

基于改进 PatchCore 的内存散热片表面缺陷检测算法^{*}

李冰^{1,2} 干根政^{1,2} 刘松言^{1,2} 张鑫磊^{1,2} 翟永杰^{1,2}

(1. 华北电力大学自动化系 保定 071003; 2. 保定市电力系统智能机器人感知与控制重点实验室 保定 071003)

摘要: 工业产品表面缺陷检测作为智能制造质量控制的核心环节,其检测精度与实时性高低对工业生产至关重要。针对现有无监督异常检测方法在复杂工业场景下面临的局部特征敏感性不足、计算冗余度高等关键问题,提出一种基于 PatchCore 的改进型多尺度特征融合检测算法。首先,通过引入自注意力机制的多尺度特征融合处理方式,对 layer3 特征图进行自注意力机制与平均池化的融合处理,增强算法对局部与全局异常特征的捕捉能力;提出通道聚合降维方法,将原始特征随机划分为若干连续子组,并对每组特征进行聚合操作生成低维特征,达到减少计算冗余的同时保留部分原始特征局部信息;构建迁移学习模型,增强算法在异常检测任务中的泛化能力,提高实际工业项目的检测精度。通过对内存散热片图像进行缺陷检测实验,结果表明,改进算法相较原算法 AUROC 提升 2.28%,F1Score 提升 4.89%,能够满足工业场景下高效率高精度的需求。

关键词: 异常检测;无监督算法;PatchCore 算法;通道聚合降维

中图分类号: TP391.4; TN911.73 文献标识码: A 国家标准学科分类代码: 520.6040

Surface defect detection algorithm for memory heat sink based on improved PatchCore

Li Bing^{1,2} Gan Genzheng^{1,2} Liu Songyan^{1,2} Zhang Xinlei^{1,2} Zhai Yongjie^{1,2}

(1. Department of Automation, North China Electric Power University, Baoding 071003, China;

2. Baoding Key Laboratory of Intelligent Robot Perception and Control in Electric Power System, Baoding 071003, China)

Abstract: As the core link of intelligent manufacturing quality control, the detection accuracy and real-time performance of surface defects in industrial products are crucial for industrial production. Aiming at the key problems of insufficient local feature sensitivity and high computational redundancy faced by existing unsupervised anomaly detection methods in complex industrial scenarios, an improved multi-scale feature fusion detection algorithm based on PatchCore is proposed. Firstly, by introducing a multi-scale feature fusion processing method with self attention mechanism, the layer 3 feature map is fused with self attention mechanism and average pooling to enhance the algorithm's ability to capture local and global abnormal features; propose a channel aggregation dimensionality reduction method, which randomly divides the original features into several continuous subgroups and aggregates each group of features to generate low dimensional features, achieving the goal of reducing computational redundancy while preserving some local information of the original features; build transfer learning models to enhance the algorithm's generalization ability in anomaly detection tasks and improve the detection accuracy of actual industrial projects. Through defect detection experiments on memory heat sink images, the results show that the improved algorithm improves AUROC by 2.28% and F1Score by 4.89% compared to the original algorithm, which can meet the requirements of high efficiency and high precision in industrial scenarios.

Keywords: anomaly detection; unsupervised algorithm; PatchCore algorithm; channel aggregation dimensionality reduction

0 引言

在工业领域中,产品质量控制直接影响企业核心竞争力与经济效益^[1],作为质量控制的核心环节,工业产品表面

缺陷检测对确保产品合格率具有不可替代的作用。目前工业产品表面的异常检测主要依赖人工方式进行目视检测,存在人工检测效率低下^[2]、劳动强度大、细小缺陷难以发现、漏检率居高等问题,严重制约了企业的产能提升和成本

控制。因此传统的人工视觉检测已经难以满足企业的要求^[3]。

近年来,随着卷积神经网络的不断发展,越来越多的深度学习模型被应用到异常检测领域中^[4]。基于深度学习的异常检测算法能够根据输入图片自身的特点,通过图像处理技术自动学习复杂、抽象的特征,从而实现细微缺陷的检测,在检测精度和效率方面均显著优于传统方法^[5]。

目前,基于深度学习的异常检测方法主要分为有监督和无监督两大类。有监督异常检测方法依赖于标注的数据,通过构建深度神经网络实现正常样本与异常样本的区分。虽然有监督异常检测方法检测效果较为准确,却存在以下局限:算法性能高度依赖标注数据的质量与数量^[6],会消耗大量的人力资源;根据已有数据训练出来的异常检测算法对于未知类型的异常检测失效,严重限制了算法的适用性。相较于有监督检测算法,无监督异常检测算法只需要拥有正常样本便可进行训练,异常检测与定位则通过比较正常样本与测试样本特征的差别实现^[7]。在实际工业应用中,更具有实用价值^[8]。

现阶段,无监督异常检测算法主要分为基于重建和基于特征嵌入两类方法。基于重建的方法核心思想是通过对正常样本的分布特征进行建模实现异常检测^[9],常见的重建模型包括自动编码器^[10]、基于生成对抗网络(generative adversarial networks, GAN)^[11-12]等。基于重建的方法具有较好的直观性与可解释性,但是有时模型会出现“过度泛化”等问题,导致异常图像也会被较好的重建^[13]。

基于特征嵌入的思想则是将高维图像数据映射到一个低维的特征空间(嵌入空间),在此空间内,正常数据和异常数据的特征分布可以被很好地捕捉。通过比较测试样本与正常样本数据分布的差异,从而判断测试样本是否为异常。如 Cohen 等^[14]受到 KNN 算法的启发,提出了一种基于异常图像和正常图像之间对齐的新型异常分割方法—SPADE,利用多分辨率特征金字塔的对应关系来获得像素级异常分割结果。Defard 等^[15]提出的 PaDiM 将高斯分布建模方法应用在 patch 级别的多尺度特征图,对正常样本的特征分布进行建模,并使用马氏距离检测异常。Roth 等^[16]提出的 PatchCore 算法设计了具有最大代表性的特征记忆库(Memory Bank),在保证检测精度的同时显著减少了推理所需要的时间。Zhou 等^[17]提出的 VQ-Flow 方法通过捕获概念特定的正态模式,并对复杂的多类数据分布进行建模,从而在多类设置中区分异常和正态样本。在 PatchCore 提出之后,许多新的方法如 GLASS^[18]、DDAD^[19]、CRAD^[20]等相继提出,尽管它们的检测效果有了新的提升,但在检测过程中需要进行多轮训练,难以部署到现实工业场景。

而 PatchCore 凭借无需重复训练的特征记忆库和较快推理速度的优势,更加适用于实际工业场景。Zhang 等^[21]提出的 Rail-PatchCore 方法通过加入双维通道注意模块,有效地降低了背景噪声的干扰,增强了异常特征的捕获能

力;杜坡等^[22]提出的改进 PatchCore 模型将主干特征提取网络改为 ResNet18,以达到轻量化的效果;Jiang 等^[23]提出的 FR-PatchCore 构建了一个特征矩阵,该矩阵被提取到特征记忆库中,解决了 PatchCore 在相似性主体方法在准确定位异常方面面临的重大限制;Ishida 等^[24]提出的 SA-PatchCore 将自注意力机制引入 PatchCore 中,提高算法对共现相关异常的检测能力。以上对 PatchCore 的改进方法大多都是基于特定任务完成的,且无法兼顾计算复杂度与检测精度之间的平衡。此外内存散热片表面缺陷类型与特点和上述任务具有较大差异,因此需要针对内存散热片表面缺陷数据集进行 PatchCore 算法的研究。

现有的方法虽然取得了较好的检测结果,但在处理多尺度异常特征时存在细节丢失问题^[25],且降维过程计算复杂度较高。为了进一步增强无监督异常检测算法的检测性能,本文以 PatchCore 为基础模型,提出一种改进的内存散热片表面缺陷检测的算法,主要工作内容如下:

首先通过引入自注意力机制的多尺度特征融合处理方式,实现对局部特征异常与基于远距离像素之间关系的全局特征异常的综合检测,提高检测的准确性以及分割的精度;提出通道聚合降维方法,将原始特征随机划分为若干连续子组,并对每组特征进行聚合操作,从而生成低维特征,达到减少计算冗余同时保留部分原始特征局部信息的效果;进行迁移学习模型的构建,使算法捕获的特征更适合工业产品表面缺陷异常检测的任务,提高检测的精确度。

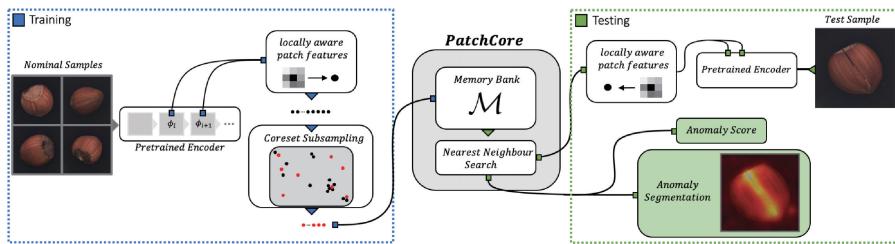
1 PatchCore 算法

PatchCore 是一种高效的无监督工业异常检测算法,该算法的核心工作在于通过构建具有代表性特征的记忆库来实现对正常样本分布的有效建模,从而检测异常图像中的异常区域(如刮痕、凹点等)。由于模型在训练时不需要异常样本,因此能够节省大量人工采集与标注图像的时间,且该方法能够识别多种异常,无需为每一种异常进行单独的训练,具有较高的适用性。PatchCore 算法原理简图如图 1 所示。

PatchCore 将输入图像分割成多个局部区域(patch),随后使用在 ImageNet 上预训练的 Wide ResNet-50 作为骨干网络^[26],提取中间两层(layer2、layer3)特征图并获取每个 patch 的特征向量。对获取的特征向量进行自适应平均池化处理,以确保不同尺寸的输入图像能够产生具有一致维度的特征向量。

在训练阶段,PatchCore 将所有正常图像的局部特征向量构建成原始的记忆库,使用核心集子采样方法将记忆库规模压缩至原始大小的 1%~10% 以显著降低存储内存与推理时间。

在测试阶段,PatchCore 对测试图像使用与训练阶段相同的操作提取每个 patch 的特征向量,随后使用 K 近邻(k-nearest neighbor, KNN)方法找到每个 patch 的特征向

图 1 PatchCore 算法原理简图^[16]Fig. 1 Schematic diagram of PatchCore algorithm principle^[16]

量在记忆库中与其最接近的特征向量，并计算它们之间的欧氏距离作为异常值。将所有异常值中的最大值作为图像级的异常值，如果该值超过预设的阈值，则认为整个图像存在异常。这些特性使 PatchCore 成为当前最先进的工业异常检测算法之一，也为本研究提供了重要基础。

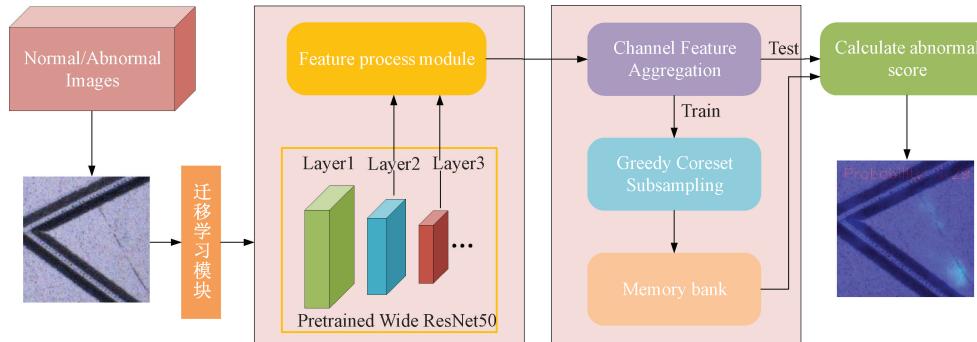


图 2 改进的 PatchCore 算法结构

Fig. 2 Improved PatchCore algorithm structure

1) 多尺度特征处理：通过在 ImageNet 上预训练的 WideResNet-50 提取输入图像的多层级特征，对 layer3 层级的特征图使用自注意力机制与平均池化融合处理，增强算法对局部异常与全局异常的综合检测能力。

2) 通道聚合降维：提出通道聚合降维方法代替随机投影降维技术，在保证算法精度的前提下降低计算的复杂程度，提高算法的推理效率。

3) 构建迁移学习模型：使用迁移学习技术对预训练模型进行微调，使算法能够学习到更适用于特定数据集的特征表示，提高实际工业项目的检测效果。

2.2 多尺度特征提取与处理

在异常检测过程中，多尺度特征的有效融合对异常检测精度具有决定性作用^[27]。Wide ResNet-50 的 layer2 和 layer3 特征图保留了较多的如轮廓、边缘、颜色等底层特征，这些特征对捕获图像中的异常非常重要；由于深层网络特征会过于偏向 ImageNet 的数据分布，并不能很好的适用于工业场景，因此本文改进的算法仍沿用 PatchCore 的多尺度特征提取策略，选择 layer2 和 layer3 来进行特征信息的提取。主体结构如图 3 所示。

layer2 特征图(28 pixel×28 pixel)保留了更多的底层

2 改进的 PatchCore 算法

2.1 整体架构设计

改进型 PatchCore 算法结构如图 2 所示，包含 3 个关键改进：

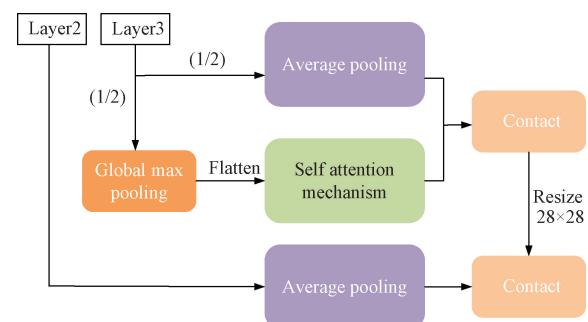


图 3 特征提取与处理

Fig. 3 Feature extraction and processing

特征，适合检测图像中的微小局部异常。因此对 layer2 提取的特征图使用进行内核大小为 3、步长为 1、填充为 1 的卷积核进行平均池化，确保输出特征图的尺寸不变。通过聚合局部区域的特征信息以增强局部特征的鲁棒性，以实现对微小的局部异常检测。具体实现过程如下：

$$O_{i',j'} = \frac{1}{k \cdot k} \sum_{i=0}^{k-1} \sum_{j=0}^{k-1} I_{(i',s-p+i), (j',s-p+j)} \quad (1)$$

其中， $O_{i',j'}$ 表示输出特征图在位置 (i', j') 处的值，

$I_{(i,j)}$ 表示输入特征图在位置 (i,j) 处的值, k 为内核大小, s 为步长, p 为填充。layer3 特征图(14×14 分辨率)具有更大的感受野, 能够捕获图像中广泛的上下文信息, 所以更适合图像全局特征的异常检测。因此, 对 layer3 特征图进行如下处理: 将 layer3 特征图按通道维度一分为二, 其中前半部分通道由自注意力机制处理, 用于检测测试图像的全局特征异常; 后半部分通道则进行平均池化, 增强算法局部异常检测能力。

对于前半部分通道特征图, 使用内核大小为 3、步长为 1、填充为 1 的卷积核进行最大池化来强调局部区域内的显著特征, 将池化后的特征展平并对特征张量的维度进行重新排列, 复制 3 次后分别作为查询(Q)、键(K)和值(V)。计算查询 Q 与键 K 之间的点积, 然后利用 softmax 函数归一化以计算注意力权重。通过此非线性方式, 算法能够更好地捕捉到不同区域之间的相关性和异常特征。具体实现过程如下:

$$\text{Attention Weight} = \text{softmax}\left(\frac{Q \cdot K^T}{\sqrt{d_k}}\right) \quad (2)$$

其中, d_k 表示键 K 的维度。将注意力权重与值 V 相乘, 得到加权后的特征, 并将其维度排列为原始特征图形状。后半部分通道特征图则执行平均池化处理, 保留局部细节特征。由于 layer3 特征图的分辨率小于 layer2, 使用双线性插值将其分辨率调整至与 layer2 相同, 再与 layer2 输出结果拼接。

2.3 通道聚合降维

PatchCore 算法对原始记忆库使用随机投影降维技术来降低特征向量的维度。该方法根据 Johnson-Lindenstrauss 定理, 通过随机投影将高维特征向量投影到低维空间, 保持数据的几何结构和相对距离, 从而降低后续核心集子采样的计算复杂度。但是随机投影降维具有以下局限性: 首先降维结果依赖于随机生成的投影矩阵, 因此每次运行的结果可能不同, 这将导致结果的不稳定性^[28]; 其次随机投影可能对某些需要精确保留距离或全局结构的数据集效果不佳, 且随机投影的效果依赖于投影矩阵的选择, 这将增加使用随机投影的复杂性。

因此, 提出一种基于通道特征聚合的降维方法, 通过对原始特征进行分组和聚合, 实现特征维度的降低。核心思想是将高维特征随机划分为若干连续子组, 每组包含若干特征, 通过聚合操作(如取均值)生成低维特征, 从而实现在保留重要特征信息的同时, 有效降低计算复杂度和存储空间。令输入矩阵为 $\mathbf{X} \in R^{N \times D}$, 经过降维之后的输出矩阵则为 $\mathbf{X}_{\text{reduced}} \in R^{N \times D_r}$ 。具体计算过程如下:

1) 根据降维比例 r , 计算降维后的特征维度:

$$D_r = D \cdot r \quad (3)$$

2) 将高维特征随机划分为 D_r 个连续子组, 每组大小 $k = D/D_r$ 。分组及组内特征可表示为:

$$G_i = \{x_{i \cdot k+j} \mid j = 1, 2, \dots, k\}, i = 0, 1, \dots, D_r - 1 \quad (4)$$

3) 再对每个组的特征进行聚合操作, 以均值聚合为例:

$$z_i = \frac{1}{k} \sum_{j=1}^k x_{i \cdot k+j} \quad (5)$$

其中, N 表示样本数量, D_r 表示降维后的特征维度, D 表示原始特征维度, r 表示目标降维比例(通常取 0.1), G_i 表示划分的第 i 个组, x 表示组内包含的特征。经过以上步骤, 降维后的特征矩阵为 $\mathbf{X}_{\text{reduced}} = [z_0, z_1, z_2, \dots, z_{D_r-1}] \in R^{N \times D_r}$ 。

通道聚合降维法通过随机分组和聚合操作实现降维, 降低计算复杂度, 适合对大规模数据进行处理。同时通过聚合操作能够在一定程度上保留原始特征的局部信息, 避免了全局降维方法可能带来的信息丢失问题。降维比例 r 可以根据实际需求进行调整, 在降维效果和计算复杂度之间进行平衡。

2.4 迁移学习模型的构建

迁移学习是深度学习领域中一种重要的技术手段, 旨在将在大规模数据集上预训练的模型应用于特定的小规模数据集, 从而解决小规模数据集标注困难、数据量不足等问题^[29]。为了增强算法在检测任务中的泛化能力, 对改进的 PatchCore 模型使用迁移学习中的微调方法, 即对预训练模型进行小幅度调整, 使模型适应新任务。具体流程如图 4 所示。

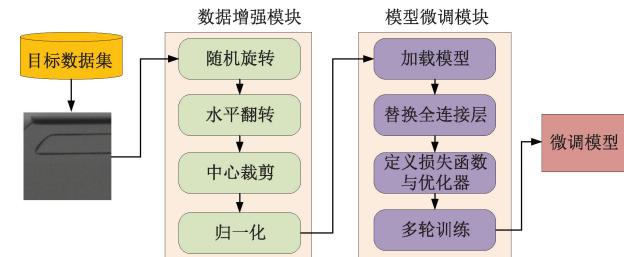


图 4 迁移学习流程图

Fig. 4 Transfer learning flow chart

为了增强模型的泛化能力并避免过拟合, 将输入图像统一调整为 256 pixel \times 256 pixel, 并使用双线性插值对图像进行平滑的缩放, 保持图像几何特征。随后使用随机旋转和随机水平翻转操作, 增强模型对旋转变化的鲁棒性以及增加数据的多样性, 对图像数据进行归一化处理以加速模型收敛。

在模型初始化过程, 首先加载预训练的 Wide ResNet-50-2 权重, 替换最后的全连接层, 将输出特征维度从 1 000 维调整为任务所需的类别数以适应新的分类任务。随后使用交叉熵损失函数作为优化目标, 通过最小化模型预测概率分布与真实标签分布之间的差异, 驱动模型学习有效的特征表示。优化器则采用随机梯度下降优化器, 将初始学习率设置为 0.01, 动量参数为 0.9 以减少训练过程中的震荡。

训练过程中,遍历训练数据,计算损失并更新模型参数。随后将模型设置为评估模式,遍历测试数据,计算测试损失和准确率,并使用 TensorBoard 记录训练过程中的损失和准确率以实时监控模型性能。

3 实验结果与分析

3.1 实验数据集

本实验采用某公司提供的内存散热片构建表面缺陷检测数据集,数据来自于真实工业生产场景,具有较高的实用价值和挑战性。该数据集主体为内存散热片表面以及表面缺陷图像,根据图像类别,本实验根据图像颜色将其分为 Black 和 White 两类分别进行检测。其中 Black 数据集多为污点、异色种类的异常,White 数据集则更多为划痕种类的异常。本实验数据集共有正常样本 897 张,异常样本 692 张,图片大小均为 224 pixel×224 pixel,实物图如图 5 所示。

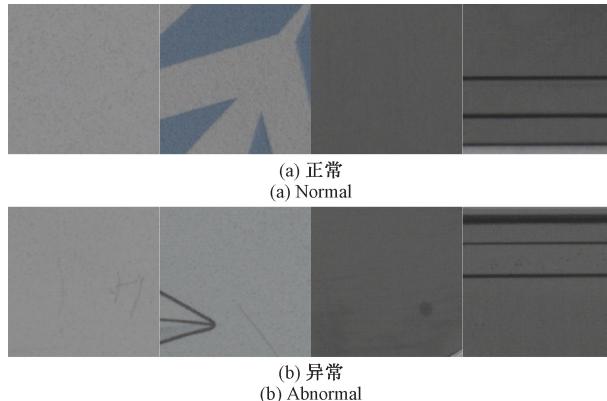


图 5 内存散热片表面缺陷数据集

Fig. 5 Dataset of surface defects on memory heat sinks

表 1 主流算法在数据集上的检测结果

Table 1 Detection results of mainstream algorithms on the dataset

%

数据集	评价指标	PaDim	PatchCore	VQ-flow	CRAD	GLASS	DDAD	SA-PatchCore	Rail-PatchCore	Ours
Black	AUROC	70.18	96.73	94.70	93.88	99.92	99.37	98.73	98.73	99.55
	F1Score	89.35	96.50	94.49	94.70	98.94	98.72	97.12	97.71	99.06
White	AUROC	93.33	97.35	92.03	94.20	99.43	98.64	98.27	98.21	99.08
	F1Score	82.78	91.37	95.20	95.25	98.27	98.32	95.73	98.04	98.59

由表 1 的实验结果可得,本文改进的算法在 Black 和 White 数据集上的表现皆优于除 GLASS 之外的其他算法,在 AUROC 与 F1Score 指标上有明显提升。尽管 GLASS 算法在检测精度方面获得最佳结果,但该算法在运行过程中需要进行数百轮训练,取最佳结果作为输出,并不适用于实际工业检测场景。在与其他改进 PatchCore 算法的对比中,虽然两种算法均对模型进行了改进,但提升的效果均低于本文改进算法。本文改进算法 AUROC 指标的提升表明,使用引入自注意力机制的多尺度特征融

3.2 实验评价指标

为了全面评估改进算法的性能,采用以下两个广泛认可的指标进行算法评价:AUROC 和 F1Score^[30]。AUROC 是指 ROC 曲线下的面积,用于评估分类模型在不同阈值下的综合性能。F1Score 是精确率和召回率的调和平均数,特别适用于类别不平衡的场景。F1Score 的计算公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1Score = 2 \times \frac{Precision \cdot Recall}{Precision + Recall} \quad (8)$$

其中,TP 表示正确识别的正样本数量,FN 表示错误识别为负样本的正样本数量,FP 错误识别为正样本的负样本数量,TN 表示正确识别的负样本数量。

3.3 实验环境与参数

实验所使用的操作系统为 Windows 11 家庭中文版,CPU 为 Intel(R) Core(TM) i9-14900HX,主频 2.20 GHz,内存 16 GB。GPU 配置为 NVIDIA GeForce RTX 4060 Laptop GPU,显存 8 GB。在实验过程中,核心集子采样的采样率为 1%,通道聚合降维的降维比例为 10%,编程语言为 python3.8,加速模块基于 CUDA-11.8 实现。

3.4 实验结果与分析

1) 算法检测精度结果对比

为了验证改进算法的有效性,本实验在内存散热片表面缺陷检测数据集上与无监督异常检测算法 PaDim、PatchCore、VQ-flow、CRAD、GLASS、DDAD 和已有改进的 PatchCore 算法 SA-PatchCore、Rail-PatchCore 进行对比实验。实验结果如表 1 所示。

合处理方式能够更好的捕获异常特征,有效提升检测精度;F1Score 指标的提升表明,改进的算法在精确率和召回率之间取得较好的平衡,能够进行有效的分类。综上对比分析,本文改进算法更适用于实际工业检测场景之中,同时保证了较高的精确度以及检测实时性,具有较高的应用价值。

2) 不同降维方法对计算冗余方面性能对比

为了验证通道聚合降维技术对算法推理速度的影响,本文做了如下实验:分别对改进的算法使用通道聚合降维、

随机投影降维和 PCA 降维方法,对比算法在单张图片上的

推理时间和特征记忆库的构建时间,具体结果如表 2 所示。

表 2 不同降维方法在单张图片上的推理时间和特征记忆库构建时间对比

Table 2 Comparison of inference time and memory bank construction time of different dimensionality

reduction methods on a single image

s

数据集	评价指标	随机投影降维	PCA 降维	通道聚合降维
Black	单张图片的推理时间	0.202	0.169	0.155
	特征记忆库构建时间	111	97	82
White	单张图片的推理时间	0.230	0.184	0.163
	特征记忆库构建时间	907	724	566

由表 2 可得,当使用通道聚合降维方法时,算法在 Black 与 White 数据集中单张图片的推理时间皆小于另外两种方法。这表明改进的的算法在保证检测高精度的基础上实现了更快的推理效率,具有更高的性能,更好地满足工业背景下的高效率标准。同时,使用通道聚合降维方法时,算法构建特征记忆库的效率有着巨大的提升,表明算法在训练阶段的计算复杂度大大降低,体现了算法性能的优越性。此外,由于通道聚合降维方法对随机划分的连续子组进行聚合操作,保留了检测所需要的部分特征信息,因此能够比随机投影降维与 PCA 降维方法有更高的检测精度,实验结果如表 3 所示。

3) 自注意力机制在不同通道维度比例下检测精度的对比试验

对 layer3 层特征图引入自注意力机制能够增强算法

对基于远距离像素之间关系的全局特征异常的检测能力,但同时也会带来更大的计算冗余和降低局部异常检测能力的缺点。因此为了实现算法对局部异常和全局异常的综合检测能力,本文进行了自注意力机制在不同通道维度比例下检测精度的对比试验,其中通道维度比例分别选取 25%、50%、75%、100%。实验结果如表 4 所示。

表 3 不同降维方法对检测精度的影响

Table 3 The impact of different dimensionality reduction methods on detection accuracy

%

降维方法	平均 AUROC	平均 F1Score
随机投影降维	98.53	97.44
PCA 降维	98.38	96.99
通道聚合降维	99.31	98.82

表 4 自注意力机制在不同通道维度比例下的检测精度

Table 4 Detection accuracy of self attention mechanism at different channel dimension ratios

%

数据集	评价指标	25%	50%	75%	100%
Black	AUROC	98.93	99.55	99.06	99.75
	F1Score	97.92	99.06	96.92	95.85
White	AUROC	99.04	99.08	98.97	99.04
	F1Score	98.28	98.59	97.37	95.11

由表 4 的实验结果可知,当通道维度比例为 50% 时,White 数据集 AUROC 和 F1Score 两个指标均最高;对于 Black 数据集,虽然通道维度比例为 50% 时的 AUROC 结果比 100% 时低 0.2%,但是其 F1Score 结果远高于后者,综合考虑下通道维度比例为 50% 时综合检测能力更强。此外,由于引入自注意力机制会增加计算复杂度,因此通道维度比例为 50% 更能满足时效性要求。

4) 消融实验结果与分析

为了验证提出的各项改进措施对算法性能的贡献,本文进行了消融实验的设计。在相同实验条件下,以 PatchCore 算法为基础,逐步进行各项改进措施。SA 指代自注意力机制(self-attention, SA), CFA 指代通道聚合降维(channel aggregation dimensionality reduction, CFA), TL 指代迁移学习(transfer learning, TL), 以各数据集平均

AUROC 和 F1Score 作为评价指标,实验结果如表 5 所示。

由表 5 的实验结果可知,将自注意力机制引入算法并改变处理方式,算法的 AUROC 指标提高 0.87%,F1Score 提升 2.82%,表明该改进增强了算法对异常的捕获能力,特别是在检测长程依赖关系(如划痕)方面表现突出;此外,使用通道聚合降维方法代替随机投影降维技术后,算法平均 AUROC 提升 0.41%,平均 F1 Score 提升 1.27%,表明此改进不仅能够加快算法的推理效率,还能保证算法精度的微小增长,提高算法的综合能力;通过构建迁移学习模型,预训练模型学习到更适用于此数据集的特征表示,算法平均 AUROC 提升 0.61%,平均 F1 Score 提升 0.77%,对算法的精度和召回率都起到了积极的作用。将 3 种改进方案结合在一起后,AUROC 提升了 2.27%,F1Score 提升了 4.89%,在各个数据集上的推理效率均有

表 5 消融实验结果

Table 5 Results of ablation experiment

实验方法	平均 AUROC	平均 F1Score	AUROC 提升	F1Score 提升	%
PatchCore	97.04	93.93	0	0	
PatchCore+SA	97.91	96.75	0.87	2.82	
PatchCore+CFA	98.28	97.59	1.24	3.66	
PatchCore+TL	97.13	94.895	0.09	0.97	
PatchCore+SA+TL	98.53	97.44	1.49	3.51	
PatchCore+CFA+TL	98.94	98.71	1.90	4.78	
PatchCore+SA+CFA	98.70	98.05	1.66	4.12	
Ours	99.31	98.82	2.27	4.89	

所提升,表明改进的算法达到了提高算法检测精度和检测效率的效果。

5)定位与分割结果可视化

为了更好的观察改进算法的检测与定位结果,对

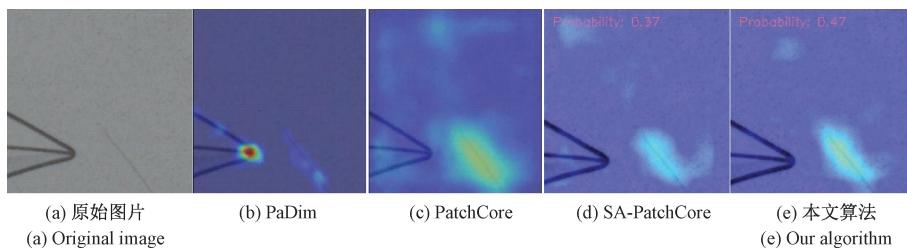


图 6 各算法异常区域定位结果

Fig. 6 Anomalous region localization results of various algorithms

热图中红色区域越多、颜色越深则表明该处为异常区域的可能性越大。如(图 6(b))所示,PaDim 算法最终生成的热图异常区域明显区别于另外 3 种算法,出现了鲜明的非异常区域的红色标记,这表明 PaDim 算法在检测与定位过程中产生了严重的误定位问题,因此无法正确的对异常区域进行分割。从图 6(c)、图 6(d)和图 6(e)相比可看出,PatchCore 算法生成的热图异常区域更加分散,正常区域中也出现了大块的黄色标记。而本文改进的算法热图上异常区域与真实缺陷位置高度吻合,更加集中于真实异常的位置,未出现定位错误的问题。

综上所述,本文改进的算法有以下 3 方面的效果:首先,通过对特征信息进行多尺度特征融合处理,提高算法对局部异常与全局异常特征的捕获能力,增强算法的综合检测能力;其次,提出通道聚合降维方法,实现在保留部分重要特征的基础上降低计算复杂度,提高算法推理效率;最后,通过对预训练模型进行迁移学习,增强算法的泛化能力与鲁棒性,提高算法的检测精度。

4 结论

在工业领域,高效准确的异常检测技术是产品质量控制的关键环节。针对现有无监督异常检测算法在检测精度和计算效率方面的不足,提出了一种基于改进

PaDim、PatchCore、SA-PatchCore 和本文算法进行了可视化处理。首先对所有测试图像的异常得分进行归一化,随后将最终的结果以热图的形式呈现,异常得分以文字的形式展现在热图的左上角,具体示例如图 6 所示。

PatchCore 的无监督异常检测算法。该算法引入自注意力机制并优化处理方式,增强了算法对局部与全局特征的捕获能力;提出通道聚合降维方法,实现精度与推理效率的全面优化;对预训练模型进行迁移学习,进一步提升改进算法的检测精度。通过对真实工业场景下所采集的内存散热片表面缺陷数据集进行实验,该算法在 AUROC 和 F1Score 两个指标上都有着较大的提升,实现了更高性能的缺陷检测,表明改进算法能够更好地满足工业产品检测所需要的高精度、高效率的标准。

参考文献

- [1] 王文鹏,秦寅畅,师文轩.工业缺陷检测无监督深度学习方法综述[J].计算机应用,2025,45(5):1658-1670.
WANG W P, QIN Y CH, SHI W X. Review of unsupervised deep learning methods for industrial defect detection[J]. Journal of Computer Applications, 2025, 45(5): 1658-1670.
- [2] 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.
- [3] 方明, 张娇, 徐晶, 等. 基于改进 YOLOv8 的轻量化皮革缺陷检测方法[J]. 电子测量技术, 2025, 48(1): 111-118.
- FANG M, ZHANG J, XU J, et al. Lightweight leather defect detection method based on improved YOLOv8[J]. Electronic Measurement Technology, 2025, 48(1):111-118.
- [4] 樊慧超. 机器视觉技术在工业检测中的应用[J]. 数字通信世界, 2020(12):156-157.
- FAN H CH. The application of machine vision technology in industrial inspection [J]. Digital Communication World, 2020(12):156-157.
- [5] 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]. Computing Technology and Automation, 2022, 41(1):59-65.
- [6] 王镇, 翟轲, 薛赛, 等. 基于通用视觉大模型与注意力增强的无监督异常检测[J]. 北京交通大学学报, 2025, 49(3): 14-22.
- WANG ZH, ZHAI K, XUE S, et al. Unsupervised anomaly detection based on universal visual transformer and attention enhancement[J]. Journal of Beijing Jiaotong University, 2025, 49(3): 14-22.
- [7] LIU J, XIE G, WANG J, et al. Deep industrial image anomaly detection: A survey [J]. ArXiv preprint arXiv: 2301.11514, 2023.
- XING P, SUN Y, ZENG D, et al. Normal image guided segmentation framework for unsupervised anomaly detection[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34 (6): 4639-4652.
- [9] DEHAENE D, FRIGO O, COMBREXELLE S, et al. Iterative energy-based projection on a normal data manifold for anomaly localization [C]. International Conference on Learning Representations, AddisAbaba, Ethiopia, 2020.
- [10] MATSUBARA T, SATO K, HAMA K, et al. Deep generative model using unregularized score for anomaly detection with heterogeneous complexity[J]. IEEE Transactions on Cybernetics, 2022, 52 (6): 5161-5173.
- [11] YAN X D, ZHANG H D, XU X X, et al. Learning semantic context from normal samples for unsupervised anomaly detection [C]. AAAI Conference on Artificial Intelligence, 2021:3110-3118.
- [12] MISHRA P, VERK R, FORNASIER D, et al. VT-ADL: A vision transformer network for image anomaly detection and localization [C]. 2021 IEEE 30th International Symposium on Industrial Electronics (ISIE). IEEE, 2021: 1-6.
- [13] 史广, 贺福强, 史红燕, 等. 基于深度学习的航空发动机叶片缺陷检测技术综述[J/OL]. 航空动力学报, 1-21 [2025-03-08]. <https://doi.org/10.13224/j.cnki.jasp.20240411>.
- SHI G, HE F Q, SHI H Y, et al. Review of deep learning-based defect detection techniques for aero-engine blade[J/OL]. Journal of Aerospace Power, 1-21 [2025-03-08]. <https://doi.org/10.13224/j.cnki.jasp.20240411>.
- [14] COHEN N, HOSHEN Y. Sub-image anomaly detection with deep pyramid correspondences [J]. ArXiv preprint arXiv:2005.02357, 2020.
- [15] 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, 2021: 475-489.
- [16] ROTH K, PEMULA L, ZEPEDA J, et al. Towards total recall in industrial anomaly detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 14318-14328.
- [17] ZHOU Y X, XU X, SUN Z, et al. VQ-Flow: Taming normalizing flows for multi-class anomaly detection via hierarchical vector quantization [J]. ArXiv preprint arXiv: 2409.00942, 2024.
- [18] CHEN Q Y, LUO H Y, LYU CH K, et al. A unified anomaly synthesis strategy with gradient ascent for industrial anomaly detection and localization [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024.
- [19] MOUSAKHAN A, BROX T, TAYYUB J. Anomaly detection with conditioned denoising diffusion models[C]. DAGM German Conference on Pattern Recognition. Cham: Springer Nature Switzerland, 2024: 181-195.
- [20] LEE J C, KIM T, PARK E, et al. Continuous memory representation for anomaly detection [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2024: 438-454.
- [21] ZHANG Y H, YU Z J, ZHU L Q, et al. Rail-PatchCore: Unsupervised learning-based detection of visual anomalies in the railway-turnout environment[J]. Applied Intelligence, 2025, 55(6): 408.

- [22] 杜坡,张乐年. 基于无监督深度学习的卷烟包装外观缺陷检测[J]. 机械制造与自动化,2023,52(5):222-224.
DU P, ZHANG L N. Appearance defect detection of cigarette packaging based on unsupervised deep learning[J]. Machine Building & Automation, 2023, 52(5): 222-224.
- [23] JIANG Z, ZHANG Y, WANG Y, et al. FR-PatchCore: An industrial anomaly detection method for improving generalization [J]. Sensors, 2024; 24(5):1368.
- [24] ISHIDA K, TAKENA Y, NOTA Y, et al. SA-PatchCore: Anomaly detection in dataset with co-occurrence relationships using self-attention[J]. IEEE Access, 2023, 11: 3232-3240.
- [25] 蒋宇浩. 无监督工业品表面异常检测算法研究[D]. 哈尔滨:哈尔滨工业大学,2024.
JIANG Y H. Research on unsupervised anomaly detection algorithms for industrial product surfaces [D]. Harbin: Harbin Institute of Technology,2024.
- [26] ZAGORUYKO S, KOMODAKIS N. Wide residual networks[J]. ArXiv preprint arXiv:1605.07146, 2016.
- [27] CHENG M, LU S, DONG X, et al. Multiscale recurrent-guided denoising network for distributed acoustic sensing-vertical seismic profile background noise attenuation [J]. Geophysics, 2023, 88 (1): WA201-WA217.
- [28] 赵刚,刘飞飞,王继奎,等. 基于图的无监督降维算法研究进展[J]. 信息与控制,2025,54(1):28-49.
ZHAO G, LIU F F, WANG J K, et al. Research progress in graph-based unsupervised dimensionality reduction algorithms [J]. Information and Control, 2025, 54(1):28-49.
- [29] 张震. 深度迁移学习在文本分类问题中的应用研究综述[J]. 信息技术与信息化,2023(6):121-124.
ZHANG ZH. A review of the application research of deep transfer learning in text classification problems [J]. Information Technology and Informatization, 2023 (6): 121-124.
- [30] XIE G, WANG J B, LIU J Q, et al. IM-IAD: Industrial image anomaly detection benchmark in manufacturing[J]. IEEE Transactions on Cybernetics, 2024,54(5): 2720-2733.

作者简介

李冰,博士,副教授,主要研究方向为模式识别与计算机视觉。

E-mail:li_bing_hb@126.com

干根政,硕士研究生,主要研究方向为模式识别与计算机视觉。

E-mail:gangenzheng@126.com

刘松言,硕士研究生,主要研究方向为模式识别与计算机视觉。

E-mail:1095125474@qq.com

张鑫磊,硕士研究生,主要研究方向为模式识别与计算机视觉。

E-mail:2398812564@qq.com

翟永杰(通信作者),博士,教授,主要研究方向为模式识别与计算机视觉。

E-mail:zhaiyongjie@ncepu.edu.cn