

基于 U 型 Swin Transformer 自编码器的色织物缺陷检测

黄媛媛¹, 熊文博¹, 张宏伟^{1,2*}, 张伟伟¹

¹西安工程大学电子信息学院, 陕西 西安 710048;

²浙江大学工业控制技术国家重点实验室, 浙江 杭州 310027

摘要 针对传统卷积神经网络对色织物花型缺陷检测效果不佳的问题, 提出一种基于 U 型 Swin Transformer 重构模型和残差分析的缺陷检测方法。该方法使用 Transformer 模型, 可更好地实现对图像全局特征的提取以及更准确的重构, 同时解决了实际生产过程中缺陷样本数量少且种类不平衡的问题。首先, 针对某种花型, 采用叠加噪声后的无缺陷样本完成重构模型的训练过程; 然后, 将待测图像输入模型中获得重构图像; 接着, 计算待测图像和重构图像的残差图像; 最后, 通过阈值分割和数学形态学处理, 即可实现对缺陷区域的检测和定位。实验结果表明, 该方法在不需要对缺陷样本标记的情况下, 能够有效地检测和定位多个色织物花型上的缺陷区域。

关键词 机器视觉; 图像处理; 色织物; 缺陷检测; 无监督学习; Swin Transformer

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP220691

Yarn-Dyed Fabric Defect Detection Based on U-Shaped Swin Transformer Auto-Encoder

Huang Yuanyuan¹, Xiong Wenbo¹, Zhang Hongwei^{1,2*}, Zhang Weiwei¹

¹School of Electronic Information, Xi'an Polytechnic University, Xi'an 710048, Shaanxi, China;

²State Key Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027, Zhejiang, China

Abstract Considering the non-effectiveness of traditional convolution neural networks in detecting pattern defects in yarn-dyed fabrics, a defect detection method based on a U-shaped Swin Transformer reconstruction model and residual analysis is proposed. This method uses the Transformer model to improve the extraction of global image features and enhance reconstruction while solving for the small number and unbalanced types of defective samples during the actual production process. First, the training process of the reconstructed model is completed for a certain pattern using the non-defective samples after adding noise. Subsequently, the test image is inputted into the model to obtain the reconstructed image, and its residual image and reconstructed image are calculated. Finally, the defect areas are detected and located via threshold segmentation and mathematical morphology processing. The results indicate that this method can be effectively used for the detection and location of defect areas on multiple yarn-dyed fabric patterns without requiring the marking of the defective samples.

Key words machine vision; image processing; yarn-dyed fabric; defect detection; unsupervised learning; Swin Transformer

1 引言

色织物花型美观多样, 其服装产品深受人们喜爱, 已成为我国出口创汇的重要产品之一^[1]。然而, 由于

织造设备故障和纱线问题等因素的影响, 织物表面会存在缺陷^[2], 缺陷的存在严重影响色织物的产品质量和销售价格。目前, 人工检测方法^[3]可以在一定程度上检测背景纹理简单、单一的织物缺陷, 但受工人主观

收稿日期: 2022-02-08; 修回日期: 2022-03-17; 录用日期: 2022-06-13; 网络首发日期: 2022-06-23

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)、工业控制技术国家重点实验室开放课题(ICT2021B04)、陕西省科技厅面上项目(2019JM-263)

通信作者: *zhanghongwei@zju.edu.cn

因素的影响,其检测效率低且漏检率高,难以用于小批量生产的色织物缺陷检测。因此,需要研究一种高效率的自动缺陷检测方法来解决色织物的缺陷检测问题。

传统的织物缺陷检测方法可以分为基于统计的方法、基于频谱的方法、基于结构的方法和基于学习的方法^[4]。基于统计的方法通过分析统计织物图像在灰度值空间分布中的特征来实现缺陷检测。例如,化春键等^[5]提出一种基于区域灰度极小值的网孔织物图像分割方法,利用高斯金字塔缩放和直方图均衡化处理图像,同时结合区域灰度极小值的分割算法和多图像融合算法实现对网孔织物图像的准确分割。基于频谱的方法将图像从空间域转换为频域,通过在频域提取纹理特征实现缺陷检测。例如,Li等^[6]提出一种基于椭圆 Gabor 滤波器的织物缺陷检测方法,该方法在训练过程中通过随机漂移粒子群优化获取正常织物的滤波参数,在检测过程中将待测图像与训练得到的图像进行结构匹配和滤波卷积以定位缺陷区域。基于结构的方法根据织物图像背景纹理的高度一致性分离出缺陷区域。例如,任梦凡等^[7]提出一种基于粗糙度测量和颜色距离的织物缺陷检测方法,该方法根据织物的周期性背景纹理,估计图像块与其八邻域图像块的颜色距离,进而使用显著性和二值化处理实现缺陷检测。基于学习的方法通过对织物图像训练样本的学习,从而实现缺陷检测。例如,Zhou等^[8]提出一种基于多尺度字典学习的纹理特征提取方法用于织物缺陷检测和分类。以上传统的方法更适用于大批量生产的灰度布匹的缺陷检测场景,对于小批量生产的不同色织物花型的缺陷检测是十分困难的。因此,研究一种色织物的缺陷检测方法具有重要理论意义和工程应用价值。

近年来,随着深度学习技术的快速发展,基于深度学习的织物缺陷检测方法受到越来越多研究者的关注。深度学习的方法能够提取传统方法难以提取的深层特征,由于卷积神经网络具有强大的特征提取和融合能力,而被广泛应用。根据是否对训练样本进行标记,深度学习的方法可分为有监督学习和无监督学习。在有监督学习方法中:Li等^[9]提出一种基于 Fisher 准则的堆叠去噪自编码器模型,首次将深度学习方法应用于织物缺陷检测;周君等^[10]提出一种基于 S-YOLOV3 模型的织物缺陷检测算法,通过对卷积核剪枝后的网络进行微调以提高模型的速度和准确率;Jing等^[11]提出一种轻量级的 Moblie-Unet 实现对织物缺陷像素级的分割。上述有监督学习的方法在织物缺陷检测领域取得了一定成果,但依赖于缺陷样本数量,然而在实际的工业场景中,小批量生产的色织物缺陷样本数量稀少且种类不平衡。因此,有监督学习的方法难以解决色织物缺陷检测的问题。

为了解决这些问题,部分研究者开始采用无监督学习的方法进行织物缺陷检测。无监督学习的方法

关键在于重构模型是否具有保留正常区域并移除缺陷区域的能力,从而进行后续的检测并定位缺陷区域。Mei等^[12]提出一种多尺度去噪卷积自编码器(MSDCAE)模型,通过构造不同尺度的高斯金字塔重构图像,并综合在不同分辨率下的检测结果实现对灰度织物的缺陷检测。张宏伟等^[13]先后提出深度去噪卷积自编码器(DCAE)和 U 型去噪卷积自编码器(UDCAE)的色织物缺陷检测方法^[14],通过处理待测图像与其重构图像的残差图像,进一步实现对多种简单花型色织物的缺陷检测。上述织物缺陷检测方法在背景纹理简单的织物花型上取得了较好的效果,但由于卷积神经网络的局限性,难以提取织物图像的全局特征,未能实现对复杂花型色织物的缺陷检测。针对传统卷积神经网络对色织物缺陷检测效果不佳的问题,本文提出一种基于 U 型 Swin Transformer 自编码器(USTAE)重构模型和残差分析的方法来解决色织物花型的缺陷检测问题。

2 所提方法

2.1 Transformer 模型

Transformer 模型是最近很热门的一种模型,该模型是 2017 年由 Vaswani 等^[15]首次提出并用于自然语言处理领域的,之后逐渐用于计算机视觉领域。2020 年,Dosovitskiy 等^[16]提出 Vision Transformer (ViT) 模型,首次使用一种完全基于自注意力机制的 Transformer 模型用于图像分类。之后,越来越多的研究者提出许多 Transformer 的变种模型用于图像视觉领域。

Transformer 模型作为使用多头自注意力机制的特征提取模型,抛弃传统卷积神经网络结构,完全使用自注意力机制来学习图像的全局特征。自注意力机制能够更好地捕获图像全局上下文信息,减少了对外部信息的依赖,更擅长捕获数据或特征内部的相关性,从而提取更强有力的特征。目前,Transformer 模型已经用于目标检测^[17]、图像分割^[18]、图像生成^[19]等领域,但在织物缺陷检测领域的应用还有待开发。

2.2 Swin Transformer 模型

Swin Transformer 模型是由 Liu 等^[20]提出的一种新型视觉 Transformer 模型。该模型采用移位窗口计算自注意力,移位窗口将自注意力计算限制在非重叠的局部窗口上,并允许跨窗口连接,在降低复杂度的同时提高效率。该模型的基础架构如图 1 所示。

从图 1 可以看出,Swin Transformer 结构中包含 patch partition 层、linear embedding 层、swin transformer block 层和 patch merging 层。patch partition 层用于分块降维,linear embedding 层用于线性变换,patch merging 层用于下采样,核心模块是 swin transformer block,该模块中包含用于移位窗口的多头注意力。多头注意力中每个头的注意力计算如下:




图 1 Swin Transformer 模型结构

Fig. 1 Structure of Swin Transformer model

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} + \mathbf{B}\right)\mathbf{V}, \quad (1)$$

式中： \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别为查询、键、值矩阵； d 为向量维度； \mathbf{B} 为偏置矩阵；Softmax 为多分类激活函数。

Swin Transformer 模型可以用作计算机视觉的通用骨干网络，并在多个视觉任务上表现出良好的性能。由于局部注意力机制，它不仅具有 Transformer 模型关注图像全局信息的能力，而且还可以关注到相邻窗口的相关信息，进而进行跨窗口的特征交互，在一定程度上

扩大了感受野。

2.3 USTAE 模型

在色织物的实际检测场景中，由于缺陷样本数量少且种类不平衡，难以构建缺陷种类完备的织物数据集，但容易获取大量的无缺陷样本。因此，可以构建无缺陷样本数据集，采用无监督的方法实现对重构模型的训练，进而通过残差分析和形态学处理实现对色织物缺陷区域的检测与定位。因此，基于 Swin Transformer 构造 U 型 Transformer 重构模型，所提 USTAE 模型结构如图 2 所示。

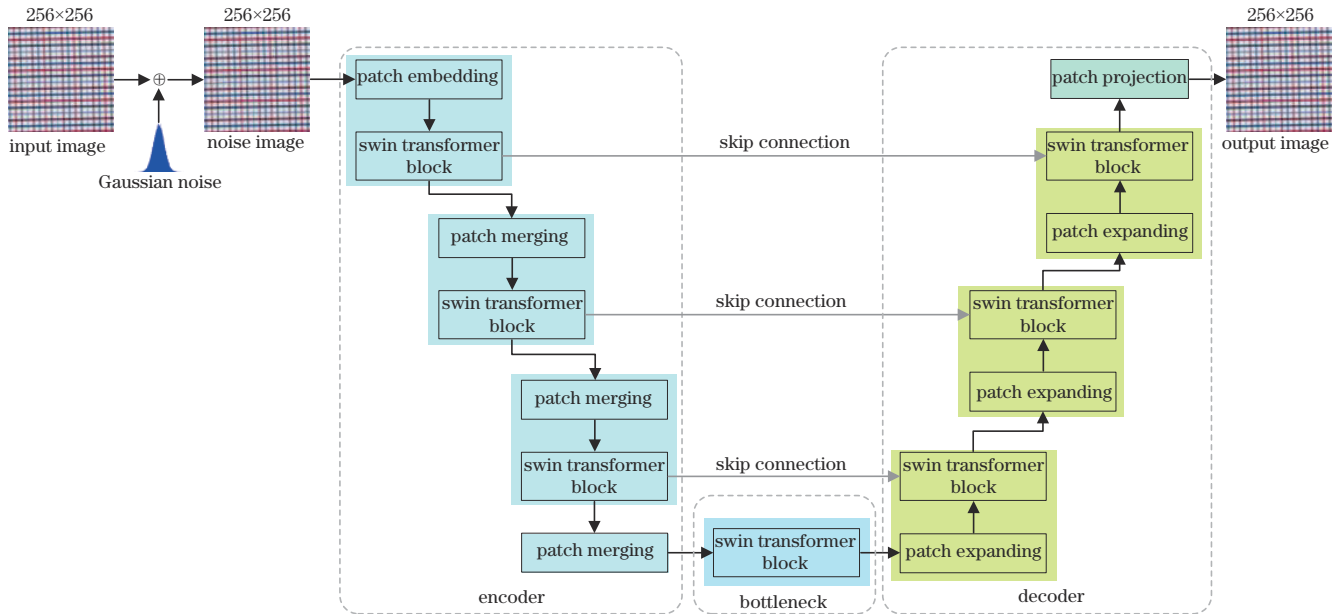


图 2 USTAE 模型结构

Fig. 2 Structure of USTAE model

图 2 的模型是一个完全基于 Swin Transformer 的 U 型对称编码器-解码器结构。编码器计算图像从局部到全局的自注意力，瓶颈层学习图像的深度特征表示，解码器实现全局特征上采样，跳接操作将浅层特征和深层特征连接在一起，从而减少空间信息损失。其中，patch embedding 层实现图像的分块降维和线性变换，patch merging 层实现图像分辨率下采样，patch expanding 层实现图像分辨率上采样，patch projection 层实现图像的通道维度变换。

2.4 USTAE 模型的训练

模型的网络结构搭建完成后，即可进行模型的训

练，如图 3 所示。输入大小为 $256 \times 256 \times 3$ 的无缺陷色织物图像，并对其叠加高斯噪声：

$$\tilde{X} = X + N(\mu, \sigma), \quad (2)$$

式中： \tilde{X} 为叠加噪声后的图像； X 为无缺陷色织物图像； $N(\mu, \sigma)$ 为均值为 μ 、方差为 σ 的高斯噪声。将叠加噪声后的图像输入训练模型中，输出为相同大小的重构去噪图像。训练过程采用均方误差 (MSE) 损失函数减少输出图像和输入图像之间的重构误差：

$$L_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n |\hat{X}(i) - X(i)|^2, \quad (3)$$

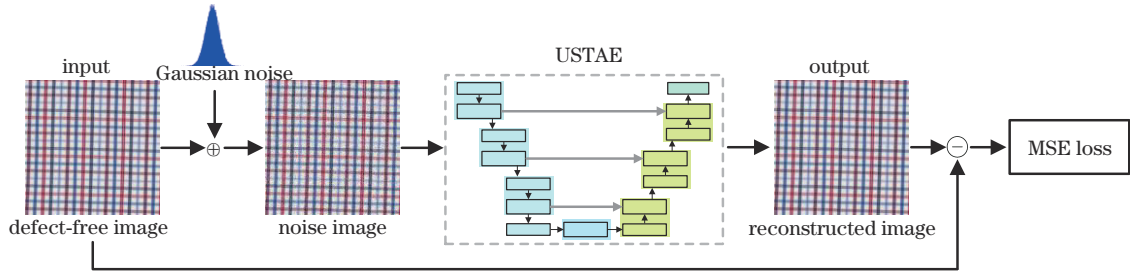


图 3 USTAE模型训练阶段

Fig. 3 Training phase of USTAE model

式中： $\hat{X}(i)$ 为重构图像； $X(i)$ 为无缺陷图像； n 为训练阶段无缺陷图像的个数。训练过程以最小化MSE损失函数数值为目标，通过AdamW优化器使损失函数达到最小，学习率设置为0.0001。为了减少参数量，窗口尺寸设置为 8×8 ，隐层节点个数为24。

2.5 基于USTAE模型的色织物缺陷检测

训练完成后的USTAE模型即可用于色织物的缺

陷检测，如图4所示。在检测阶段，输入为 $256 \times 256 \times 3$ 大小的色织物图像，输出为相同大小的重构图像。若输入图像中含有缺陷，经过模型输出后的图像将保留正常纹理并移除缺陷区域。由于缺陷区域存在明显的像素值差异，因此通过残差分析和形态学处理即可定位缺陷区域。相反，若输入图像中没有缺陷，则输出重构图与输入图的差异为随机噪声。

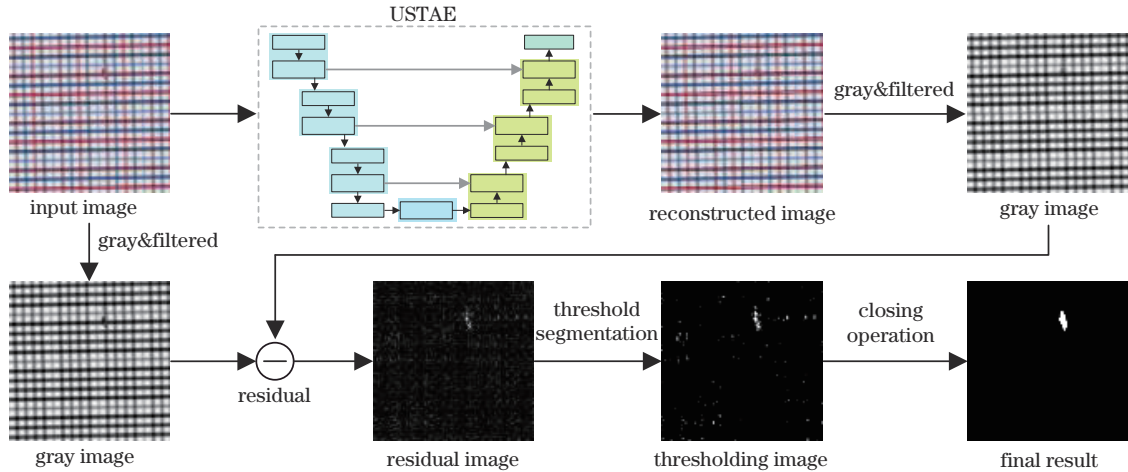


图 4 USTAE模型的缺陷检测阶段

Fig. 4 Defect detection phase of USTAE model

模型的具体检测步骤如下：

1) 将待测图像输入模型中，输出为对应的重构图像，分别对输入待测图像和重构图像进行灰度化，如下：

$$X_{\text{gray}} = 0.2125 \cdot X_r + 0.7154 \cdot X_g + 0.0721 \cdot X_b, \quad (4)$$

式中： X_{gray} 表示灰度图像； X_r 、 X_g 、 X_b 分别为彩色图对应RGB三个不同颜色通道下的像素值。

2) 对灰度化后的图像加入高斯滤波，采用 3×3 的高斯卷积核对灰度图像进行滑窗操作，如下：

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2 + y^2}{2\sigma_x\sigma_y}\right), \quad (5)$$

式中： (x, y) 为灰度图像的像素坐标； σ_x 和 σ_y 分别为图像 x 轴和 y 轴方向的像素标准差。

3) 计算输入待测图像和重构图像之间的残差图像，如下：

$$X_{\text{res}} = \left| X_{\text{gray} + \text{Gaussian}} - \hat{X}_{\text{gray} + \text{Gaussian}} \right|, \quad (6)$$

式中： X_{res} 为残差图像； $X_{\text{gray} + \text{Gaussian}}$ 和 $\hat{X}_{\text{gray} + \text{Gaussian}}$ 分别为灰度化和高斯滤波后的输入待测图像和重构图像。

4) 为了去除图像中的随机噪声点，对残差图像进行阈值分割，得到二值化图像。采用自适应阈值分割的方法，阈值选取如下：

$$T = \mu' + \epsilon\sigma', \quad (7)$$

式中： T 为自适应阈值； μ' 和 σ' 分别为残差图像的均值和标准差； ϵ 为控制分割的灵敏度， ϵ 值过小会导致大量的误检， ϵ 值过大会导致无法正确检测某些缺陷区域，设置 ϵ 为3.5。

5) 通过闭运算的形态学处理获得最终检测结果，对二值化图像进行先膨胀后腐蚀的闭运算操作，如下：

$$X_{\text{closing}} = (X_{\text{binary}} \oplus E) \ominus E, \quad (8)$$

式中： X_{closing} 为闭运算后的图像； X_{binary} 为二值化图像； E 为结构元素； \oplus 为膨胀操作； \ominus 为腐蚀操作。

3 实验结果与对比分析

3.1 实验平台

实验所用的工作站硬件配置如下:中央处理器为 Intel(R) Core(TM) i7-6850K@ 3.60 GHz;显卡为 GeForce RTX 3090(24 GB);内存为 128 GB。软件配置如下:操作系统为 Ubuntu 18.04.5 LTS;深度学习框架为 PyTorch 1.7.1;软件环境基于 Anaconda 3 和 Python 3.6.2。

3.2 色织物数据集

色织物样本来自公开发布的 YDFID-1 数据集^[21],将该数据集中所有图像整理成分辨率大小为 $512 \times 512 \times 3$ 的图像。根据色织物图像的复杂程度,将其分

为 3 类:简单格子(SL)、条纹图案(SP)和复杂格子(CL)。该数据集共有 17 种不同花型的色织物图像,选取 6 种色织物图像数据集,分别记为 SL1、SL13、SP3、SP5、SP24 和 CL1。每个花型均包含用于训练的无缺陷样本和用于测试的有缺陷样本。各数据集分布情况如表 1 所示。部分样本如图 5 所示,其中,图 5(a)为 6 个数据集的无缺陷图像,图 5(b)为 6 个数据集的缺陷图像。

表 1 色织物样本分布

Table 1 Distribution of yarn-dyed fabric samples

Dataset	SL1	SL13	SP3	SP5	SP24	CL1
Defect-free	171	176	168	166	231	170
Defective	9	23	16	19	27	4




图 5 色织物样本图像。(a)无缺陷样本;(b)有缺陷样本

Fig. 5 Images of yarn-dyed fabric samples. (a) Defect-free samples; (b) defective samples

3.3 评价指标

在色织物的缺陷检测过程中,为了评价模型的有效性,对检测结果进行定性和定量分析。其中,定量分析采用像素级评价指标中的精确率($R_{\text{precision}}$)、召回率(R_{recall})、综合评价指标(S_{F1})和平均交并比($R_{\text{precision}}$ 、 R_{recall} 、 S_{F1} 、 R_{IoU}),这些指标的定义^[22]如下:

$$R_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (9)$$

$$R_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (10)$$

$$S_{\text{F1}} = 2 \times \frac{R_{\text{precision}} \times R_{\text{recall}}}{R_{\text{precision}} + R_{\text{recall}}}, \quad (11)$$

$$R_{\text{IoU}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}} + N_{\text{FP}}}, \quad (12)$$

式中: N_{TP} 表示缺陷区域被成功检出的像素个数; N_{TN} 表示无缺陷区域被成功检为无缺陷区域的像素个数; N_{FP} 表示无缺陷区域被误检为缺陷区域的像素个数; N_{FN} 表示缺陷区域未被检出的像素个数。

3.4 结果与分析

3.4.1 噪声等级评价指标分析

不同等级的高斯噪声会在训练过程中影响模型的重构性能,进而影响后续的缺陷检测。为了评估不同等级噪声对检测性能的影响,选取花型复杂且缺陷样本

足够多的 SP24 数据集,设置均值 μ 为 0。通过改变噪声方差 σ 的值进行噪声等级评价实验,不同噪声因子与检测评价指标 $R_{\text{precision}}$ 、 R_{recall} 、 S_{F1} 、 R_{IoU} 的关系如图 6 所示。




图 6 不同噪声等级对缺陷检测结果的影响

Fig. 6 Influence of different noise levels on defect detection results

由图 6 可得,随着噪声等级的增大,其对应的指标呈下降趋势,说明模型对缺陷的检测精度逐渐降低。当 σ 为 0.1 时,检测效果最好,因此选取 $\sigma=0.1$ 为输入色织物图像的高斯噪声等级。

3.4.2 缺陷检测结果定性分析

训练后的 USTAE 模型能够有效重构色织物图像,通过残差分析和形态学处理即可定位并检测缺陷区域。为了直观对比所提模型的有效性,将 USTAE 模型与 DCAE、MSDCAE 和 UDCAE 等 3 个模型进行对比,分别在 6 个数据集上进行训练和测试,部分缺陷检测结果如图 7 所示。

从图 7 可以看出,在 4 种模型中,所提 USTAE 模型具有更精确的检测效果,其检测到的缺陷区域更接近真实值。对于 DCAE 模型,其可以准确定位 SL13、SP5、CL1 上的缺陷区域,在 SL1 和 SP3 上出现了过检,在 SP24 上存在漏检。对于 MSDCAE 模型,其可以准确定位 SL13、SP5、CL1 上的缺陷区域,其在 SL1、SP3、SP24 上有过检。对于 UDCAE 模型,在 SL1 和 CL1 上可以检测定位缺陷区域,在 SP3、SP5 上有过检,在 SL13 上无法定位缺陷区域。对于所提 USTAE 模型,其可以准确检测并定位 6 个数据集中的缺陷位置,有更少的漏检和过检,尤其是在 SP24 花型上,其他 3 种模型均有严重的过检和漏检情况,而 USTAE 模型能够精准地检测出缺陷区域。

3.4.3 缺陷检测结果定量分析

为了定量分析模型缺陷检测能力,将所提 USTAE 模型与 DCAE、MSDCAE 和 UDCAE 模型进

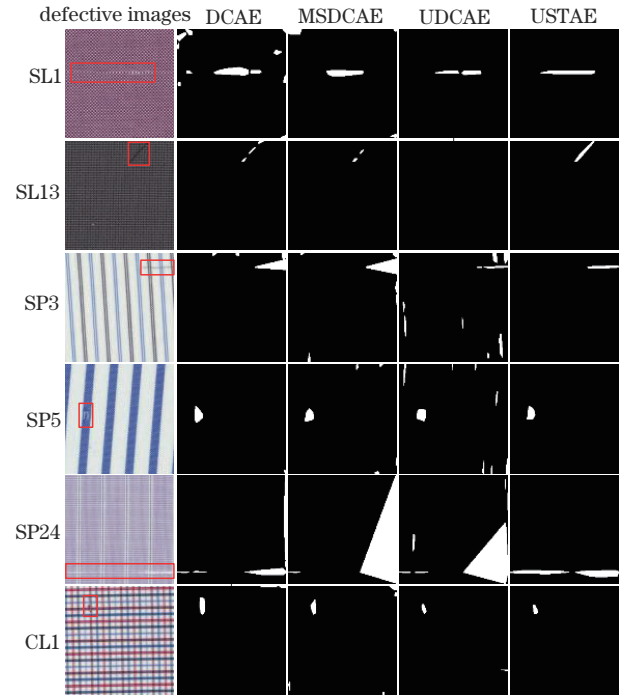


图 7 4 种模型的缺陷检测结果对比

Fig. 7 Comparison of defect detection results of four models

行比较,采用 $R_{\text{precision}}$ 、 R_{recall} 、 S_{F1} 、 R_{IoU} 等 4 个评价指标进行定量分析,结果如表 2 所示。

表 2 4 种模型的 4 项评价指标对比

Table 2 Comparison of four evaluation indexes of four models

Index	Model	SL1	SL13	SP3	SP5	SP24	CL1	Mean value
$R_{\text{precision}} / \%$	DCAE	33.10	25.10	43.26	57.03	44.40	23.34	37.70
	MSDCAE	45.40	15.94	42.36	47.99	32.00	21.39	34.18
	UDCAE	61.17	10.46	30.48	42.48	24.27	29.94	33.13
	USTAE	67.72	37.70	67.36	62.75	58.62	55.03	58.20
$R_{\text{recall}} / \%$	DCAE	73.14	15.80	48.36	64.03	60.69	90.74	58.79
	MSDCAE	62.66	12.57	49.20	60.29	45.65	65.23	49.27
	UDCAE	74.22	7.79	33.46	53.52	46.53	56.01	45.26
	USTAE	66.49	20.03	53.13	59.82	59.48	71.71	55.11
$S_{\text{F1}} / \%$	DCAE	41.50	17.14	42.46	55.84	48.15	36.79	40.31
	MSDCAE	51.61	11.77	41.64	48.19	34.42	31.84	36.58
	UDCAE	64.53	5.37	29.10	41.51	26.90	36.56	33.99
	USTAE	62.13	22.39	52.19	57.79	54.60	59.57	51.44
$R_{\text{IoU}} / \%$	DCAE	29.42	12.77	30.83	39.89	34.18	23.03	28.35
	MSDCAE	39.42	8.56	29.94	33.34	24.39	19.53	25.86
	UDCAE	50.69	3.14	21.43	28.55	18.12	23.59	24.30
	USTAE	46.83	16.52	38.73	42.18	40.36	43.30	37.99

表 2 显示了 4 种模型在评价指标 $R_{\text{precision}}$ 、 R_{recall} 、 S_{F1} 、 R_{IoU} 上的比较结果,加粗数据为最佳结果,表的最后一列为在所有数据集上的平均值。可以看出:USTAE 模型取得了最好的效果,在 5 个数据集上的 $R_{\text{precision}}$ 、 S_{F1} 、 R_{IoU} 值均达到最高;其次是 DCAE 模型,其 R_{recall} 达到最高值,总体效果比 MSDCAE 和 UDCAE 模型更好。

总体来说,USTAE 模型的整体效果更好,虽然 DCAE 模型的召回率高,但是过高的召回率往往会致过检。综合考虑 S_{F1} 和 R_{IoU} 指标,所提 USTAE 模型表现出更好的检测性能和更准确的缺陷检测效果。

3.4.4 消融实验

为了证明所提 USTAE 模型的有效性,在模型中

改变跳接数量进行消融实验,分别在跳接数为 0、1、2、3 时计算定量评价指标在 6 个花型上的平均值,结果如表 3 所示。

表 3 跳接数量的消融实验

Table 3 Ablation experiment of the number of skip connection

Skip connection	$R_{\text{precision}} / \%$	$R_{\text{recall}} / \%$	$S_{F1} / \%$	$R_{\text{IoU}} / \%$
0	52.41	50.16	46.81	34.53
1	55.44	51.50	49.31	36.69
2	53.91	50.48	48.02	35.74
3	58.20	55.11	51.44	37.99

由表 3 可以看出,模型的性能随着跳接数的增加而提升。在跳接数为 3 时,模型的性能最好,说明跳接操作可更好地把浅层特征和深层特征连接在一起,从而减少了空间信息损失。为了使模型更加鲁棒,设置跳接数为 3。

4 结 论

针对纺织行业中色织物花型的缺陷检测问题,提出一种基于 U 型 Swin Transformer 自编码器的色织物缺陷检测方法。首先,对加入高斯噪声的无缺陷样本进行模型训练;然后,将待测图像输入模型中得到相应重构图像;接着,计算待测图像和重构图像之间的残差图像;最后,对残差图像进行阈值分割和形态学处理,实现色织物缺陷的检测与定位。与传统的卷积神经网络相比,Transformer 模型能更好地提取图像的全局特征,实现更准确的图像重构。同时,该方法只使用无缺陷样本对模型进行训练,充分利用无监督学习方法的优点,有效解决了缺陷样本数量少且种类不平衡的问题。实验结果表明,该方法具有良好的检测性能,能够满足实际色织物的检测工艺要求,为色织物服装行业提供了一种易于工程实践的自动缺陷检测方案。

参 考 文 献

- [1] 周小溪,梁惠娥,陈潇潇,等.春夏季衬衫用色织面料材质的感性评价[J].纺织学报,2016,37(8):59-64.
Zhou X X, Liang H E, Chen X X, et al. Sensibility assessment of spring and summer shirt yarn-dyed fabrics [J]. Journal of Textile Research, 2016, 37(8): 59-64.
- [2] Kumar A. Computer-vision-based fabric defect detection: a survey[J]. IEEE Transactions on Industrial Electronics, 2008, 55(1): 348-363.
- [3] 任欢欢,景军锋,张缓缓,等.应用 GIS 和 FTDT 的织物错花缺陷检测研究[J].激光与光电子学进展,2019,56(13):131005.
Ren H H, Jing J F, Zhang H H, et al. Cross-printing defect detection of printed fabric using GIS and FTDT [J]. Laser & Optoelectronics Progress, 2019, 56(13): 131005.

- [4] 卢荣胜,吴昂,张腾达,等.自动光学(视觉)检测技术及其在缺陷检测中的应用综述[J].光学学报,2018,38(8):0815002.
Lu R S, Wu A, Zhang T D, et al. Review on automated optical (visual) inspection and its applications in defect detection[J]. Acta Optica Sinica, 2018, 38(8): 0815002.
- [5] 化春键,孙康康,陈莹.基于区域灰度极小值的网孔织物图像分割算法[J].激光与光电子学进展,2021,58(2):0210014.
Hua C J, Sun K K, Chen Y. Image segmentation algorithm of mesh fabric based on regional minimum gray value[J]. Laser & Optoelectronics Progress, 2021, 58(2): 0210014.
- [6] Li Y Y, Luo H C, Yu M M, et al. Fabric defect detection algorithm using RDPSO-based optimal Gabor filter[J]. The Journal of the Textile Institute, 2019, 110(4): 487-495.
- [7] 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):0410008.
Ren M F, Zhu L, Ma X M, et al. Fabric defect detection method based on coarseness measurement and color distance[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410008.
- [8] Zhou Z Y, Wang C, Gao X, et al. Fabric defect detection and classifier via multi-scale dictionary learning and an adaptive differential evolution optimized regularization extreme learning machine[J]. Fibres and Textiles in Eastern Europe, 2019, 27(133): 67-77.
- [9] Li Y D, Zhao W G, Pan J H. Deformable patterned fabric defect detection with fisher criterion-based deep learning[J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(2): 1256-1264.
- [10] 周君,景军锋,张缓缓,等.基于 S-YOLOV3 模型的织物实时缺陷检测算法[J].激光与光电子学进展,2020,57(16):161001.
Zhou J, Jing J F, Zhang H H, et al. Real-time fabric defect detection algorithm based on S-YOLOV3 model [J]. Laser & Optoelectronics Progress, 2020, 57(16): 161001.
- [11] Jing J F, Wang Z, Ratsch M, et al. Mobile-Unet: an efficient convolutional neural network for fabric defect detection[J]. Textile Research Journal, 2022, 92(1/2): 30-42.
- [12] 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.
- [13] 张宏伟,汤文博,李鹏飞,等.基于去噪卷积自编码器的色织衬衫裁片缺陷检测[J].纺织高校基础科学学报,2019,32(2):119-125,132.
Zhang H W, Tang W B, Li P F, et al. Defect detection and location of yarn-dyed shirt piece based on denoising convolutional autoencoder[J]. Basic Sciences Journal of Textile Universities, 2019, 32(2): 119-125, 132.
- [14] 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 S, 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.
- [15] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. (2017-06-12) [2022-02-04]. <https://arxiv.org/abs/1706.03762>.
- [16] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: transformers for image recognition at scale[EB/OL]. (2020-10-22) [2021-02-04]. <https://arxiv.org/abs/2010.11929>.
- [17] 何林远, 白俊强, 贺旭, 等. 基于稀疏 Transformer 的遥感旋转目标检测[J]. 激光与光电子学进展, 2022, 59(18): 1810003.
- He L Y, Bai J Q, He X, et al. Remote sensing rotated object detection based on sparse transformer[J]. Laser & Optoelectronics Progress, 2022, 59(18): 1810003.
- [18] Strudel R, Garcia R, Laptev I, et al. Segmenter: transformer for semantic segmentation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2021: 7242-7252.
- [19] Chen M, Radford A, Child R, et al. Generative pretraining from pixels[C]//ICML'20: Proceedings of the 37th International Conference on Machine Learning, July 13-18, 2020, Virtual Event. New York: ACM Press, 2020: 1691-1703.
- [20] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2021: 9992-10002.
- [21] Zhang H W. Yarn-dyed fabric image dataset version1 [DB/OL]. (2021-06-30) [2022-02-04]. <http://github.com/ZHW-AI/YDFID-1>.
- [22] Liu Y H, Yao J, Lu X H, et al. DeepCrack: a deep hierarchical feature learning architecture for crack segmentation[J]. Neurocomputing, 2019, 338: 139-153.