

# 注意力残差块引导的师生网络 色织物缺陷检测算法

张 玥, 刘帅波, 张思怡, 吴天禧  
(西安工程大学 电子信息学院, 西安 710048)

**摘要:** 针对传统色织物缺陷检测重构模型存在难以保证缺陷区域的重构效果、漏检和误检率偏高等问题, 提出一种注意力残差块引导的无监督师生网络色织物缺陷检测算法; 从知识蒸馏角度出发, 基于 Wide\_Resnet50\_2 网络设计一种具有编码-解码结构的教师-学生模型, 学生网络通过恢复经过预训练的教师网络的多尺度特征增强重构能力; 提出一种融合双重注意力的残差模块 DARM, 对特征信息进行双重权重分配的方式可以去除教师网络输出的冗余信息, 进一步扩大师生网络之间对于缺陷区域的表征差异, 提升模型的缺陷检测与定位能力; 实验结果表明, 提出的算法在 YDFID-1 数据集上 AUPRO 达到了 85.8%、像素级 AUROC 和图像级 AUROC 分别达到了 96.3% 和 98.3%; 在少样本条件设置下, 提出的算法在 MVTec 数据集上 AUPRO 和 AUROC 下降不超过 4.5%, 实验结果验证了该算法处理色织物缺陷检测问题的有效性以及稳定性。

**关键词:** 图像处理; 色织物; 缺陷检测; 注意力机制; 知识蒸馏

## Teacher-student Network Yarn-dyed Fabric Defect Detection Based on Attention Residual Block Guidance

ZHANG Yue, LIU Shuaibo, ZHANG Siyi, WU Tianxi

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

**Abstract:** Aiming at traditional yarn-dyed fabric defect detection reconstruction models, there are problems such as difficulty to ensure the reconstruction effect of defective regions, missed detection and high false detection rate, an unsupervised teacher-student network yarn-dyed fabric defect detection algorithm based on attention residual block guidance is proposed. Firstly, from the perspective of knowledge distillation, a teacher-student model with encoding-decoding structure based on Wide\_Resnet50\_2 network is designed, and the student network enhances the reconstruction capability by recovering the multi-scale features of pre-trained teacher network. Secondly, a dual attention residual module (DARM) is proposed to incorporate the dual attention, remove the teacher network output redundant information in the dual weight assignment mode of feature information, further expand the representation differences of defective regions between the teacher-student networks, and improve the defect detection and localization ability of the model. The experimental results show that the AUPRO of the proposed algorithm reaches by 85.8%, the pixel-level AUROC by 96.3%, and the image-level AUROC by 98.3% on the YDFID-1 dataset, the AUPRO and AUROC of the proposed algorithm decrease by no more than 4.5% on the MVTec dataset under few sample conditions, the experimental results verify that the algorithm has the effectiveness and stability of dealing with color fabric defect detection.

**Keywords:** image processing; yarn-dyed fabric; fabric defect detection; attention mechanism; knowledge distillation

## 0 引言

色织物在人们的生活中随处可见, 其丰富的色彩造就了风格迥异的各类产品, 极大地满足了人们对于织物产品的需求。随着工业自动化技术的不断发展, 传统制造业的生产方式发生变革, 色织物的质量也渐渐成为衡量其经济价值的重要指标。但在色织物生产过程中, 往往会受到各种不稳定因素的影响, 如机械设备故障、断纱和人工操作

不当等, 从而造成织物表面出现松经、断纬和纱结等缺陷, 这将直接影响色织物产品整体质量<sup>[1]</sup>。

织物缺陷检测是纺织制造业相关领域至关重要的研究方向之一。以往大多数生产企业采用原始的人工目测方法来进行织物缺陷检测, 在一定程度上对简单背景, 花色单一的织物有效。但随着织物花型、色彩越来越复杂, 人工易疲劳、主观性判断等客观因素影响不可避免会导致缺陷检测效率低, 出现误检和漏检现象<sup>[2-3]</sup>。因此, 基于传统机

收稿日期: 2023-10-23; 修回日期: 2023-11-27。

基金项目: 国家自然科学基金(61803292); 纺织工业联合会科技指导性项目(2020111); 西安工程大学研究生创新基金项目(chx2023011)。

作者简介: 张 玥(1990-), 女, 硕士, 工程师。

通讯作者: 刘帅波(2001-), 男, 硕士。

引用格式: 张 玥, 刘帅波, 张思怡, 等. 注意力残差块引导的师生网络色织物缺陷检测算法[J]. 计算机测量与控制, 2024, 32(5): 80-87.

器视觉方法、有监督深度学习方法和无监督深度学习方法的自动化织物缺陷检测技术开始快速发展<sup>[4-8]</sup>。

传统缺陷检测算法分为四大类: 统计算法、结构算法、频谱算法和基于模型的算法<sup>[9]</sup>。其中, 统计方法<sup>[10-11]</sup>使用各种表征描述纹理图像来定义灰度值的空间分布, 当织物图像中存在较大的疵点时, 该类方法往往处理效果较差。文献 [10] 利用图像的极值点密度图并结合形态学处理实现织物缺陷检测。文献 [11] 通过利用变异系数对织物图像缺陷部分进行识别。结构算法<sup>[12]</sup>通过对正常图像进行特征建模, 学习其纹理分布规则, 进而识别缺陷, 但当织物图像不具备规律性的纹理背景时, 其检测效果总是不尽人意。傅里叶变换<sup>[13]</sup>、Gabor 变换<sup>[14]</sup>和小波变换<sup>[15]</sup>是频谱算法的主要方法, 它们大多在频域中提取纹理特征。频谱算法通过设计滤波器来滤除纹理背景以实现缺陷识别的目的, 但这种操作通常会提升模型的计算复杂度。模型方法<sup>[16]</sup>通过将纹理图像图案化, 根据图案特征分布进行建模表示, 该方法适用于检测明显的或者复杂的缺陷区域, 对于小型缺陷并不敏感。总之, 基于传统机器视觉的织物缺陷检测方法主要依靠手工设计提取特征, 有限的特征识别能力往往会阻碍其缺陷检测性能。

近年来, 有监督的缺陷检测方法逐渐在深度学习领域崭露头角。文献 [17] 提出基于 Fisher 准则的堆叠去噪自编码器, 该方法利用少量缺陷样本微调网络参数, 并通过与训练正常样本的无监督方式结合有效地提高了织物缺陷的检测精度。文献 [18] 提出了一种称为先验锚卷积神经网络 (PRAN, priori anchor convolutional neural network) 的缺陷检测算法, 首先利用特征金字塔网络 (FPN, feature pyramid network) 来保留更详细的微小缺陷信息, 然后基于真值框生成稀疏先验锚, 以实现更加准确、高效地定位极端缺陷。文献 [19] 提出了一种去变形缺陷检测网络 (D4Net), 该模型通过选择最合适的参考并与输入图像配对, 然后将其发送到去变形网络, 用于在给定的图像及其对应的参考图像中检测具有变形的非刚性产品的缺陷。文献 [20] 提出了一个自我监督的表示学习模型, 通过利用标记和未标记的数据有效地解决了标记样本稀缺的限制, 该模型基于对比学习框架进行改进, 利用到了增强管道和轻量级卷积编码器。文献 [21] 提出了一种简单直观的自然合成异常 (NSA, natural synthetic anomalies) 方法, 用于仅使用正常训练数据训练缺陷检测和定位的端到端模型。NSA 集成了泊松图像编辑功能, 可无缝混合来自不同图像的各种大小的缩放斑块, 与以往用于监督缺陷检测的数据增量策略相比, 这种方法能产生与自然子图像不规则性更相似的各种合成异常。但是, 在各种工业场景下, 缺陷样本的数量不足以支持有监督深度学习方法的训练学习, 因此, 有监督的织物缺陷检测方法的性能与发展受到了很大的限制<sup>[22]</sup>。

目前, 无监督深度学习已经成为缺陷检测领域重要的研究方向之一<sup>[23-24]</sup>。文献 [25] 提出了一种新型的无监督

高频特征映射模型 (HFFMM, high-frequency feature mapping model)。首先, 设计了一个多尺度高频信息提取模块用于捕捉疵点图像中丰富的高频信息, 并使用查询键注意力模块获得融合映射矩阵, 最后, 通过比较映射矩阵转换后的两个特征实现缺陷检测。文献 [26] 提出了一种基于多尺度去噪卷积自编码器 (MSCDAE, multiscale convolutional denoising auto-encoder) 的无监督织物缺陷检测方法, 训练阶段, 模型具备提取织物特征并重构织物图像的能力, 测试阶段, 由于缺陷处的特征与正常织物的特征不同, 因此模型并不能够重构缺陷处的图像, 该方法通过对比较模型输出的多尺度重构图与输入图像之间的像素级差异实现织物缺陷检测。文献 [27] 提出了一种基于变分自编码器 (VAE-L2SSIM, variational auto-encoder-L2 structural similarity) 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, 满足了织物疵点检测的实时计算需求。与 VAE-L2SSIM 不同的是 AE-L2SSIM 采用经典的卷积自编码器作为模型框架。文献 [28] 提出了一种基于 U 形去噪卷积自编码器 (UDCAE, u-shaped denoising convolutional auto-encoder) 的无监督织物缺陷检测方法。该方法使用跳跃连接辅助图像重构, 以实现色织衬衫裁片的缺陷检测和定位。但跳跃操作有可能将缺陷信息引入解码器, 不利于将其缺陷区域修复为正常, 从而导致缺陷检测失败。

知识蒸馏概念首次被文献 [29] 提出, 它以“教师—学生”网络的知识迁移思想为基础实现知识在师生 (T-S, teacher-student) 对中进行传递, 知识迁移是通过使用复杂的教师网络诱导简单的学生网络训练来实现的<sup>[30]</sup>。被称为知识蒸馏的学生—教师框架在缺陷检测任务中已被证明是有效的<sup>[31-32]</sup>。在该框架中, 教师网络在大规模数据集上进行预训练, 学生网络在仅使用正常样本的数据集上模拟教师网络的特征表示。主要假设是, 学生网络在训练阶段只学习正常样本, 当其表征异常时, 可能会和教师网络生成不一致的表示。因此, 在推理阶段可以识别出异常像素和图像。这为知识蒸馏方法实现缺陷检测提供了理论基础。

本文从知识蒸馏的角度来改善以往重构方法中图像重构模糊、缺陷区域难以去除等问题, 研究一种性能更优的无监督织物缺陷检测方法。相比较于以往的缺陷检测方法, 知识蒸馏在网络特征层面建立损失计算, 使模型更加关注于图像细节的学习。主要工作概述如下:

- 1) 针对以往重构方法难以保证将缺陷区域重构为正常区域的问题, 从知识蒸馏的角度出发提出一个基于注意力残差块引导的无监督师生网络框架。

- 2) 提出了双重注意力残差模块 (DARM, dual attention residual module), 通过去除教师网络输出的高维冗余信息, 提升学生网络对正常特征的恢复能力。

- 3) 所提方法不需要任何缺陷样本的标注信息, 同时在训练阶段只需要少数正常样本便可以实现较好的缺陷检测性能, 可以方便快速部署到实际工业场景中。

4) 实验结果表明, 与其它几种无监督织物缺陷检测算法性能对比, 所提方法性能最优。

## 1 色织物缺陷检测方法

### 1.1 注意力残差块引导的师生模型

本文提出一个基于注意力残差块引导的无监督师生网络框架来实现色织物缺陷检测与定位。如图 1 所示, 所提方法使用新型蒸馏框架, 使得教师编码器网络和学生解码器网络对于缺陷区域的表征高度不同, 同时通过利用双重注意力残差模块的双重权重分配机制进一步加大了师生网络之间对于缺陷区域的表征差异, 这为模型的缺陷检测与定位能力提供了保证。

注意力残差块引导的无监督师生网络框架由教师编码器  $E$ 、特征融合模块 (FFM, feature fusion module)、双重注意力残差模块 DARM、学生解码器  $D$  组成。

模型中成对的激活对应关系如式 (1) 和式 (2) 所示:

$$f'_E = E^l(I) \quad (1)$$

$$f'_D = D^l(\varphi') \quad (2)$$

其中:  $E^l$ 、 $D^l$  分别表示教师网络的第  $l$  个编码块和第  $l$  个解码块,  $I \in R^{H \times W \times C}$  表示无缺陷的输入图像,  $\varphi'$  为经过 DARM 作用后的紧密特征输出, 且作为学生网络特征重建的输入向量,  $f'_E$ 、 $f'_D$  分别为第  $l$  个编码块和解码块对应的特征图输出, 且  $f'_E$ 、 $f'_D \in R^{H_l \times W_l \times C_l}$ ,  $H_l$ 、 $W_l$  和  $C_l$  分别表示第  $l$  个特征图的高度、宽度和通道数。

将在 ImageNet<sup>[33]</sup> 上经过预训练的 Wide\_Resnet50\_2<sup>[34]</sup> 作为教师编码器网络的骨干。更宽的残差网络具有强大的特征提取能力, 这有助于对输入图像  $I$  的特征进行完美表征, 同时在训练过程中对教师  $E$  的所有参数进行冻结。不

同于传统蒸馏, 本文所提方法在训练阶段, 输入图像只作为教师编码器的输入, 因此知识蒸馏将从教师的深层开始。学生解码器直接利用高级表示对低级特征进行重建是非常具有挑战性的。以往的数据重建工作通常会采用跳接方法来连接编码器和解码器。然而, 跳接操作存在着向学生泄漏缺陷信息的问题。

特征融合模块 (FFM) 通过对包含不同层级语义信息的特征图进行融合, 解决了学生解码器  $D$  的低层特征恢复问题。为了便于特征拼接, 采用一个或多个步长为 2 的  $3 \times 3$  卷积层对浅层特征进行下采样, 然后进行批量归一化和 ReLU 激活操作。如图 1 所示, 左侧绿线所示代表两个  $3 \times 3$  卷积操作, 黄线代表一个  $3 \times 3$  卷积操作。最后利用步长为 1 的  $1 \times 1$  卷积层和带 ReLU 激活的批量归一化来获得丰富而紧凑的特征  $\varphi$ 。DARM 通过将教师模型的高维输出表示  $\varphi$  浓缩为紧密的特征嵌入  $\varphi'$  实现去除冗余信息。知识蒸馏方法中的教师模型虽然可以提取丰富的特征, 但获得的高维描述符可能存在相当大的冗余。而信息冗余不利于学生模型解码基本的无缺陷特征。DARM 采用 ResNet<sup>[35]</sup> 的第四残差块作为基础块。首先经过基于能量函数构建的注意力 SimAM<sup>[36]</sup> 对输入信息  $\varphi$  进行 3D 注意权重分配, 然后使用经典的通道注意力压缩-激励 (SE, squeeze-excitation) 模块<sup>[37]</sup> 在通道层面再一次进行特征权重分配, 使得模型可以专注于学习重要特征, 达到去除冗余信息的效果。这为学生网络从高层到底层有效解码教师信息提供了强有力的帮助, 有效缓解了以往重构方法难以去除缺陷区域的问题。

尽管简单的学生网络可能加强了与教师网络之间对于缺陷表征的差异, 但是浅层架构较弱的表示能力会影响到模型对于缺陷的精确检测和定位。同时, 为了匹配教师编码器  $E$  的中间表示, 学生解码器  $D$  采用与教师编码器  $E$  相反的结构, 均采用 Wide\_Resnet50\_2 作为网络骨干。学生解码器的目标是模仿训练期间教师网络的表现, 为此, 本模型探究了多尺度特征下的缺陷检测蒸馏。神经网络的浅层提取的特征包含更多的像素点的信息, 如边缘, 颜色等信息。而深层网络随着感受野的增加, 会获取图像整体性的一些语义信息。局部缺陷和全局缺陷分别由教师和学生低层和高层特征的低相似性表示。

#### 1.1.1 损失函数

采用余弦相似性作为知识蒸馏 (KD, knowledge distillation) 过程的蒸馏损失, 它可以精确地对高维和低维信息中的关系进行捕获。首先, 沿着通道轴计算特征张量  $f'_E$  和  $f'_D$  的矢量余弦相似性损失, 并获得二维异常图  $M^l \in R^{H_l \times W_l}$ ,  $M^l$  中值越大代表异常得分越高, 如式 (3) 所示:

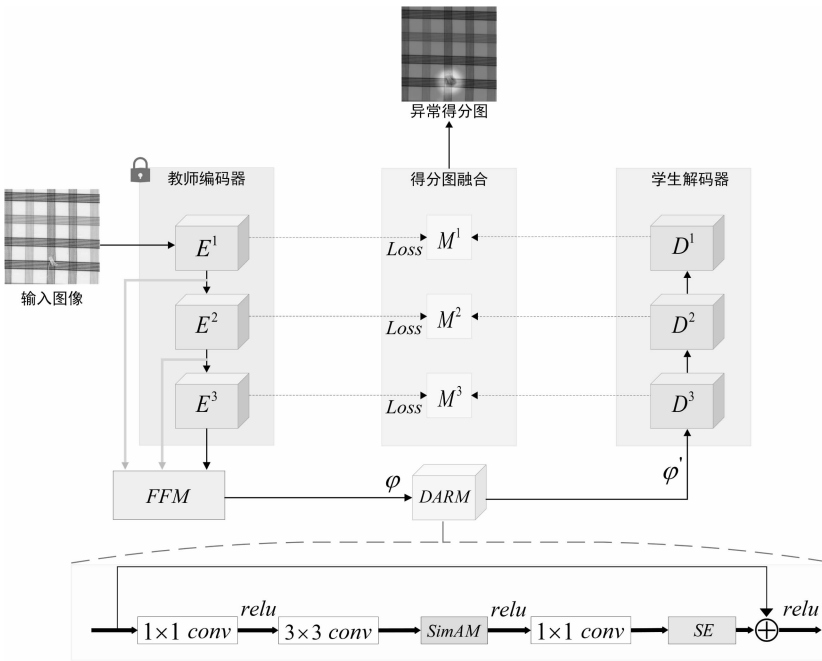


图 1 师生网络结构图

$$M^l(h, \omega) = 1 - \frac{(f'_E(h, \omega))^T \cdot f'_D(h, \omega)}{\|f'_E(h, \omega)\| \|f'_D(h, \omega)\|} \quad (3)$$

由于神经网络的浅层和深层的关注点并不一致, 故在本文考虑了多尺度的知识提取, 通过累加多尺度的异常图, 得到了实际蒸馏阶段的目标函数  $L_{KD}$ , 如式 (4) 所示:

$$L_{KD} = \sum_{l=1}^L \left\{ \frac{1}{H_l W_l} \sum_{h=1}^{H_l} \sum_{w=1}^{W_l} M^l(h, \omega) \right\} \quad (4)$$

式中,  $L$  表示在实验中使用的特征总层数。在特征层面进行的多层级训练部署可以保证模型对图像细节的信息提取能力, 有效缓解了以往重构方法中重构图像模糊问题。

### 1.1.2 DRAM 模块

DARM 模块是实现缺陷精确检测与定位的关键。随着网络层次的不断加深, 神经网络提取到的图片信息会越来越丰富, 同时往往会夹杂与模型所需重要特征无关的冗余信息。而受人脑注意力启发而诞生的注意力机制可以有效缓解这个问题。不同于以往的注意力机制使用方式, 本文所提方法在 ResNet 残差块中采用一种全新的 3D 注意力 SimAM<sup>[36]</sup>和通道注意力 SE<sup>[37]</sup>结合的方式, 实现了对特征信息的双重权重分配。

注意力模块在计算机视觉任务的应用中往往侧重于通道域或空间域, 然而这两种机制往往是共存的, 这大大的限制了学习注意力权重的灵活性。尽管一些研究者尝试将空间域注意力与通道注意力进行并行或串行组合, 但这也并未在实质意义上实现二者之间的协同作用。而基于能量函数构建的 SimAM 注意力模块可以有效生成真实的三维权重, 并获取每一个神经元的重要性。同时该模块具有无参性, 且不会给网络增加额外的计算负担。因此在提出的方法中引入了 SimAM 模块。

在神经网络的深层中, 提取越来越精细的特征信息对模型的性能提出了很大挑战。此外, 由于所提方法采用沿着通道轴计算特征张量之间余弦相似性损失的方法来定位缺陷。而 SE 注意力模块能够赋予特征图中的每个特征通道不同的权值, 它针对通道维度的优越性能使得模型能够专注于学习重要特征, 因此在提出的方法中引入 SE 模块。DARM 模块整体的数据流可以简要的表示为公式 (5):

$$\varphi' = \text{Relu}\{\text{SE}[\text{SimAM}(\varphi)]\} \quad (5)$$

式中,  $\varphi$  表示经特征融合模块作用后的高维特征嵌入,  $\varphi'$  表示经双重注意力残差模块作用去除冗余信息后的特征嵌入。提出的 DARM 模块保证了学生网络对正常特征的恢复能力, 有效缓解了以往重构方法无法保证去除缺陷区域的问题。

### 1.2 色织物缺陷检测

在缺陷检测阶段, 输入缺陷样本, 教师网络可以表征输入样本中的缺陷区域特征。但学生解码器只会从 DARM 得到的紧密特征嵌入  $\varphi'$  中恢复无缺陷特征表示。因此, 当缺陷被查询时, 学生网络就会生成与教师网络不一致的表示。如公式 (3) 所示, 在所提出的方法中根据教师模型和学生模型不同的表示, 得到了一组异常图  $M^l$ ,  $M^l$  中的值大小反映了第 1 个特征张量的逐点异常情况。同时, 为了更加

精确的查询定位到缺陷, 本研究使用双线性插值法将  $M^l$  上采样到原始图像大小, 并通过将所有  $M^l$  进行逐像素累加得到最终异常得分图, 如式 (6) 所示:

$$M_{\text{score}} = \sum_{l=1}^L \Psi(M^l) \quad (6)$$

式中,  $\Psi$  表示双线性插值上采样步骤。同时, 使用高斯滤波器对  $M_{\text{score}}$  进行平滑处理, 达到去除噪声的目的。由于对于任何缺陷样本来说, 无论缺陷区域的大小, 其都会存在一个响应最强的点, 为此, 本研究将  $M_{\text{score}}$  中的最大值定义为样本级别的异常得分。

## 2 实验

### 2.1 实验环境

实验环境详细配置如下。硬件配置: 中央处理器为 Intel (R) Core (TM) i7-6850K CPU @ 3.60 GHz; 显卡为 GeForce RTX 3090 (24 G); 内存为 128 GBs。软件配置: 操作系统为 Ubuntu 18.04.5 LTS; 软件环境基于 Anaconda3 和 Python3.8.13; 深度学习框架为 PyTorch1.7.1。模型训练时, 设置批大小为 32, 训练轮数为 200, 学习率为 0.005。

### 2.2 实验数据集

YDFID-1<sup>[38]</sup>数据集由 3 501 张不同花型的彩色纹理织物图像共同组成, 它包含 3 189 张无缺陷图像和 312 张缺陷图像, 所有图像分辨率大小均为  $512 \times 512 \times 3$ , 实验过程中所使用的图像输入大小均为  $256 \times 256 \times 3$ 。该数据集根据织物花型的复杂程度被分为简单格子 (SL, simple lattices)、复杂格子 (CL, complex lattices) 和条纹图案 (SP, stripe patterns) 等三大类。本文采用了 YDFID-1 数据集中的 9 种花型来进行算法的验证和对比, 训练阶段使用每种花型数据集的无缺陷样本, 测试阶段使用与其对应的缺陷样本。实验所用 9 种花型名称分别为 CL6、CL13、CL20、SL1、SL13、SL14、SP15、SP20 和 SP22。所使用的部分 YDFID-1 数据集中有缺陷和无缺陷的详细样本数目如表 1 所示。数据集的部分花型如图 2 所示, 每个类别的第一行均表示无缺陷图像, 第二行表示缺陷图像。

表 1 YDFID-1 部分数据集有缺陷和无缺陷样本数目分布

花型	CL6	CL13	CL20	SL1	SL13	SL14	SP15	SP20	SP22
正常样本数	138	148	107	482	309	179	174	125	29
缺陷样本数	6	11	42	15	22	13	8	19	12

MVTec<sup>[39]</sup>数据集由 5 354 张不同目标和纹理类型的彩色真实图像组成, 它包含 5 种纹理类型和 10 种物体类型等 15 类高分辨图像, 并且涉及高达 73 种缺陷类型。该数据集包含用于训练的 3 629 张无缺陷图像, 以及用于测试的 1 725 张图像 (测试集包括 1 258 张缺陷图像和 467 张无缺陷图像), 所有图像的尺寸在  $700 \times 700 \sim 1\,024 \times 1\,024$  之间。在本实验中, 选择网格, 地毯, 皮革, 瓷砖, 木材等五类纹理数据集作为实验对象, 有缺陷和无缺陷的详细样本数目如表 2 所示。

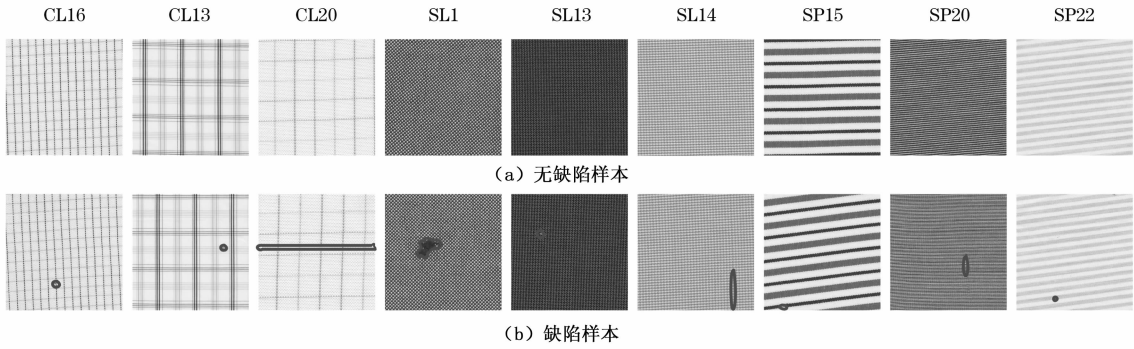


图 2 YDFID-1 数据集部分花型

表 2 MVTec 纹理类数据集有缺陷和无缺陷样本数目分布

类别	网格	地毯	皮革	瓷砖	木材
正常样本数	264	280	245	230	247
缺陷样本数	57	89	92	84	60

### 2.3 评价指标

经典的评价指标包括召回率 (Recall), 假正率 (FPR, false positive rate) 和真阳性率 (TPR, true positive rate), 这些评价指标的定义如式 (7) ~ (9) 所示:

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

$$FPR = \frac{FP}{TN + FP} \quad (8)$$

$$TPR = \frac{TP}{TP + FN} \quad (9)$$

其中:  $TP$  表示缺陷区域中缺陷被成功检测出的像素数;  $TN$  表示正常区域中被正确检测出正常的像素数;  $FP$  表示正常区域中被错误检测为缺陷的像素数;  $FN$  表示缺陷区域被检测为正常的像素数。

在本研究中, 使用 AUROC 和 AUPRO 来评估模型对于彩色纹理织物缺陷的检测与定位能力<sup>[39]</sup>。其中, AUROC 是 ROC 曲线下的面积, ROC 曲线衡量 Recall 和 FPR 之间的权衡, ROC 曲线又称接收者操作特征曲线, 该曲线有两个维度, 横轴为 FPR, 纵轴为 TPR; 而 AUPRO 与 TPR 密

切相关。

### 2.4 实验结果及分析

分别在 YDFID-1 数据集上对 MSCDAE、AE (L2SSIM)、VAE (L2SSIM) 和本文所提方法进行对比, 并进行定量分析和定性分析。

#### 2.4.1 缺陷检测结果定量分析

4 种方法在公共数据集 YDFID-1 上的缺陷检测与定位性能如表 3 所示。图像级 AUROC 用来评价模型的缺陷检测性能, 像素级 AUROC 和 AUPRO 用来评价模型的缺陷定位性能。所提方法的图像级 AUROC 值达到了 98.3%, 这比 MSCDAE 的检测结果提高了 20.6%。然而与 VAE (L2SSIM) 相比较而言, 评价指标值仅低了 0.4%。研究发现, 大多数模型在图像级 AUROC 值上都能得到一个近乎完美的表现, 而实际的缺陷检测效果并不一定和图像级 AUROC 值成正比, 类似的结论在文献 [40] 的研究中也给出。此外, 所提方法的像素级 AUROC 值达到了 96.3%, 这比 MSCDAE 的定位性能提高了 14.4%, 而 AUPRO 值达到了 85.8%, 比 MSCDAE 的定位结果提高了 21.4%。实验结果表明, 本文所提算法检测性能最优。

#### 2.4.2 缺陷检测结果定性分析

图 3 为 4 种模型在 YDFID-1 数据集中的部分缺陷定位热力图对比结果。从图中可以看出, 本文所提方法实现了最好的缺陷检测与定位性能。在 SL13 花型中存在地块状集

表 3 YDFID-1 数据集上 4 种方法的缺陷检测与定位性能对比

指标	算法	CL6	CL13	CL20	SL1	SL13	SL14	SP15	SP20	SP22	平均值
图像级 AUROC	MSCDAE	94.2	58.2	43.0	98.9	90.1	96.7	70.1	73.3	74.7	77.7
	AE(L2SSIM)	96.7	100	99.4	98.6	90.8	99.0	90.6	98.4	97.4	96.8
	VAE(L2SSIM)	99.2	100	99.6	99.1	99.8	99.6	91.4	100	100	98.7
	Ours	99.3	97.2	99.6	95.7	100	99.7	97.6	95.3	100	98.3
像素级 AUROC	MSCDAE	99.1	77.3	38.9	98.0	99.4	85.5	85.5	73.3	80.1	81.9
	AE(L2SSIM)	98.6	97.6	85.2	99.3	96.4	94.8	79.8	89.9	91.3	92.5
	VAE(L2SSIM)	99.2	97.0	83.6	99.3	96.3	96.8	95.9	92.2	88.8	94.3
	Ours	99.9	98.2	97.5	97.8	99.8	95.5	96.9	96.7	84.3	96.3
AUPRO	MSCDAE	97.3	37.5	20.1	95.4	97.5	74.8	65.1	33.0	58.6	64.4
	AE(L2SSIM)	95.2	93.1	67.3	98.5	82.5	90.2	51.0	59.2	66.1	78.1
	VAE(L2SSIM)	97.3	91.0	64.6	98.0	90.1	88.8	86.5	76.0	60.3	83.6
	Ours	92.3	80.2	89.6	88.1	98.6	90.4	79.7	79.4	73.9	85.8




图 3 4 种方法在部分 YDFID-1 数据集中的缺陷定位对比

中缺陷区域定位中, MSCDAE 模型和 AE (L2SSIM) 模型都出现了明显的漏检现象, 而 VAE (L2SSIM) 模型几乎没有准确地将缺陷检测出来。

对于 SL14 花型和 SP15 花型中存在的长横条型缺陷, 虽然 MSCDAE 模型可以基本检测出缺陷区域, 但却伴随着大量地过检, 而 AE (L2SSIM) 和 VAE (L2SSIM) 几乎无法定位到这类缺陷。对于 CL13、CL20 和 SP20 花型中存在的小缺陷, MSCDAE、AE (L2SSIM)、VAE (L2SSIM) 表现出较差的检测性能。实验结果表明, 本文提出的师生网络有效避免了过检和漏检情况的发生, 实现了更加精确的缺陷检测性能。

#### 2.4.3 消融实验

本文提出了一种基于 SimAM 和 SE 双重注意力组成的

双重注意力残差模块 (DARM)。为了验证这种新颖的双重注意力机制对于模型性能的有效性, 在 YDFID-1 数据集中的九种花型上进行相关消融研究。实验结果如表 4 所示。

从表 4 中可以发现, 在加入 SimAM 注意力后, 用于表征缺陷定位性能的 AUPRO 的值提升了 1.7%, 并且用来表征缺陷检测性能的图像级 AUROC 的值提升了 2.5%; 当只有 SE 注意力机制被使用时, 图像级 AUROC 值、像素级 AUROC 值和 AUPRO 值分别提升了 3.7%, 0.3% 和 3.6%。当顺序融合 SimAM 和 SE 注意力机制, 用于表征缺陷定位性能的 AUPRO 值提升了 4.2%, 像素级 AUROC 值提升了 0.7%, 用来表征缺陷检测性能的图像级 AUROC 值提升了 5.7%。实验结果表明, 本文提出的双重注意力残差模块能够通过 SimAM 注意力来获取每一个神经元的重要性。

使用 SE 注意力重新关注通道学习的操作使得模型更加关注于学习重要特征。通过对特征信息进行顺序双重权重分配可以有效去除冗余信息，显著提高了模型的色织物缺陷检测性能。

表 4 SimAM 和 SE 对模型性能影响的消融研究

SimAM	SE	图像级 AUROC	像素级 AUROC	AUPRO
—	—	92.6	95.6	81.6
✓	—	95.1	94.8	83.3
—	✓	96.3	95.9	85.2
✓	✓	98.3	96.3	85.8

### 2.4.4 Few-shot 性能研究

在仅具有少量训练数据的情况下进行缺陷检测性能研究已经成为计算机视觉任务的热门方向。少样本 (Few-shot) 训练意味着模型训练时计算量会大幅下降，这也是工业生产中一直追求的模型性能。为了验证所提方法的 Few-shot 特性以及其是否适用于其他类型纹理的缺陷检测，本研究在工业数据集 MVTEC<sup>[39]</sup> 上进行了相关实验，实验结果如表 5 所示。训练阶段所使用的正常样本均是随机挑选的，K 表示样本数量，迭代次数统一设置为 N=600。

表 5 MVTEC 纹理类数据集上 Few-shot 性能探究

指标	训练样本数	网格	地毯	皮革	瓷砖	木材	平均值
图像级 AUROC	K=*	97.6	99.2	100	99.1	98.9	99.0
	K=8	88.5	100	100	99.3	98.3	97.2(-1.8)
	K=4	75.1	100	100	99.4	98.2	94.5(-4.5)
像素级 AUROC	K=*	98.6	99.0	99.5	95.8	95.5	97.7
	K=8	90.5	99.2	99.5	94.5	95.2	95.8(-1.9)
	K=4	84.3	99.3	99.5	94.8	95.0	94.6(-3.1)
AUPRO	K=*	97.4	97.2	99.2	90.9	92.1	95.4
	K=8	91.8	97.5	99.1	88.3	92.5	93.8(-1.6)
	K=4	88.5	97.8	99.1	88.7	92.5	93.3(-2.1)

实验设置 3 个对照组来探究模型的 Few-shot 特性。K=\* 代表保持原数据集中的训练样本数不变，可以发现当 K=4 和 K=8 时，模型在 5 个纹理类数据上的平均评价指标都有小幅度的下降，但当 K=4 时，模型的图像级 AUROC 达到 94.5%，像素级 AUROC 达到 94.6%，AUPRO 达到 93.3%，与使用全部训练样本相比表现出相当的竞争性。实验结果表明，本文所提方法在工业场景下有着巨大的应用潜力。

### 3 结束语

本文提出一种新颖的基于注意力残差块引导的无监督师生网络色织物缺陷检测算法，从知识蒸馏的角度来改善以往的重构方法中图像重构模糊、缺陷区域难以去除的问题。首先，不同于传统蒸馏的编码—解码结构，本文的教师—学生网络采用编码—解码结构，通过利用编解码结构的重构性能进一步突出师生网络之间的缺陷表征差异。其次，在特征层面设置的多层级训练部署保证了模型对于图

像细节的信息提取能力，有效缓解了以往重构模糊问题。此外，双重注意力残差块通过去除教师网络输出的冗余信息保证了学生网络对正常特征的恢复能力，有效缓解了以往难以去除缺陷区域的问题。总之，与其它检测模型相比，所提出的织物缺陷检测方法具有优越的缺陷检测与定位性能，且在少样本设置的情况下依然具有较强的竞争力，可以为工业领域提供一个新颖且有效的自动缺陷检测方案。

### 参考文献:

- [1] KUMAR A. Computer-vision-based fabric defect detection: A survey [J]. IEEE Transactions on Industrial Electronics, 2008, 55 (1): 348-363.
- [2] 任梦凡, 朱磊, 马晓敏, 等. 基于粗糙度测量和颜色距离的织物缺陷检测方法 [J]. 激光与光电子学进展, 2021, 58 (4): 155-162.
- [3] NGAN H Y, PANG G K, YUNG N H. Automated fabric defect detection—a review [J]. Image and Vision Computing, 2011, 29 (7): 442-458.
- [4] 张雷, 李冰倩. 基于特征融合与注意力的织物缺陷检测研究 [J]. 电脑与信息技术, 2022, 30 (5): 5-8.
- [5] 苏泽斌, 武静威, 李鹏飞. 改进的 Faster R-CNN 算法在数码印花织物缺陷检测中的应用 [J]. 西安工程大学学报, 2022, 36 (4): 1-9.
- [6] 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.
- [7] 景军锋, 范晓婷, 李鹏飞, 等. 应用深度卷积神经网络的色织物缺陷检测 [J]. 纺织学报, 2017, 38 (2): 68-74.
- [8] 赵麟坤, 陈玉洁, 张玉井, 等. 基于改进的 Faster RCNN 碳纤维编织物缺陷检测 [J]. 棉纺织技术, 2023, 1 (2): 48-54.
- [9] LI C, LI J, LI Y, et al. Fabric defect detection in textile manufacturing: a survey of the state of the art [J]. Security and Communication Networks, 2021, 2021 (2): 1-13.
- [10] SONG L, LI R, CHEN S. Fabric defect detection based on membership degree of regions [J]. IEEE Access, 2020, 8 (1): 48752-48760.
- [11] KUMAR P S, HAFEDH H. Detection of defects in knitted fabric images using Eigen values [J]. International Journal Computer Science Engineering-IJASCSE, 2013, 2 (3): 7-10.
- [12] JIA L, LIANG J. Fabric defect inspection based on isotropic lattice segmentation [J]. Journal of the Franklin Institute, 2017, 354 (13): 5694-5738.
- [13] MALEK A S, DREAN J Y, BIGUE L, et al. Optimization of automated online fabric inspection by fast Fourier transform (FFT) and cross-correlation [J]. Textile Research Journal, 2013, 83 (3): 256-268.
- [14] JING J, Yang P, Li P, et al. Supervised defect detection on textile fabrics via optimal Gabor filter [J]. Journal of Industrial Textiles, 2014, 44 (1): 40-57.
- [15] YAPI D, ALLILI M S, BAAZIZ N. Automatic Fabric Defect

- Detection Using Learning-Based Local Textural Distributions in the Contourlet Domain [J]. *IEEE Transactions on Automation Science and Engineering*, 2018, 15 (3): 1014 - 1026.
- [16] SHU Y, ZHANG L, ZUO D, et al. Analysis of texture enhancement methods for the detection of eco-friendly textile fabric defects [J]. *Journal of Intelligent & Fuzzy Systems*, 2021, 41 (3): 4439 - 4449.
- [17] LI Y, ZHAO W, PAN J. Deformable patterned fabric defect detection with fisher criterion-based deep learning [J]. *IEEE Transactions on Automation Science and Engineering*, 2016, 14 (2): 1256 - 1264.
- [18] PENG P, WANG Y, HAO C, et al. Automatic fabric defect detection method using PRAN-net [J]. *Applied Sciences*, 2020, 10 (23): 8434.
- [19] XU X, CHEN J, ZHANG H, et al. D4Net: De-deformation defect detection network for non-rigid products with large patterns [J]. *Information Sciences*, 2021, 547: 763 - 776.
- [20] ZABIN M, KABIR A N B, KABIR M K, et al. Contrastive self-supervised representation learning framework for metal surface defect detection [J]. *Journal of Big Data*, 2023, 10 (1): 1 - 24.
- [21] SCHLÜTER H M, TAN J, HOU B, et al. Natural synthetic anomalies for self-supervised anomaly detection and localization [C] // 2022 European Conference on Computer Vision. Cham, Switzerland: ECCV, 2022: 474 - 489.
- [22] 黄媛媛, 熊文博, 张宏伟, 等. 基于U型Swin Transformer自编码器的色织物缺陷检测 [J]. *激光与光电子学进展*, 2023, 60 (12): 1 - 12.
- [23] PIRNAY J, CHAI K. Inpainting transformer for anomaly detection [C] // 2022 ICIAP; Proceedings of the 21st International Conference on Image Analysis and Processing. Lecce, New York: IEEE, 2022: 394 - 406.
- [24] ZHANG H W, QIAO G H, LU S, et al. Attention-based feature fusion generative adversarial network for yarn-dyed fabric defect detection [J]. *Textile Research Journal*, 2022, 93 (5): 1178 - 1195.
- [25] WAN D, GAO C, ZHOU J, et al. Unsupervised fabric defect detection with high-frequency feature mapping [J]. *Multimedia Tools and Applications*, 2023: 1 - 18.
- [26] MEI S, YANG H, YIN Z P. An unsupervised-learning-based approach for automated defect inspection on textured surfaces [J]. *IEEE Transactions on Instrumentation and Measurement*, 2018, 67 (6): 1266 - 1277.
- [27] WEI W, DENG D X, 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 Process*, 2021, 18 (3): 807 - 823.
- [28] 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.
- [29] HINTON G, VINYALS O, DEAN J. Distilling the knowl-  
edge in a neural network [J]. *Computer Science*, 2015, 14 (7): 38 - 39.
- [30] ADRIANA R, NICOLAS B, EBRAHIMI K S, et al. Fintnets: Hints for thin deep nets [C] // 2015 ICLR: Proceedings of the 3th International Conference on Learning Representations. San Diego, CA: ICLR, 2015: 1 - 12.
- [31] BERGMANN P, FAUSER M, SATTLEGGER D, et al. Uninformed students: Student-teacher anomaly detection with discriminative latent embeddings [C] // 2022 Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle, WA, USA: IEEE, 2020: 4183 - 4192.
- [32] SALEHI M, SADJADI N, BASELIZADEH S, et al. Multi-resolution knowledge distillation for anomaly detection [C] // 2021 Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Nashville, TN, USA: IEEE, 2021: 14902 - 14912.
- [33] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database [C] // 2009 CVPR: Proceedings of the 22th IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL, New York: IEEE, 2009: 248 - 255.
- [34] ALAEDDING H, JIHENE M. Wide deep residual networks in networks [J]. *Multimedia Tools and Applications*, 2023, 82 (5): 7889 - 7899.
- [35] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C] // CVPR 2016: Proceedings of the 29th IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, New York: IEEE, 2016: 770 - 778.
- [36] YANG L X, ZHANG R Y, LI L D, et al. Simam: a simple, parameter-free attention module for convolutional neural networks [C] // ICML 2021: Proceedings of the 38th International Conference on Machine Learning. United States, New York: ICML, 2021: 11853 - 11864.
- [37] HU J, SHEN L, SAMUEL A. Squeeze-and-excitation networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42 (8): 2011 - 2023.
- [38] ZHANG H W, MI H M, LU SH. Yarn-dyed fabric image dataset Version1 [EB/OL]. [2022 - 06 - 30]. <https://github.com/ZHW-AI/YDFID-1>.
- [39] BERGMANN P, FAUSER M, SATTLEGGER D, et al. MVTec AD-a comprehensive real-world dataset for unsupervised anomaly detection [C] // 2019 CVPR: 32th Conference on Computer Vision and Pattern Recognition. United States, New York: IEEE, 2019: 9584 - 9592.
- [40] ZOU Y, JRONG J, PEMULA L, et al. Spot-the-difference self-supervised pre-training for anomaly detection and segmentation [C] // 2022 ECCV: Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: ECCV, 2022: 392 - 408.