文章编号:1007－6735(2025)05－0533－09　DOI: 10.13255/j.cnki.jusst.20240718001

基于改进 PatchCore 的无监督异常检测算法

税建达[1]，　陈　龙[1]，　卞佰成[1]，　吴世青[1]，　陈红光[2]
（1. 上海理工大学 机械工程学院，上海 200093；2. 上海贝特威科技有限公司，上海 200093）

摘要： 在现有的工业系统中，利用无监督算法进行工业场景的结构异常检测是一种非常重要的手段。针对现有无监督异常检测模型对离群正常特征的低敏特性，提出一种基于 PatchCore 改进的无监督异常检测模型。首先，引入无监督聚类算法对其核心特征集进行聚类采样，以降低算法对离群的正常特征的敏感度。其次，以余弦相似度作为度量标准，仅考虑特征向量方向的相似性，从而消除正常特征向量内异常值导致欧式距离异常的影响。最后，在 MVTec LOCO AD 和 MVTec AD 数据集上分别进行验证。实验结果表明，改进的 PatchCore 模型在 MVTec LOCO AD 和 MVTec AD 数据集上的图像级 AUROC 和像素级 AUROC 得分分别达到 0.876 和 0.860，与 PatchCore 模型相比，分别提升了 5.1% 和 3.7%。

关键词： 无监督；异常检测；聚类采样
中图分类号： TP 391　　**文献标志码：** A

Unsupervised anomaly detection algorithm based on improved PatchCore

SHUI Jianda[1], CHEN Long[1], BIAN Baicheng[1], WU Shiqing[1], CHEN Hongguang[2]
(1. *School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China*; 2. *Shanghai Betterway Automation Technology Co., Ltd., Shanghai 201109, China*)

Abstract: In existing industrial systems, using unsupervised algorithms for structural anomaly detection in industrial scenes is a very important means. To address the low sensitivity of existing unsupervised anomaly detection models to outlier normal features, an improved unsupervised anomaly detection model based on PatchCore was proposed. Firstly, an unsupervised clustering algorithm was introduced to cluster and sample its core feature set, in order to reduce the sensitivity of the algorithm to outlier normal features. Secondly, using cosine similarity as a metric, only the similarity in the direction of the

收稿日期: 2024−07−18
基金项目: 国家自然科学基金资助项目(52005338)
第一作者: 税建达(1998—)，男，硕士研究生．研究方向：机器视觉．E-mail：sjd15884970333@163.com
通信作者: 陈　龙(1978—)，男，教授．研究方向：机器视觉与机器人应用技术．E-mail：cl@usst.edu.cn

引文格式: 税建达，陈龙，卞佰成，等．基于改进 PatchCore 的无监督异常检测算法[J]．上海理工大学学报，2025，47(5)：533-541.
Citation: SHUI Jianda, CHEN Long, BIAN Baicheng, et al. Unsupervised anomaly detection algorithm based on improved PatchCore[J]. Journal of University of Shanghai for Science and Technology, 2025, 47(5): 533-541.

feature vectors was considered to eliminate the influence of outliers within the normal feature vectors on the Euclidean distance anomaly. Finally, validation was performed on the MVTec LOCO AD and MVTec AD datasets, respectively. The experimental results show that the improved PatchCore model achieves image-level AUROC and pixel-level AUROC scores of 0.876 and 0.860 on the MVTec LOCO AD and MVTec AD datasets, respectively, which is increased by 5.1% and 3.7% compared with that of the PatchCore model.

Keywords: *unsupervised*; *anomaly detection*; *cluster sampling*

无监督异常检测旨在对某一过程中产生的不符合主观意愿的事件进行观测，在不同的应用场景下有不同的表现形式，目前已广泛应用到了工业、农业、医学以及传统手工业等领域。在工业应用中，无监督缺陷检测多以结构异常为主要检测目标，旨在发现生产工件表面的破损、异物、划伤，是一种不需要标注数据的机器学习方法。它可以从大量的正常数据中学习出正常特征，并将新进入的数据与这些特征进行比较，从而判断该数据是否存在异常。相比于全监督学习方法，无监督学习方法不需要人工标注数据，这大大降低了人工成本，并且可以更好地适应不同生产环境下的变化。然而，无监督结构异常检测方法也面临着一些挑战。例如，如何从大量的正常数据中学习出有效的特征，如何有效地比较新进入的数据与这些特征的相似性，以及如何评估模型的性能等。无监督模型大多依赖于学习正常数据固有的表示能力，通过在 MVTec AD[1] 和 MVTec LOCO AD[2] 等标准工业异常检测数据集上的实践，研究者们通常使用自动编码器模型[3]来实现。为了更好地估计数据集分布，文献 [4] 提出了基于混合高斯模型的扩展。为了避免直接拟合隐空间分布，选择结合贝叶斯公式来提升概率的上界，文献 [5] 在此基础上提出了一种新模型 GWAE。InsetGAN[6] 在 GAN 的基础上学习预定义的几何或者通过归一化流变换。文献 [7] 选择直接计算隐空间的解析解估计分布。近几年的研究开始使用在大型外部自然图像数据集（如 ImageNet[8]）上预训练的模型，体现了更为优秀的检测性能。使用预训练模型的强大之处在于无需对手头的数据进行任何适应，这导致了其他依赖使用预训练特征的工业异常检测方法的出现，如 SpaDe[9]，它利用包含各种特征层次的内存库进行细粒度的异常分割和图像级异常检测。文献 [10]在 SpaDe 的基础上提出了 PaDim，其利用特征块和马氏距离估算异常。该方法与文献 [11]在完整图像上的研究类似。为了更好地解释自然预训练和工业图像数据之间的分布变化，可以进行后续的自适应，例如通过文献 [12] 中的学生–教师知识蒸馏模型[13]。

目前在工业领域应用较多的 PatchCore[14] 算法，沿用了 PaDim 的结构，使用内存库来保留特征信息。但是，面对复杂的工业场景，PatchCore 算法同样不能展示优秀的效果。针对 PatchCore 算法使用贪心算法作为核心集采样策略，使其易忽略部分正常特征分布的离群值，导致核心集无法包含完整的正常特征实例。同时，其使用了欧式距离作为衡量指标，可能存在对特征向量中的轻微噪声敏感的问题。对此，提出了两个改进：首先，假设正常样本的特征服从混合高斯分布，即存在多组不同的均值和方差的集合$\{(\mu_1,\sigma_1^2),(\mu_2,\sigma_2^2),\cdots,(\mu_k,\sigma_k^2)\}$能完全表示正常特征。因此，以 K-means 作为核心特征集的聚类策略，其拟合出的核心簇作为混合高斯分布的均值，能更好地表示正常样本特征集。其次，由网络提取的特征向量均已映射到了统一的特征空间中，在衡量特征相似性时仅需考虑向量间的方向，即两个向量夹角越小，线性相关性越高；夹角越大，相关性越低。因此，本文引入余弦相似度来衡量特征之间的相似程度。

1 方 法

1.1 PatchCore 概述

PatchCore 算法分为 3 大部分：聚合到内存库的局部特征、核心集降采样策略、检测和定位决策。

a. 聚合局部特征：选取 Wide-resnet[15] 作为预训练网络，输入图像通过预处理送入网络的大小为 224×224，以批量大小为 2 举例，输入预训练网

络中的大小为(2，3，224，224)。由于不特意进行目标分布的迁移和适配，直接调用在 ImageNet 预训练后的模型，从 ImageNet 上学习到的高级抽象特征和工业环境中所需要的抽象特征相关度不高，因此，网络在更深更抽象层上的适配置信度有限。此外，由于可提取的高维特征表示较少，这类方法在测试时可用的上下文语境也受到了限制。所以 PatchCore 算法使用局部聚合的中间层的补丁特征。经过有效实验证明，以预训练网络中的第 2 层与第 3 层的特征结合起来能产生最好的效果。第 3 层的输出为(2，1024，14，14)，通过双线性插值与第 2 层进行匹配，由平均池化进行特征聚合，存入核心集。如式(1)和(2)所示：

$$N_p^{(h,w)}=\left\{(a,b)\middle|a\in\left[\left(h-\frac{p}{2}\right),\cdots,\left(h+\frac{p}{2}\right)\right],\ b\in\left[\left(w-\frac{p}{2}\right),\cdots,\left(w+\frac{p}{2}\right)\right]\right\} \tag{1}$$

$$\varphi_{i,j}\left(N_p^{(h,w)}\right)=\mathrm{fag}\left(\left\{\varphi_{i,j}(a,b)|(a,b)\in N_p^{(h,w)}\right\}\right) \tag{2}$$

式中：$N_p^{(h,w)}$为特征图上位置(h,w)处大小为$p\times p$的一块补丁；fag为邻域特征向量的聚合函数。

b. 核心集降采样：为了缩短实际应用的时间，控制核心集的大小，以欧式距离为指标，使用贪婪核心集子采样进行不同比例的采样。实验结果表明，以 1%(即降采样后的特征集大小与原始核心集大小的比例)效果最为突出。

c. 将测试集的图片通过同样的编码方式，输入同样的预训练网络中得到的特征与降采样后的核心集以欧式距离作为标准，用测试集中特征到核心集中各自最近邻居M^*的最大距离分数S^*来估计图像级异常分数S。

1.2　改进后的算法

以 PatchCore 算法作为基线，在此基础上改良采样策略和得分方式，改良后流程图如图 1 所示。

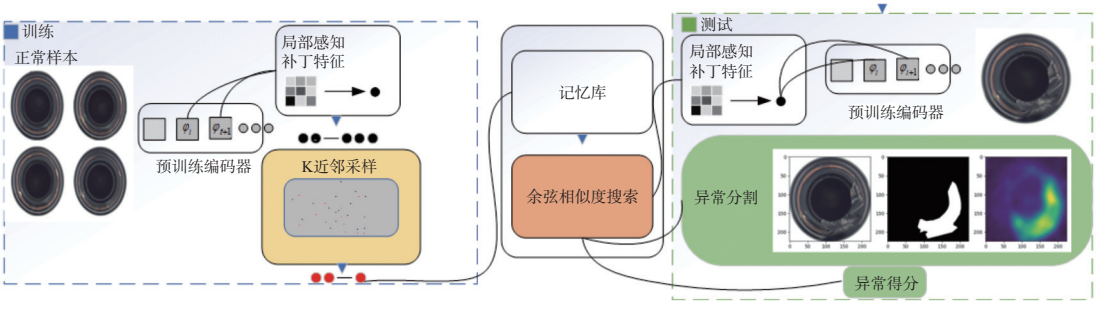

图 1　算法流程图

Fig.1　Flow chart of algorithm

保留 PatchCore 算法的原始框架，提取预训练网络中的第 2 层和第 3 层的特征，通过双线性插值对齐相应的补丁特征，为了进一步减少采样时间，利用 Johnson-Lindenstrauss 定理[17]，通过 PCA 降低特征维度：$R^d\to R^{d_*}$，并且$d_*<d$。引入 K-means 算法替换贪婪算法，作为核心集采样策略，更好地拟合原始特征集的分布状态。对于核心集M，通过测试特征到M_*中各自最近邻居M_*的余弦距离S_*来估计图像级异常分数。

1.3　核心集采样

对于一个正常的图片来说，亮度、形状、相机状态、物体自身状态的不同会导致图片的分布出现较大的差异。为了有效表示正常样本特征，本文假设其分布服从混合高斯分布，即正常样本特征x可以由k个不同的子高斯分布模型$\{(\mu_1,\sigma_1^2),(\mu_2,\sigma_2^2),\cdots,(\mu_k,\sigma_k^2)\}$表示为$p(x)=\sum_{i=1}^{k}\lambda_i\frac{1}{\sqrt{2\pi}\sigma_i}\mathrm{e}^{-\frac{(x-\mu)^2}{2\sigma^2}}$，其中：$\lambda_i$表示第$i$个高斯模型的权重；$\mu$表示期望；$\sigma^2$表示方差。以 bottle 样本为例，图 2 展示了不同 bottle 样本的像素分布情况。

由于物体自身状态及其他因素干扰，所拍摄出来的图片并不属于单一分布。此时，无法使用单一高斯分布描述该样本分布，混合高斯分布可以更好地描述这个问题。对于单高斯模型，以最大似然函数来估算参数θ的值，公式如下：

$$\theta=\arg\max_{\theta}L(\theta) \tag{3}$$

假设每个数据点独立，由概率密度函数推导似然函数，公式如下：

$$L(\theta)=\Pi_{j=1}^{N}P(x_j,\theta) \tag{4}$$

由于每个点发生的概率都很小，乘积会变得极其小，不利于计算和观察，因此，通常用最大尽然估计来计算。对于高斯混合模型，最大似然函数的公式如下：

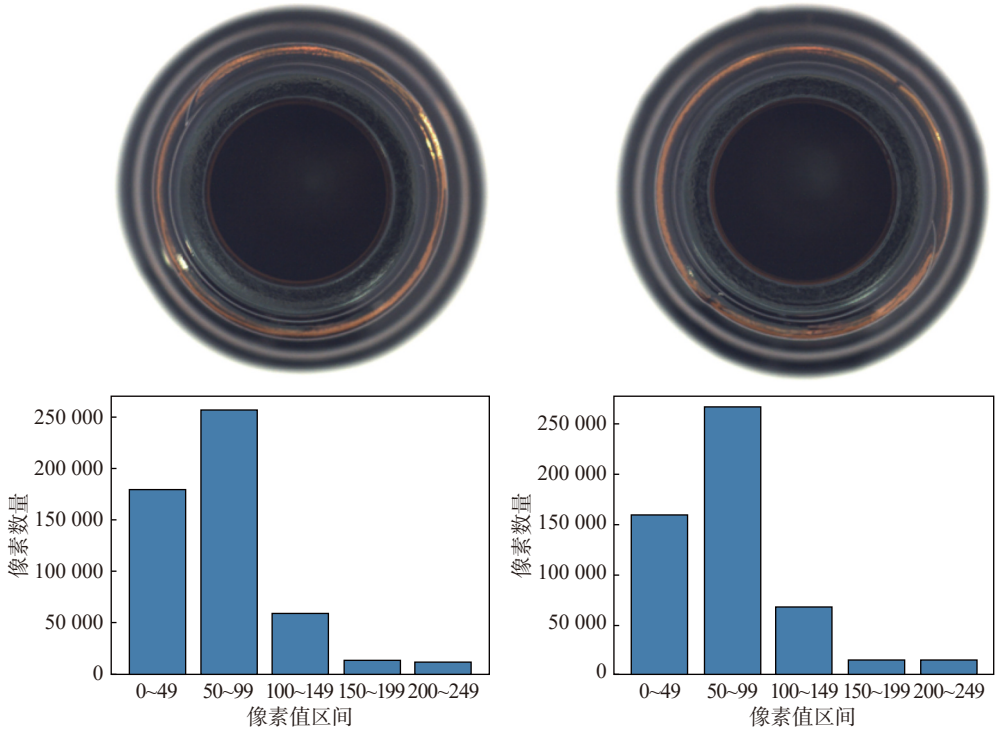

图 2　正常样本及其分布对比图

Fig.2　Comparison chart of normal samples and their distribution

$$\log L(\theta)=\sum_{j=1}^{N}\log P(x_j,\theta)=\sum_{j=1}^{N}\log\left(\sum_{k=1}^{K}\alpha_k\varphi(x,\theta_k)\right)\quad(5)$$

每个子模型都有未知的α_k、μ_k、σ_k，直接求导无法计算，需要通过迭代的方法进行求解。于是，选择 K-means 算法来完成核心集的采样工作。具体是将 Backbone 提取的特征经过 PCA 降维处理，得到相关系数较大的维度，之后将降维的特征送入采样器中，这样可以避免筛选出来的特征集中在某一区域，使特征更能代表整个数据的分布。图 3 展示了贪婪算法和原 K-means 算法的流程。

后续的实验 1 可以来侧面证明这个观点。图 4 以 bottle 中的 5 000 个样本为例，展示了极小最大值以及 K-means 聚类这 2 种不同采样方式的对比效果。K-means 聚类采样方法没有遗漏簇，更加接近空间支持。

1.4　异常得分计算

传统的 K-means 聚类算法采用的是欧式距离

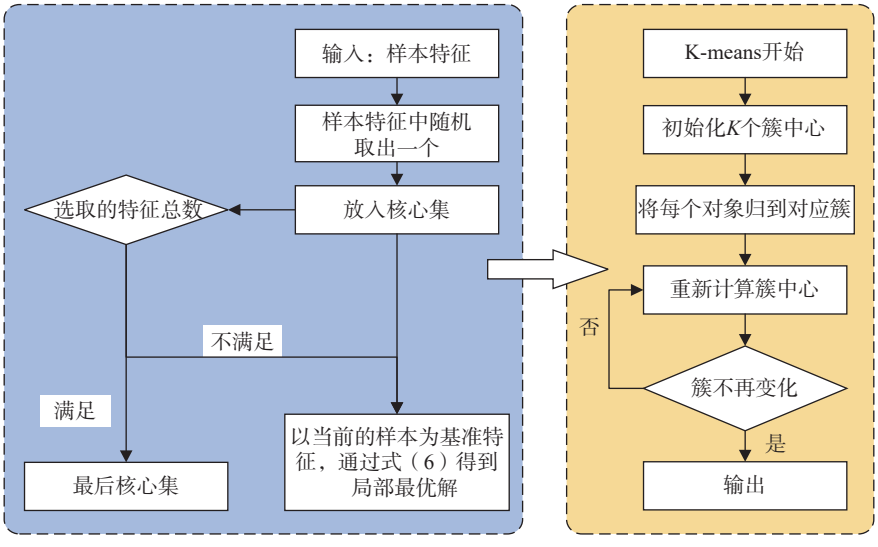

图 3　贪婪算法（左）与 K-means（右）流程对比图

Fig.3　Comparison chart of the greedy algorithm (left) and K-means (right) processes

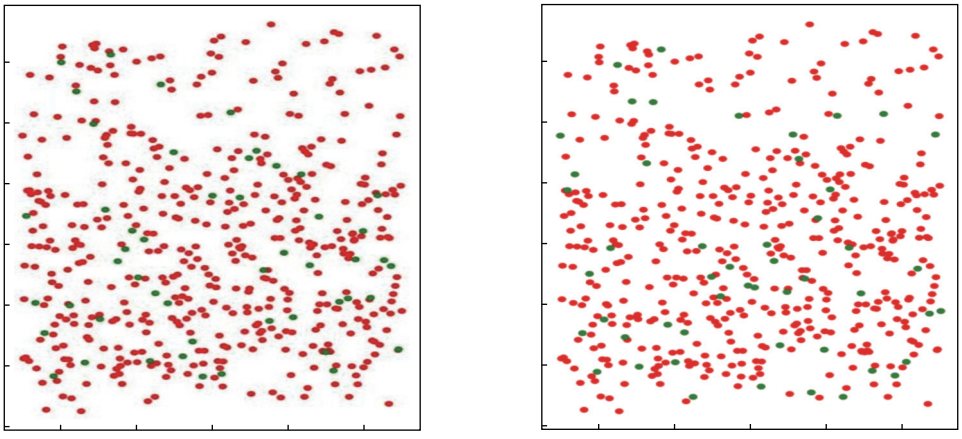

图 4　极小最大值采样（左）和 K-means 采样（右）对比图

Fig.4　Comparison chart of extreme minimum maximum value sampling (left) and K-means sampling (right)

度量，但将欧式距离替换成余弦距离会取得更好的效果。因为欧式距离更加注重数值的差异，而余弦距离衡量的是空间向量的夹角，更加体现出在方向上的差异。为了更好地衡量两个高维向量的相似性，余弦相似度更加适合。具体地，将测试图片以上述一样的传播方式得到测试特征，以测试特征为中心，将内存库中特征的余弦相似度作为得分，设置一个超参数 k，取前 k 个与测试特征相似的特征，将它们通过余弦相似度得到的分数通过均值化并且平均后的分数作为最后的分数，公式如下：

$$m^{\text{test},*}, m^{*} = \underset{m^{\text{test}} \in P(x^{\text{test}})}{\arg\max} \ \underset{m \in M}{\arg\min} \| m^{\text{test}} - m \|_2 \tag{6}$$

$$S^{*} = \frac{\sum_{i=1}^{n} (m_i^{\text{test},*} m_i^{*})}{\sqrt{\sum_{i=1}^{n} (m_i^{\text{test},*})^2} \sqrt{\sum_{i=1}^{n} (m_i^{*})^2}} \tag{7}$$

式中：$m^{\text{test},*}, m^{*}$ 分别是测试集和训练集通过算法所聚类的核心库特征。

2　实验与结果分析

2.1　实验平台配置

本实验基于搭载 Intel Xeon E5-2680 v3 CPU 与 NVIDIA GTX 1080 Ti GPU 的硬件平台，在 Windows 系统下使用 PyTorch 框架及 CUDA 11.3 完成。

2.2　评价指标

为了测量分割性能，使用图像级 AUROC 和异常像素级 AUROC 作为衡量指标。AUROC 曲线是针对各种阈值设置下的分类问题的性能度量，是一种概率曲线，表示可分离的程度或测度。表 1 展示了该曲线中需要使用的评价变量。其中：T_{N} 代表模型正确地预测出了一个正常样本；F_{P} 代表模型错误地将一个正常样本预测为异常；F_{N} 代表模型错误地将一个异常样本预测为正常；T_{P} 代表模型正确地预测出了一个异常样本。

表 1　评价指标

Tab.1　Evaluation indicators

真实值	测试值	
	0	1
0	T_{N}	F_{P}
1	F_{N}	T_{P}

当前被分到正样本类别中，真实的正样本占所有正样本的比例，即真阳性率 T_{PR} 公式如下：

$$T_{\text{PR}} = \frac{T_{\text{P}}}{T_{\text{P}} + T_{\text{N}}} \tag{8}$$

所有完好的样本里错误检测为有缺陷的样本占的比例，即假阳性率 F_{PR} 公式如下：

$$F_{\text{PR}} = \frac{F_{\text{P}}}{F_{\text{P}} + T_{\text{N}}} \tag{9}$$

2.3　实验结果

实验 1 对 MVTec AD 数据集进行以 20 为梯度，依次降低训练集的数量，最终发现每个类的训练集数量在 140 张左右，最后的得分能达到最好的效果。图 5 为单一样本数量（以 bottle 为例）对 3 种评判标准的影响折线图；图 6 展示了整个数据集的不同数量对 3 种评判标准的影响，其中：红色代表原数据数量，蓝色代表删减后数据数量。实验结果表明，140 张图片的训练集与 300 张图片的训练集表现结果相差不大，甚至优于 300 张的训练集。这也从侧面证明了 PatchCore

算法中核心集采样策略容易陷入局部最优解的结果。

2.4 MVTec LOCO AD 和 MVTec AD 数据集上的异常检测

MVTec LOCO AD 数据集用于评估无监督异常定位算法，分为两个部分：结构异常和逻辑异常。它包含来自 5 个不同类别的 3644 张图像。图 7 展示了数据集的实例。

MVTec AD 数据集是用于对异常检测方法进行基准测试的数据集，重点是工业检测。它包含超过 5000 个高分辨率图像，分为 15 个不同的对象和纹理类别。每个类别包括一组无缺陷的训练图像和具有各种缺陷的图像的测试集以及没有缺陷的图像。

为了验证算法的有效性和普适性，在 MVTec LOCO AD 和 MVTecAD 数据集上进行实验 2，所得到的结果和 PatchCore 算法相比，在 bottle、pill、cable 等类别上能保持较好的结果，但在 carpet、grid 等纹理特征显著的类别上稍显逊色。表 2 为实验在 MVTec LOCO AD 数据集上的结果，表 3 为实验在 MVTec AD 数据集上的结果。

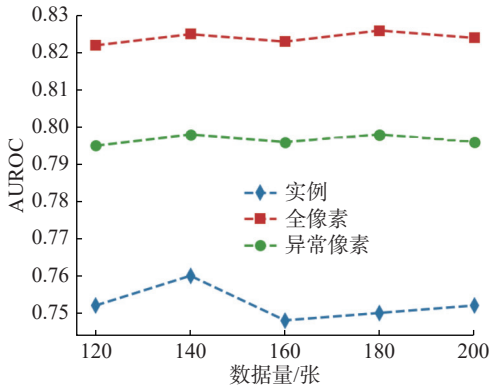

图 5 bottle 类样本数量对评价指标的影响

Fig.5 The impact of the number of bottle-type samples on the evaluation indicators

图 8 为在 MVTec LOCO AD 数据集上的检测结果。

2.5 消融实验

为了验证不同改进策略对算法性能的影响，设计了 4 组不同策略搭配的消融实验，实验结果如表 4 所示。改进 1 为用 K-means 采样方式替换贪心算法，改进 2 为更改距离度量方式和得分计算方式。实验结果表明，使用 K-means 采样方式替换贪心算法，图像级 AUROC 提高了 4.3%，异常像素级 AUROC 提高了 1.6%。如果单独改进得

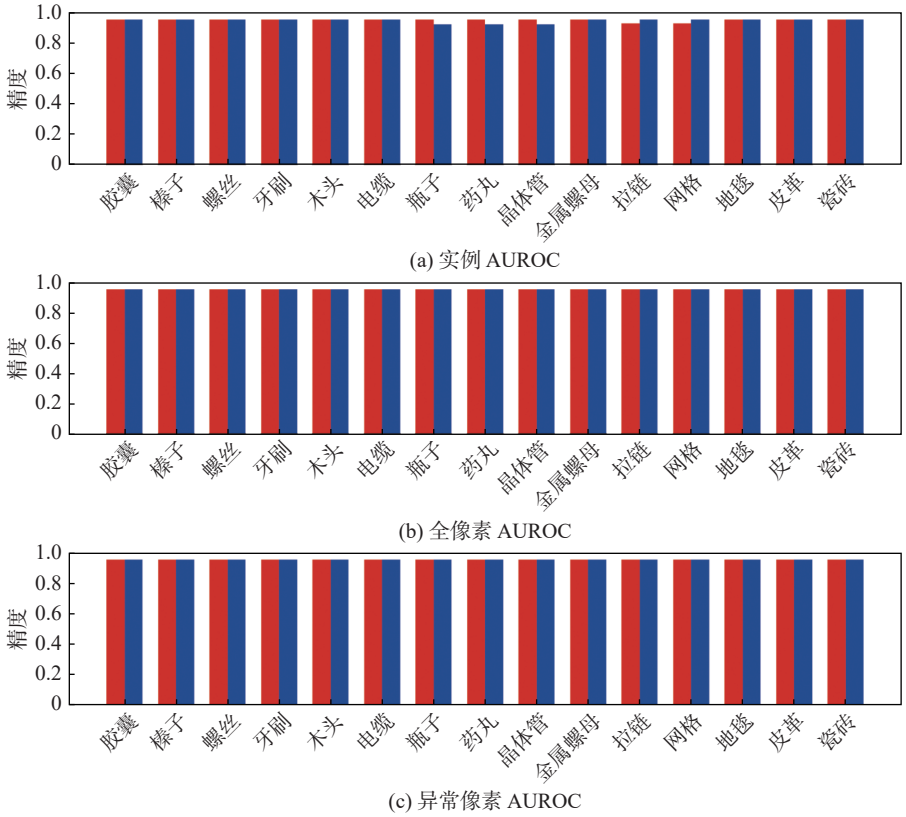

(a) 实例 AUROC

(b) 全像素 AUROC

(c) 异常像素 AUROC

图 6 不同种类训练集数量对评价标准的影响

Fig.6 The impact of the number of different types of training sets on evaluation standards

图 7　MVTec LOCO AD 数据集实例

Fig.7　MVTec LOCO AD dataset instance

表 2　MVTec LOCO AD 检测结果 (图像级 AUROC/异常像素级 AUROC)

Tab.2　MVTec LOCO AD detection results (image-level AUROC/anomalous pixel-level AUROC)

类别	PatchCore	改良后的算法	PaDim	CutPaste
breakfast box	(0.80,0.80)	(0.83,0.80)	(0.78,0.78)	(0.70,/)
pushpins	(0.90,0.88)	(0.91,0.89)	(0.59,0.87)	(0.68,/)
screw bag	(0.80,0.78)	(0.85,0.84)	(0.60,0.82)	(0.80,/)
splicing connectors	(0.86,0.83)	(0.88,0.83)	(0.59,0.82)	(0.66,/)
juice bottle	(0.95,0.92)	(0.95,092)	(0.82,0.84)	(0.78,/)
平均	(0.82,0.82)	(0.88,0.86)	(0.64,0.83)	(0.71,/)

表 3　MVTec AD 检测结果 (图像级 AUROC/异常像素级 AUROC)

Tab.3　MVTec AD detection results (image-level AUROC/anomaly pixel-level AUROC)

类别	PatchCore	改良后的算法	PaDim	CutPaste
bottle	(0.98,0.98)	(0.98,0.98)	(0.98,0.95)	(0.98,/)
cable	(0.98,0.97)	(0.97,0.96)	(0.97,0.89)	(0.91,/)
capsule	(0.99,0.99)	(0.99,0.99)	(0.98,0.94)	(0.97,/)
carpet	(0.99,0.99)	(0.99,0.99)	(0.99,0.96)	(0.98,/)
grid	(0.98,0.98)	(0.94,0.94)	(0.97,0.95)	(0.98,/)
hazelnut	(0.98,0.98)	(0.98,0.97)	(0.98,0.92)	(0.97,/)
leather	(0.99,0.99)	(0.99,0.99)	(0.99,0.98)	(0.99,/)
metal_nut	(0.98,0.98)	(0.98,0.97)	(0.97,0.86)	(0.93,/)
pill	(0.98,0.98)	(0.96,0.96)	(0.96,0.93)	(0.96,/)
screw	(0.99,0.99)	(0.98,0.97)	(0.99,0.94)	(0.97,/)
tile	(0.96,0.94)	(0.95,0.95)	(0.94,0.86)	(0.91,/)
toothbrush	(0.99,0.98)	(0.95,0.95)	(0.99,0.93)	(0.98,/)
transistor	(0.96,0.93)	(0.95,0.93)	(0.97,0.98)	(0.93,/)
wood	(0.95,0.94)	(0.95,0.93)	(0.95,0.98)	(0.96,/)
zipper	(0.99,0.99)	(0.99,0.98)	(0.98,0.98)	(0.99,/)
平均	(0.98,0.97)	(0.97,0.96)	(0.97,0.94)	(0.96,/)

分计算方式和距离度量，其效果没有 PatchCore 算法优秀。但是，如果结合 K-means 采样和改进得分计算方式、距离度量，比单独使用 K-means 时的图像级 AUROC 提升了 1.1%，异常像素级 AUROC

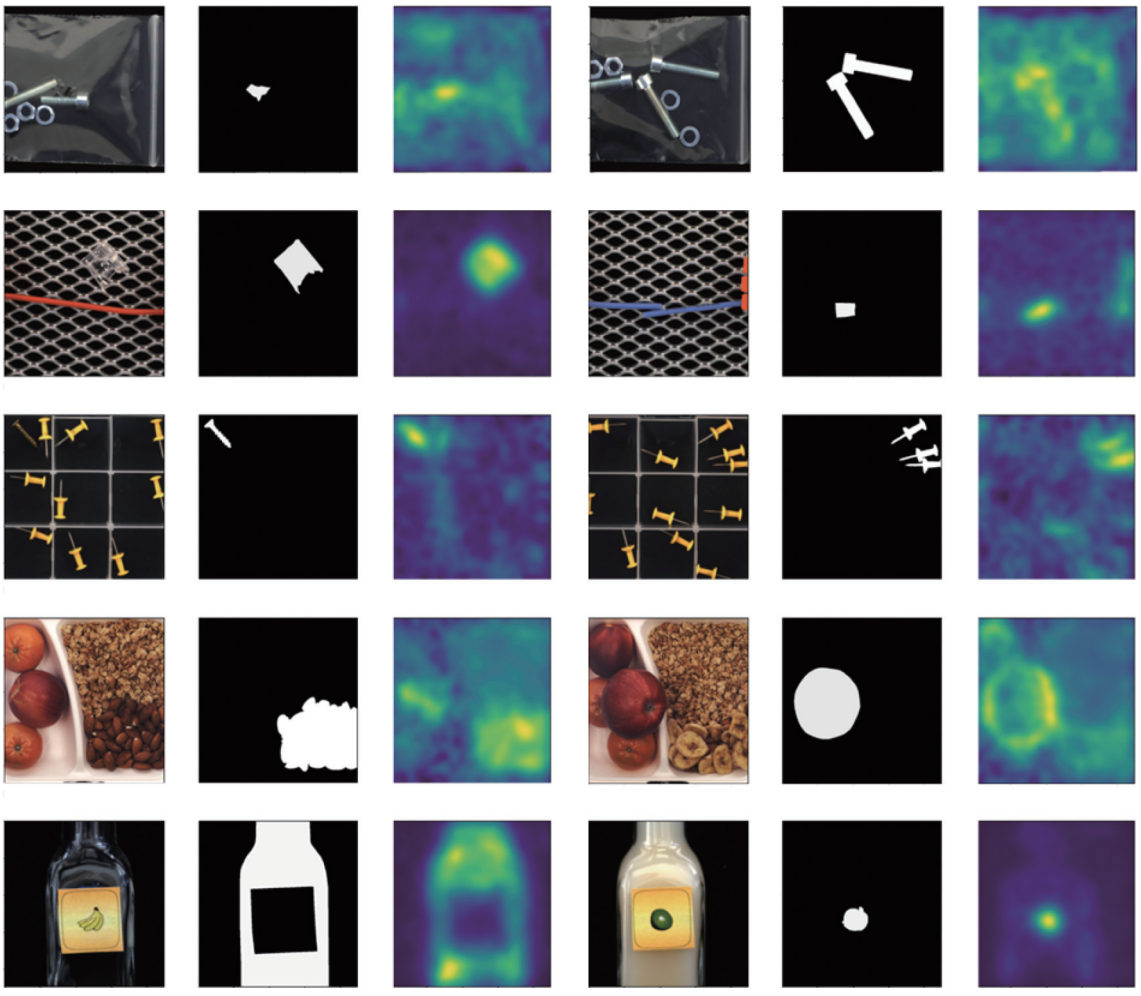

图 8 检测结果

Fig.8 Test results

提升了 2%，相对于 PatchCore 分别提升了 5.1%，3.7%。综上所述，改进后的 PatchCore 算法性能要优于 PatchCore，具有更好的鲁棒性。

表 4 消融实验结果

Tab.4 Results of ablation experiment

实验序号	改进1	改进2	图像级AUROC	异常像素级AUROC
1			0.825	0.823
2	√		0.868	0.84
3		√	0.815	0.812
4	√	√	0.876	0.860

3 结 论

本文以 PatchCore 算法作为基线，针对算法中的核心集降采样策略容易陷入局部最优解的问题，引入 K-means 算法作为降采样算法来解决这个问题。为了避免欧式距离作为衡量指标，可能存在对特征向量中的轻微噪声敏感的问题，使用余弦相似度来衡量特征之间的相似程度。在 MVTecAD 数据集和 MVTec LOCO AD 数据集进行实验论证，最后在 PatchCore 算法的基础上，图像级 AUROC 提升了 5.1%，异常像素级 AUROC 提升了 3.7%。证明改良后的算法具有良好的鲁棒性。在后续的研究中，可以利用一些样本增强方法来加强预训练网络的特征提取能力。

参考文献：

[1] BERGMANN P, BATZNER K, FAUSER M, et al. Beyond dents and scratches: logical constraints in unsupervised anomaly detection and localization[J]. International Journal of Computer Vision, 2022, 130(4): 947–969.

[2] BERGMANNP, FAUSER M, SATTLEGGER D, et al. MVTec AD-A comprehensive real-world dataset for unsupervised anomaly detection[C]//32nd IEEE/CVF Conference on Computer Vision and Pattern Recognition

(CVPR). Long Beach: IEEE, 2019: 9584–9592.
[3] 张玥, 王世豪, 李英健, 等. 基于 U 型注意力门自编码器的色织物缺陷检测方法 [J]. 光电子·激光, 2024, 35(8): 851−860.
[4] XU W H, FAZEL M, DU S S. Toward global convergence of gradient EM for over-parameterized gaussian mixture models[J/OL]. [2024-06-29]. https://doi.org/10.48550/arXiv.2407.00490.
[5] NAKAGAWA N, TOGO R, OGAWA T, et al. Gromov-Wasserstein autoencoders[C]//11th International Conference on Learning Representations. Kigali: OpenReview. net, 2023.
[6] FRÜHSTÜCK A, SINGH K K, SHECHTMAN E, et al. InsetGAN for full-body image generation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 7713–7722.
[7] LEI J R, HU X B, WANG Y, et al. PyramidFLow: high-resolution defect contrastive localization using pyramid normalizing flow[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023: 14143–14152.
[8] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami: IEEE, 2009: 248–255.
[9] COHEN N, HOSHEN Y. Sub-image anomaly detection with deep pyramid correspondences[J/OL]. [2020-05-05]. https://doi.org/10.48550/arXiv.2005.02357.
[10] DEFARD T, SETKOV A, LOESCH A, et al. PaDiM: a patch distribution modeling framework for anomaly detection and localization[C]//25th International Conference on Pattern Recognition. Milan: Springer, 2021: 475–489.
[11] RIPPEL O, MERTENS P, MERHOF D. Modeling the distribution of normal data in pre-trained deep features for anomaly detection[C]//2020 25th International Conference on Pattern Recognition (ICPR). Milan: IEEE, 2021: 6726–6733.
[12] BANG G, CHOI K, KIM J, et al. RadarDistill: boosting radar-based object detection performance via knowledge distillation from LiDAR features[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024: 15491–15500.
[13] SALEHI M, SADJADI N, BASELIZADEH S, et al. Multiresolution knowledge distillation for anomaly detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 14897–14907.
[14] ROTH K, PEMULA L, ZEPEDA J, et al. Towards total recall in industrial anomaly detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022: 14298–14308.
[15] ZAGORUYKO S, KOMODAKIS N. Wide residual networks[C]//Proceedings of the British Machine Vision Conference 2016. York: BMVA Press, 2016.

（编辑：董　伟）