC 评分。

2.3 异常检测

瓷砖的异常检测结果如表 2 所示, 结果以 AUROC 分

数列出, 最后一行是所有类的平均得分。本文算法异常检测的平均值是 95.09%, 比异常检测最高的 Cutpaste 和 US 两个模型的检测结果提高了 3.71% 和 2.74%, 说明即使瓷砖本身具有复杂的纹理结构, 不像对称图像那样对齐居中, 自监督模型也能有效捕获在正常训练数据集上的统计相似性。实验结果表明本文自监督算法优于 Cutpaste 和 US 等多种检测网络模型, 能够满足瓷砖表面异常检测的需求。

表 2 异常检测结果

种类	RIAD	GANomaly	Cutpaste	ITAE	US	Our	%
缺角瑕疵	94.15	84.31	92.27	70.56	95.83	97.85	
凹陷瑕疵	87.32	80.67	88.62	85.93	91.48	94.78	
深色瑕疵	93.26	76.82	89.43	68.72	89.45	90.54	
白色瑕疵	90.38	79.75	96.02	77.84	90.24	95.56	
光圈瑕疵	89.37	75.36	90.58	63.38	94.75	96.73	
平均值	90.89	79.38	91.38	73.28	92.35	95.09	

2.4 异常定位

异常定位可视化结果如图 10 所示, 第 1 列是瓷砖缺陷图片; 第 2 列白色区域是瓷砖表面缺陷真实定位掩码的图像(基准); 第 3 列是图像整体决策的 Grad-CAM 得分结果; 第 4 列是补丁决策得分热图。在最后两列图像中, 颜色表示缺陷得分, 得分越高, 表示该区域属于缺陷的置信

度越高。通过观察第 3 列和第 4 列图像, 整体决策和补丁决策能够完成不同类型缺陷定位, 但是补丁决策相比整体决策定位缺陷区域更加合理(例如, 图 10(b)补丁决策的光圈瑕疵与定位区域更加贴合), 色彩饱和度更高(例如, 图 10(f)补丁决策的深色瑕疵置信度更高)。

瓷砖表面异常定位评分结果如表 3 所示, 自监督模型

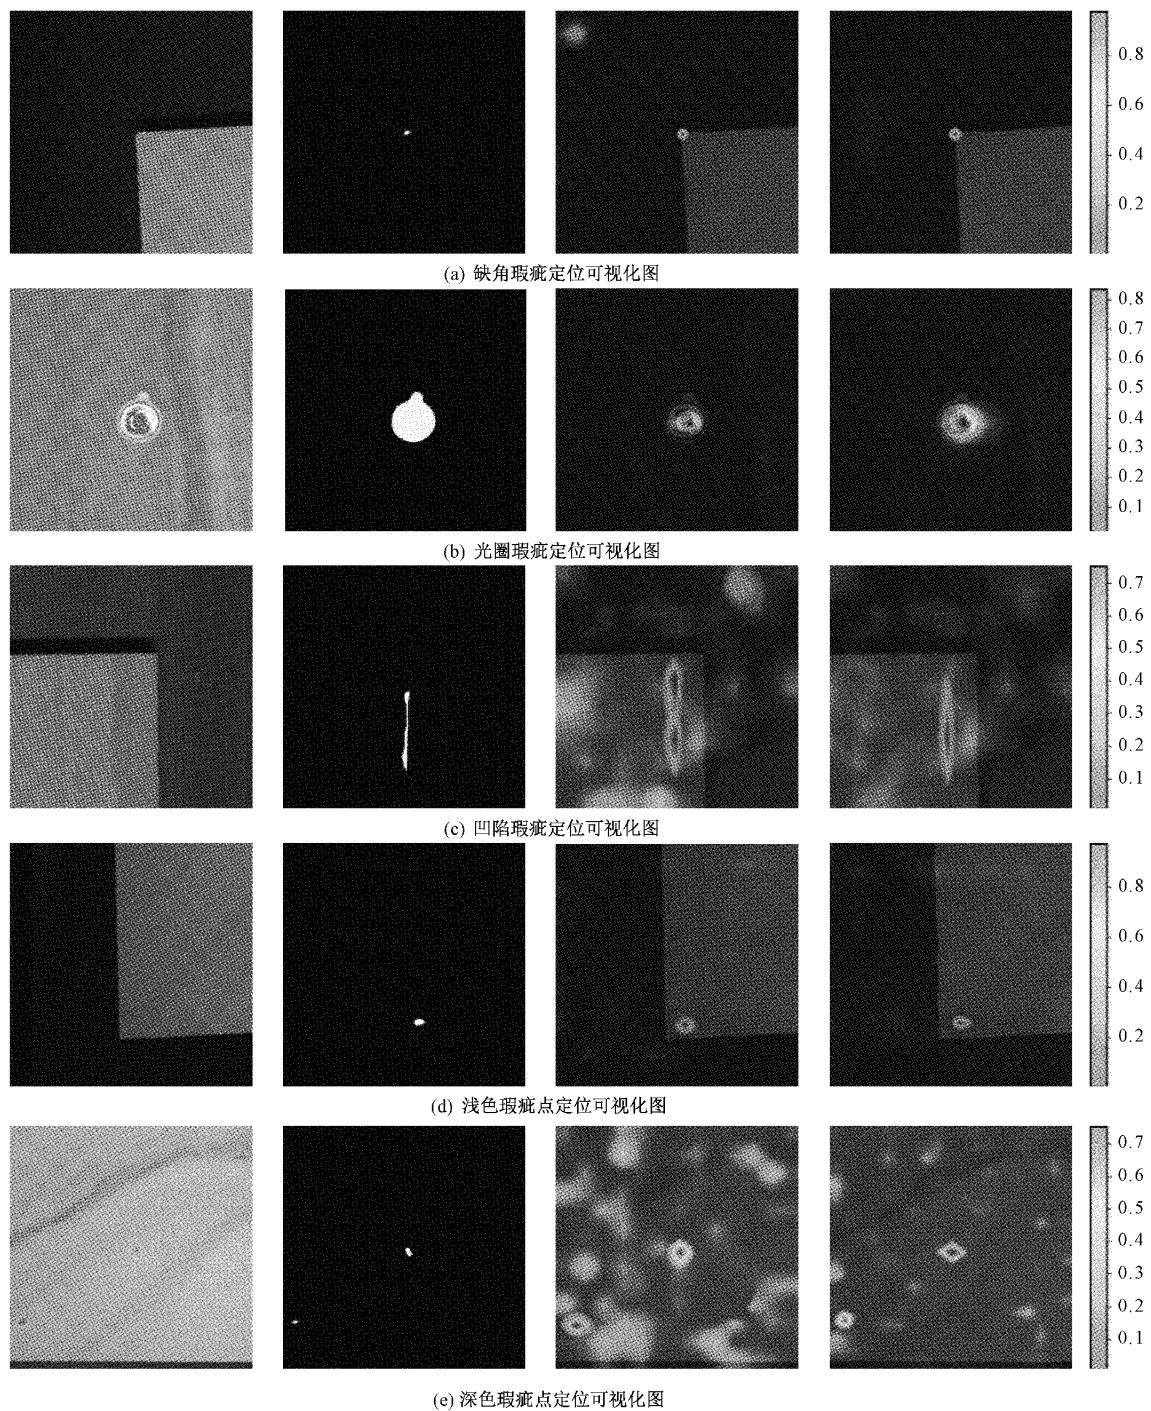


图 10 缺陷定位可视化图

通过整体决策和补丁决策进行异常定位,综合以上两种决策,该方法取得的平均定位评分为 93.32%。如表 4 所示,通过对比其他最先进的定位方法,本文取得的平均定位评分率最高,分别比异常定位评分率最高的 US 和 RAID 两种定位模型提高了 1.22% 和 4.01%。这表明设计的自监督网络模型可以有效地对瓷砖表面不规则异常进行准确定位。

表 3 AUROC 定位评分率

种类	整体决策	补丁决策	%
缺角瑕疵	94.53	96.24	
凹陷瑕疵	90.63	93.27	
深色瑕疵	88.75	89.04	
白色瑕疵	95.33	94.67	
光圈瑕疵	95.21	95.48	
平均值		93.32	

表4 AUROC定位评分率对比结果 %

种类	平均值
RIAD	89.31
AnoGAN	50.00
Cutpaste	88.31
US	92.10
VEVAE	80.00
Our	93.32

3 结 论

本文针对瓷砖表面纹理不规则和缺陷样本少等问题,提出了一种两阶段自监督瓷砖表面缺陷检测与定位模型。该模型在训练阶段只需要输入无标注样本,经过分布增强对比学习对数据进行扩充,解决了缺陷数据样本少,缺陷分布不规则性差的问题,减少了对标注数据的依赖,提高了瓷砖表面常见缺陷的检测和定位准确性和鲁棒性。实验表明,该模型的平均异常检测率达到95.09%;异常定位率达到93.32%,不仅保障了产业生产同批次瓷砖产品的可靠性和稳定性,还为瓷砖表面质量检测提供了新的方向。在未来的工作中,将对网络规模压缩和提高预测速度方面进行进一步研究。在产业应用领域,把模型部署在移动端,实现便捷实时的瓷砖表面缺陷检测与定位。

参考文献

- [1] 陶昱,侯伟,徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
- [2] 熊建平. 基于计算机视觉的墙地砖表面缺陷检测[J]. 电子测量技术, 2015, 38(5): 53-55.
- [3] 张军,张海云,赵玉刚等. 基于机器视觉的瓷砖裂纹检测[J]. 包装工程, 2018, 39(9): 146-150.
- [4] 权小霞,李军华,汪宇玲. 基于局部方差加权信息熵的瓷砖表面缺陷检测[J]. 中国陶瓷, 2019, 55(10): 46-55.
- [5] 李军华,权小霞,汪宇玲. 多特征融合的瓷砖表面缺陷检测算法研究[J]. 计算机工程与应用, 2020, 56(15): 8.
- [6] 王淑青,顿伟超,黄剑锋,王年涛. 基于YOLOv5的瓷砖表面缺陷检测[J]. 包装工程, 2022, 43(9): 217-224.
- [7] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: Visual explanations from deep networks via gradient-based localization [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 618-626.
- [8] LIZNERSKI P, RUFF L, VANDERMEULEN R A. Explainable deep one-class classification [J]. ArXiv Preprint, 2020, ArXiv:2007.01760.
- [9] LI C L, SOHN K, YOON J, et al. Cutpaste: Self-supervised learning for anomaly detection and localization [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 9664-9674.
- [10] SOHN K. Improved deep metric learning with multi-class n-pair loss objective [J]. Advances in Neural Information Processing Systems, 2016, 29: 1857-1865.
- [11] ARORA S, KHANDEPARKAR H, KHODAK M, et al. A theoretical analysis of contrastive unsupervised representation learning [J]. ArXiv Preprint, 2019, ArXiv:1902.09229.
- [12] RUFF L, VANDERMEULEN R, GOERNITZ N, et al. Deep one-class classification [C]. International Conference on Machine Learning, PMLR. 2018: 4393-4402.
- [13] WANG T, ISOLA P. Understanding contrastive representation learning through alignment and uniformity on the hypersphere [C]. International Conference on Machine Learning, PMLR. 2020: 9929-9939.
- [14] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]. International Conference on Machine Learning, PMLR, 2020: 1597-1607.
- [15] GOLAN I, EL-YANIV R. Deep anomaly detection using geometric transformations [J]. Advances in Neural Information Processing Systems, 2018, 31: 9758-9769.
- [16] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.
- [17] DEFARD T, SETKOV A, LOESCH A, et al. Padim: A patch distribution modeling framework for anomaly detection and localization [C]. International Conference on Pattern Recognition. Springer, Cham. 2021: 475-489.
- [18] REN J, LIU P J, FERTIG E, et al. Likelihood ratios for out-of-distribution detection [J]. Advances in Neural Information Processing Systems, 2019, 32: 1-4.
- [19] SOHN K, Li C L, YOON J, et al. Learning and evaluating representations for deep one-class classification [J]. ArXiv Preprint, 2020, ArXiv:2011.02578.
- [20] ZAVRTANIK V, KRISTAN M, SKOCAJ D. Reconstruction by inpainting for visual anomaly

- detection[J]. Pattern Recognition, 2021, 112: 107706.
- [21] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Gandomaly: Semi-supervised anomaly detection via adversarial training [C]. Asian Conference on Computer Vision. Springer, Cham, 2018: 622-637.
- [22] HUANG C, CAO J, YE F, et al. Inverse-transform autoencoder for anomaly detection [J]. ArXiv Preprint, 2019, ArXiv:1911.10676.
- [23] BERGMANN P, FAUSER M, SATTLEGGER D, et al. Uninformed students: Student-teacher anomaly detection with discriminative latent embeddings[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 4183-4192.
- [24] 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.

- [25] LIU W, LI R, ZHENG M, et al. Towards visually explaining variational autoencoders[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 8642-8651.

作者简介

王飞州,硕士研究生,主要研究方向为图像信息处理技术。

E-mail: 2200220105@stu.ahpu.edu.cn

程凡永(通信作者),博士,副教授,研究生导师,主要研究方向为图像处理,机器学习和故障诊断。

E-mail: b12090031@hnu.edu.cn

张明艳,讲师,主要研究方向为深度学习和图像处理。

E-mail: mingyanhappy0912@163.com

张红,副教授,主要研究方向为传感器技术与应用。

E-mail: zhang666y@126.com