

## 基于合成缺陷的偏光片外观对抗异常检测方法

钟小品<sup>1</sup>, 朱俊玮<sup>1</sup>, 列智豪<sup>1</sup>, 邓元龙<sup>2\*</sup><sup>1</sup>深圳大学机电与控制工程学院, 广东 深圳 510086;<sup>2</sup>深圳技师学院, 广东 深圳 518116

**摘要** 目前的自动光学检测技术受到以下两方面的挑战:难以获取足够数量的缺陷样本,且种类极不平衡;外观缺陷形态多样,种类复杂。上述问题严重影响偏光片外观缺陷的检测精度和效率。基于此,提出一种无需真实缺陷样本的深度对抗异常检测方法。采用编码器捕获条纹结构光缺陷图像的规律性特征,并通过解码器重建出无缺陷图像,再通过一个编码器模块构成无监督对抗网络,最后根据重建图像与样本图像的差异计算异常得分。在训练阶段加入合成缺陷,同时改进目标潜在损失函数,进一步提高检测精度。在一个考虑光照不均衡、噪声、相机畸变等因素的偏光片外观缺陷数据集上的实验结果表明,所提方法测试结果的 area under curve 达到 97.9%,单张图像平均检测时间为 19.2 ms,检测准确率为 94.6%,均优于 GANomaly 等方法,验证了其有效性与鲁棒性。

**关键词** 机器视觉; 偏光片; 结构光成像; 生成对抗网络; 异常检测

中图分类号 TP391.4 文献标志码 A

DOI: 10.3788/LOP222111

## Anomaly Detection Method of Polarizer Appearance Based on Synthetic Defects

Zhong Xiaopin<sup>1</sup>, Zhu Junwei<sup>1</sup>, Lie Zhihao<sup>1</sup>, Deng Yuanlong<sup>2\*</sup><sup>1</sup>College of Mechatronics and Control Engineering, Shenzhen University, Shenzhen 510086, Guangdong, China;<sup>2</sup>Shenzhen Institute of Technology, Shenzhen 518116, Guangdong, China

**Abstract** The current automatic optical detection technology is challenged by the following two aspects: it is difficult to obtain enough defect samples, and the types are extremely unbalanced; the appearance defects are diverse and complex. The above problems seriously affect the detection accuracy and efficiency of the appearance defects of polarizers. Considering these issues, a new depth antagonism method of anomaly detection without real defect samples is proposed. An encoder is used to capture the regular characteristics of the stripe-structured light defect image and a decoder is used to reconstruct the defect-free image. An encoder module is then used to form an unsupervised countermeasure network. Finally, the abnormal score is calculated according to the difference between the reconstructed image and the sample image. In the training phase, synthetic defects are added, and the target potential loss function is improved to further increase the detection accuracy. The experimental results for a polarizer appearance defect data set-considering factors such as light imbalance, noise, and camera distortion-show that the area under curve of the test results of the proposed method reaches 97.9%, the average detection time of a single image is 19.2 ms, and the detection accuracy is 94.6%, which is superior to other methods such as GANomaly. The effectiveness and robustness of the proposed method are verified.

**Key words** machine vision; polarizer; structured light imaging; generative adversarial network; anomaly detection

## 1 引言

偏光片是一种常见的偏振光学元件,应用非常广泛,尤其在液晶显示面板中,必有两层偏振方向正交的偏光片。偏光片的凸凹点、异物、气泡、划痕等外观缺

陷会降低显示面板的质量等级,甚至报废整个面板。目前的自动光学检测技术受到以下两方面的挑战:难以获取足够数量的工业缺陷样本,且种类极不平衡;外观缺陷形态多样、种类各异,甚至难以穷尽。因此,深入探索偏光片外观缺陷自动检测技术具有重要的研究

收稿日期: 2022-07-20; 修回日期: 2022-09-03; 录用日期: 2022-09-26; 网络首发日期: 2022-10-06

基金项目: 国家自然科学基金面上项目(62171288)、深圳市科技创新计划(JCYJ20190808143415801)

通信作者: \*dengyl@szu.edu.cn

和应用意义。

目前广泛采用机器视觉检测偏光片外观缺陷,主要通过传统图像处理方法或机器学习方法提取和识别缺陷。Yoon 等<sup>[1]</sup>采用图像分割和模板匹配方法对点缺陷、气泡、异物、Thread、Cunic 等 5 类缺陷进行检测和识别,缺陷分类精度达到 96%。Kuo 等<sup>[2]</sup>对缺陷图像进行预处理后,使用霍夫变换来识别分割后的图像,在总数为 200 的数据集中(每类 40 张),缺陷分类精度达到 98%,有效地识别点缺陷、灰尘、异物、划痕、气泡等 5 类缺陷。Cheng 等<sup>[3]</sup>使用哈尔小波变换方法来处理偏光片 Mura 缺陷,能够快速检测出线 Mura 缺陷。Won 等<sup>[4]</sup>采用卷积神经网络研究点状缺陷的分类问题,在总数为 210 的数据集中(70 张背景图、70 张疑似缺陷图和 70 张缺陷图像),缺陷检测精度达到 95%。中北大学 Lei 等<sup>[5]</sup>使用深度学习目标检测算法对偏光片外观缺陷进行检测,平均分类精度达到 67.5%。Liu 等<sup>[6]</sup>在 2020 年提出一种基于深度学习的轻量级神经网络(LWEN),在总数为 6000 张偏光片图像的数据集中(缺陷图像 3000 张、脏污图像 3000 张),模型的分分类准确率达到 99.4%,有效地解决脏污和缺陷图像的分类问题。该团队同年再次提出基于深度学习的轻量级神经网络(DDN),在模型大小约为 290 kB 的情况下,分类准确率达到 99.5%<sup>[7]</sup>。而 Huang 等<sup>[8]</sup>也在 2020 年提出一种基于改进局部二值模式描述符和支持向量机的识别方法,在总数为 250 的数据集中(每类 50 张),识别准确率达到 99.2%,可有效识别划痕、点缺陷、偏膜、缺胶和背景图。

上述研究一定程度都存在缺陷样本不足和类型不均衡问题,这导致训练的分类器具有明显的偏向性,影响泛化能力。针对这个问题,Schlegl 等<sup>[9]</sup>基于生成对抗网络首次提出 AnoGAN 模型用于缺陷检测,模型的训练阶段只需要正样本,推理阶段采用特征匹配方法,测试图像迭代计算找到对应的潜在空间向量  $z$ ,再使用向量  $z$  前向传播,最后用判别器对生成器的输出进行评分,超过一定阈值则判定为缺陷。但该方法计算量大,影响缺陷检测效率。Akçay 等<sup>[10]</sup>提出一种编码-解码-编码的对抗自编码网络模型 GANomaly,大大提升训练效率,在推断的时候使用已训练网络计算测试图像的编码损失,并与阈值比较以判定样本是否存在缺陷。不久,Akçay 等<sup>[11]</sup>又在 GANomaly 的基础上,引入跳跃连接层,提出 Skip-GANomaly,增强模型的重建能力。对于一些极细微缺陷,该网络一般会以修复的方式重建图像,如果仍然采用简单的编码损失阈值,难以进一步提高缺陷检测准确度。

针对上述问题,本文提出一种基于合成缺陷的半监督偏光片外观对抗异常检测方法。首先采用人工配置生成大量随机缺陷,对样本进行数据增广,得到无缺陷与有缺陷的成对训练集;然后利用对抗生成网络模

型联合学习偏光片正常样本高维图像空间的生成和潜在空间的分布;捕获其正常样本数据分布,最后利用 Adam 优化器对模型进行训练。测试结果表明了所提方法的有效性及其鲁棒性。

## 2 成像系统

条纹结构光背投照明可以有效增强细微缺陷成像效果<sup>[12]</sup>,王维等<sup>[13]</sup>就通过一种偏振透射结构光检测透明物体的表面缺陷,所提方法通过条纹结构光来检测偏光片缺陷,实验系统如图 1 所示。




图 1 偏光片成像实验系统示意图

Fig. 1 Schematic diagram of polarizer imaging experiment system

在平板电脑上编程产生所需要的结构光条纹样式,设置合适的条纹宽度、占空比和扫描周期,可大幅提高缺陷的成像对比度,增强效果如图 2 所示。采用主动光扫描即可覆盖所有区域<sup>[14]</sup>。1 个样品采集 2~4 幅图像,即可检测其缺陷情况。




图 2 结构光成像增强效果(左,均匀光;右,结构光)

Fig. 2 Structured light imaging enhancement effect (left, uniform light; right, structured light)

## 3 基于合成缺陷的生成式对抗神经网络

### 3.1 编码-解码生成对抗结构

生成对抗网络(GAN)是一种无监督机器学习方法<sup>[15]</sup>,由于其优秀的生成特性,近年来受到广泛关注,目前已经在图像生成<sup>[16]</sup>、图像超分辨<sup>[17]</sup>、风格迁

移<sup>[18-19]</sup>、目标检测<sup>[20]</sup>等方面获得成功应用。GAN 一般由生成器和判别器构成,前者试图通过学习训练集数据的特征来生成假图像,而后者则负责分辨输入的图片是真实的还是生成器生成的假图像。该生成器是一个类似于解码器的网络,从一个潜在空间中学习输入数据的分布,其主要目标是从原始真实数据分布中抽样高维数据。判别器网络通常具有经典的分类体系结构,读取输入图像,并确定其类别(真或假)。自动编码器由 Rumelhart 等<sup>[21]</sup>最早提出并应用于高维复杂的数据处理,主要由编码器(encoder)和解码器(decoder)组成,编码器会把输入的高维数据映射为低维的中间变量,然后解码器再把低维的中间变量上采样为高维的输入空间数据。自动编码器模型可以将输入数据压缩至隐藏空间表示,去除噪声影响、保留图像的结构信息,这正符合本研究的应用场景<sup>[22]</sup>。

### 3.2 网络结构

所提模型总体框架如图 3 所示,其中,  $\mathbf{x}$  为输入数据,  $\mathbf{x}_c$  为添加合成缺陷后的输入数据,  $\mathbf{x}_g$  为重建图像数据。训练的过程中,  $C(\mathbf{x})$  模块随机地在输入数据上添

加合成缺陷,使模型学习缺陷修复能力。编码器和解码器构成自动编码器,是生成对抗网络的生成器。在编码解码网络结构中采用跳跃连接进行残差计算,允许解码器在序列的多个向量中提取所需要的信息、局部和全局信息,以实现更好的条纹结构重建效果。整个网络模型对应 3 个损失函数,除了对抗性损失  $L_{adv}$  之外,为了使模型能同时学习到正常数据在图像空间和潜在向量空间的分布,设置上下文损失函数  $L_{con}$ 。而潜在的表现损失  $L_{lat}$  通过比较输入数据和重建数据在编码过程中的特征矩阵,使模型重建的图像数据在潜在空间上与输入数据一致。在推理阶段使用一个异常分数预测样本,正常数据将获得较小的异常得分,否则是异常数据。

判别器本质是由卷积层、归一化层以及激活函数等组成的多层卷积分类网络,可以输出数据的类别,如图 4 所示。判别器分辨输入数据  $\mathbf{x}$  是真实数据还是生成的假数据,并且在训练过程中与生成器相互对抗,逐渐达到纳什均衡,使生成器具有良好的缺陷修复或图像重建能力。

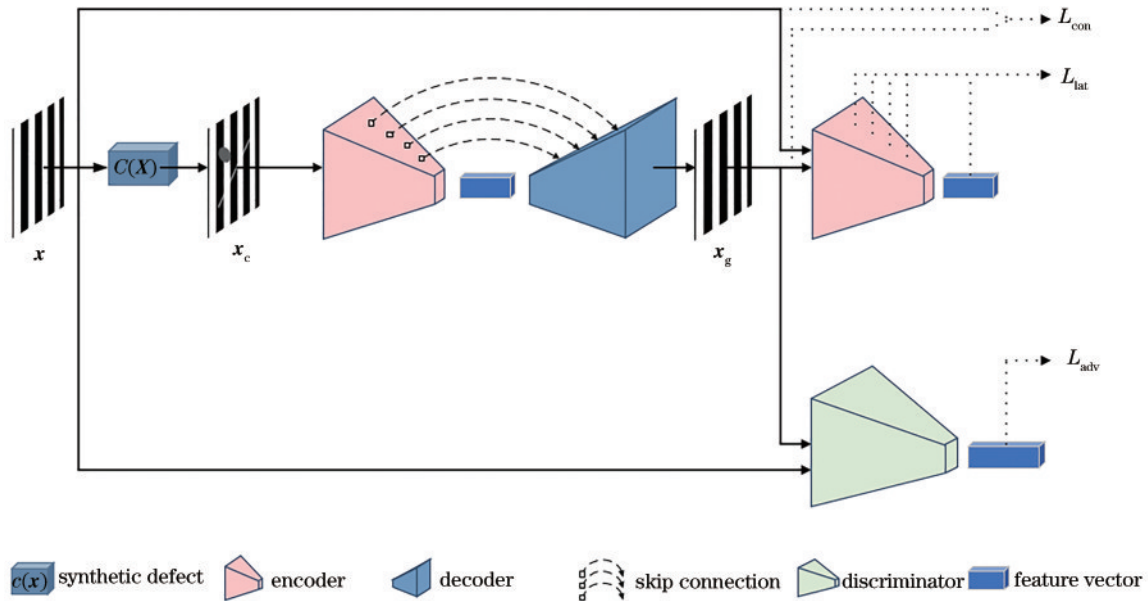


图 3 所提模型的总体框架

Fig. 3 Overall framework of proposed model

### 3.3 损失函数

为了使网络模型在训练过程中获得较强的重建能力以及缺陷修复能力,对抗损失  $L_{adv}$  的表达式为

$$L_{adv} = E_{\mathbf{x} \in P_r} [\log D(\mathbf{x})] + E_{\mathbf{x}_g \in P_g} \left\{ \log [1 - D(\mathbf{x}_g)] \right\}, \quad (1)$$

式中:  $D$  为判别器;  $E(\cdot)$  表示分布函数的数学期望;  $P_r$  为输入数据的分布;  $P_g$  表示生成数据的分布;  $\mathbf{x}_g$  由生成器  $G$  得到。训练的目标是最小化生成器  $G$  的对抗损失,最大化判别器  $D$  的对抗损失,即达到  $\min_G \max_D L_{adv}$ 。

对抗损失函数使模型学习如何产生真实的样本,但不能保证模型捕捉到关于输入的上下文信息。因

此,可采用基于  $L_1$  距离的上下文损失  $L_{con}$  衡量重建差异的指标。最小化  $L_{con}$  损失函数即可使模型输出的重建图像尽可能与无缺陷正常样本一致。为了明确地学习上下文信息,充分获取正常样本的数据分布,对输入  $\mathbf{x}$  和重构输出  $\mathbf{x}_g$  进行  $L_1$  归一化,结合余弦相似度指标作为惩罚项,这种归一化确保模型能够生成与正常样本在上下文上相近的图像。训练目标的上下文损失的表达式为

$$L_{con} = E_{\mathbf{x} \in P_r} \left\| \bar{\mathbf{x}} - \bar{\mathbf{x}}_g \right\|_1 + \frac{\langle \mathbf{x}, \mathbf{x}_g \rangle}{\| \mathbf{x} \| \| \mathbf{x}_g \|}, \quad (2)$$



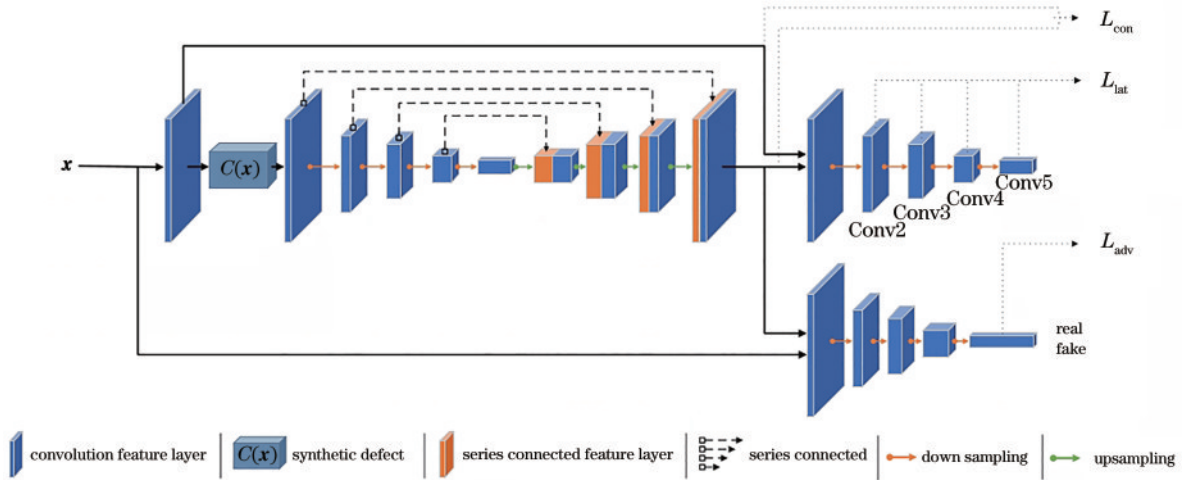


图 4 基于编码解码结构的对抗异常检测网络模型

Fig. 4 Anti anomaly detection network model based on encoding and decoding structure

式中:  $\bar{x}, \bar{x}_g$  为归一化项;  $\frac{\langle \mathbf{x}, \mathbf{x}_g \rangle}{\|\mathbf{x}\| \|\mathbf{x}_g\|}$  为余弦项。

根据 Mahendran 等<sup>[23]</sup>的研究,随着网络层数增加,输出特征表现为对输入图像的逐步抽象,但是经过反演实验,这些特征仍然能对图像重建过程作出贡献。因此,利用编码器重新获得重建图像和原图的编码特征,并计算它们的  $L_2$  距离,以确保网络能够生成上下文合理的潜在表示。潜在表示损失函数的表达式为

$$L_{lat} = \sum_j a_j \|E_j(\mathbf{x}) - E_j(\mathbf{x}_g)\|_2, \quad (3)$$

式中:  $E_j(\cdot)$  表示编码器第  $j$  层的卷积特征,  $j \in \text{Conv2}, \text{Conv3}, \text{Conv4}, \text{Conv5}$ ;  $a_j$  代表编码器第  $j$  层的权重。

Skip-GANomaly 的潜在损失只包含 Conv5,是提出潜在损失函数的一种特例。在实验中发现,每个编码器特定层的权重全部取 1 时,实验效果最佳。

总训练目标损失函数为上述损失的加权和:

$$L = \lambda_{adv} L_{adv} + \lambda_{con} L_{con} + \lambda_{lat} L_{lat}, \quad (4)$$

式中:参数  $\lambda_{adv}, \lambda_{con}, \lambda_{lat}$  由实验确定。对抗损失的引入在一定程度上会与重构误差竞争,通过加权参数可以平衡图像重建的总体以及重要细节。

### 3.4 基于合成缺陷的异常检测过程

利用条纹结构光背投照明采集到的无缺陷样本图像作为训练数据集,一定量无缺陷和有缺陷样本图像形成测试集,相应的正常/异常样本识别流程如图 5 所

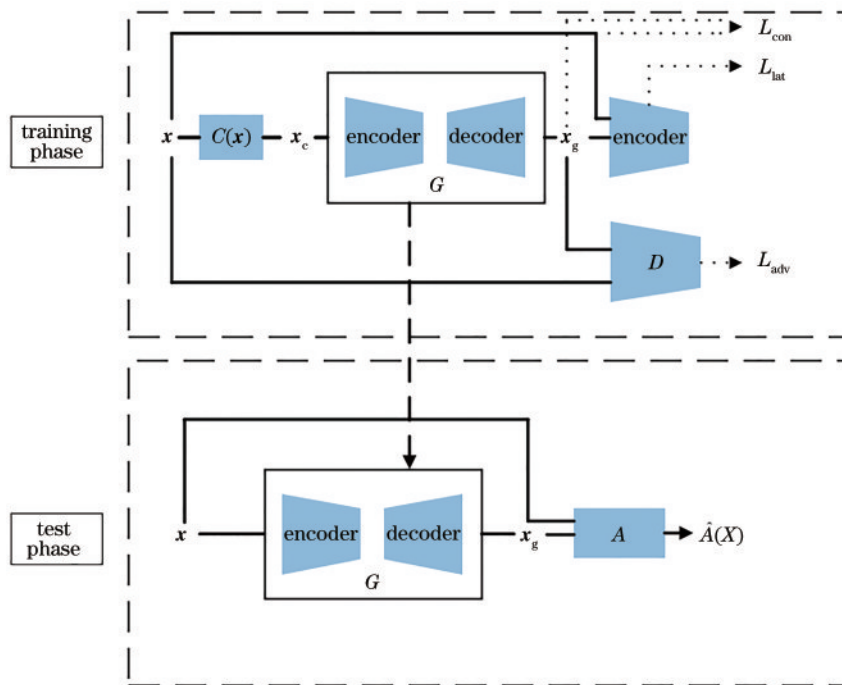


图 5 基于合成缺陷的异常检测过程

Fig. 5 Anomaly detection process based on synthetic defects

示,其中, $A$ 为缺陷分数计算模块。在训练阶段,正常样本添加合成缺陷之后,输入网络进行迭代训练。在测试阶段,将测试样本输入迭代后的最优模型中,得到重建图像,进而计算重建图像和原图差异获得异常分数。如果异常分数大于设定的阈值,则判定原图带有缺陷。

异常分数的表达式为

$$A(\mathbf{x}) = \|\mathbf{x} - \mathbf{x}_g\|_2, \quad (5)$$

对缺陷分数进行尺度缩放,将其归一化至 $[0,1]$ ,可得到形成缺陷概率:

$$\hat{A}(\mathbf{x}) = 1 - \exp[-A(\mathbf{x}, \mathbf{x}_g)]. \quad (6)$$

## 4 实验结果及分析

### 4.1 数据集

为了提高模型训练的稳定性,尽可能使用具有代表性、可以覆盖大多数特征的正常样品。训练集含 10000 个正常样本,而测试集包括 100 个正常样本以及 1019 个异常样本。

条纹结构光缺陷图像的常见特征有条纹间距、黑

白条纹宽度比、亮度、饱和度等。对于亮度使用平均像素灰度进行表示:

$$M = \frac{1}{HW} \sum_{s,t} I(s,t), \quad (7)$$

式中: $I(s,t)$ 为 $(s,t)$ 位置上的像素灰度值; $H$ 为图像的高度; $W$ 为图像的宽度。

对于饱和度,其表达式<sup>[24]</sup>为

$$S = \exp\left[-\frac{(M - \mu)^2}{2\sigma_g^2}\right], \quad (8)$$

式中: $\mu$ 是期望值,取值为 1,也即当归一化后灰度图像的灰度均值为 1 时,图像达到最高级别的饱和度; $\sigma_g$ 为灰度标准差,取 0.3 即可获得接近人眼感受的饱和度表达。

不同特征的取值范围以及例图如表 1 所示。偏光片的缺陷种类很多,有些缺陷难以收集到足够多的样本。本研究着眼于解决偏光片细微透明缺陷的检测问题,因此主要采集点缺陷、异物、气泡、折痕等 4 类缺陷,各类缺陷示例如图 6 所示。

表 1 不同特征下正常样本

Table 1 Normal samples under different characteristics

Frequency (fringe spacing)	Width ratio of black and white stripes	Brightness	Saturation	Rotation	Edge distortion	Noise impact
$1/2\pi - 1/\pi$	0.2-5	50-200	0-0.9	$0 - \pi$	0.1-5	Gaussian exponent

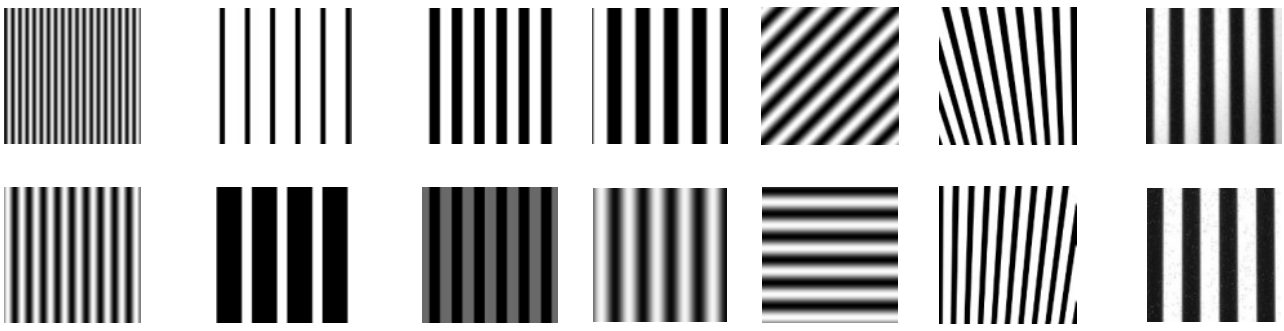




图 6 真实缺陷示例。(a)点缺陷;(b)异物;(c)气泡;(d)折痕

Fig. 6 Real defect examples. (a) Point defect; (b) foreign matter; (c) bubbles; (d) crease

### 4.2 合成缺陷

生成模型的学习目标是获取正常样本的数据分布,不需要知道缺陷样本的具体形式。在训练阶段,通过合成并添加足够多样化的随机缺陷,经过多次迭代学习,模型即可获得修复缺陷区域从而重建图像的能力。缺陷的形状、位置、大小、灰度值以及数量都是随

机的,图 7 展示了部分合成缺陷的示例,第 1 行为无缺陷原图,第 2 行是相应的含合成缺陷的图像。

### 4.3 模型训练与超参数选择

在特征扩充后的 10000 张 OK 数据集上训练模型。训练环境为: Intel® Core (TM) i9-9900X CPU 3.50 GHz, GPU 为 GTX2080Ti, 实现框架是 PyTorch (v1.7, Python




图 7 合成缺陷示例

Fig. 7 Examples of composite defects

3.8), 使用 Adam<sup>[25]</sup> 优化网络, 初始学习率为 0.0002, 动量参数  $\beta_1=0.5$ 、 $\beta_2=0.999$ 。损失函数的权重分配实验结果如图 8 所示, 其中, 3 条曲线分别代表 3 个损失的权重超参数, 当固定该超参数为横坐标值时, 阴影部分为其他两个权重超参数在 1~100 变动而得到的模型精度最小值和最大值, 图中的点则为阴影部分的中值, 最后实验发现  $\lambda_{adv}=1$ 、 $\lambda_{con}=50$ 、 $\lambda_{lat}=1$  时模型精度最好。




图 8 模型损失权重的超参数选择图

Fig. 8 Hyperparametric selection diagram of model loss weight

#### 4.4 模型测试

实验结果表明, 在条纹模式背景下, 在训练的无缺陷样本足够多时, 该模型可以获得更高的精度, 如图 9 所示, 分别用 1000 张、4000 张、7000 张和 10000 张正常样本去训练模型, 可看到模型的 area under curve (AUC) 逐渐升高, 这是因为数量更多的正常样本可以让模型更好地学习正常样本的分布情况, 从而提高模型精度。

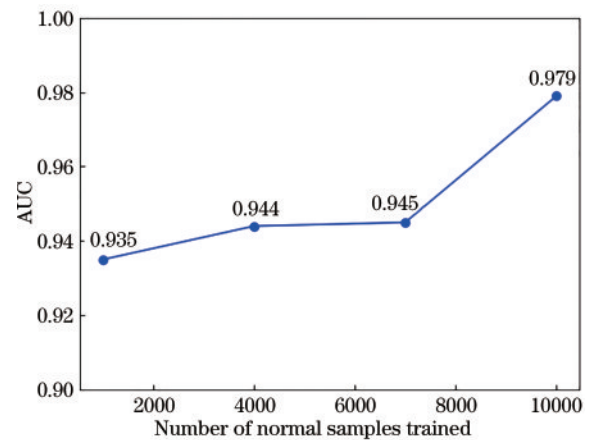


图 9 训练样本数量和模型精度关系图

Fig. 9 Relationship between number of training samples and model accuracy

把用 10000 张正常样本训练 200 次的模型在 1000 张测试集图像上进行测试。在测试阶段, 针对缺陷图像, 模型可以重建出相同背景下经过修复的偏光片图像。

对于正常样本, 无论是 Skip-GANomaly 还是所提方法都可以重建出与正常样本几乎相同的图像, 如图 10 所示。对于缺陷样本, 在同样的超参数和开发环境下, Skip-GANomaly 无法感知到点状和线状缺陷, 所以会重建出和异常样本几乎一致的图像。而大面积团状缺陷虽然被 Skip-GANomaly 感受到, 但重建出来的区域与正常区域差异也较大。原因在于: Skip-GANomaly 采用跳跃连接层, 模型重建时会修复掉一些极细微缺陷; 对于一些较细微的缺陷, 则能直接重建出来; 对于较大的缺陷, 模型可以重建大部分区域。这 3 种情况, 缺陷原图和模型生成图的差距都较小, 因此不容易通过异常得分区别开。






图 10 部分正常样本重建效果对比

Fig. 10 Comparison of reconstruction results of some normal samples

与 Skip-GANomaly 不同,所提方法在潜在损失上考虑每层的卷积特征,可以感受从小到大的各类异常区域,且在训练阶段添加合成缺陷,模型易于学习到一个正确的图像重建修复过程,有缺陷的原图

与模型重建图之间有更大差距,利于异常检测,对比结果如图 11 所示。尽管有些没有把缺陷区域完美重建,但是通过异常分数已经可以正确判别是否存在异常。




图 11 缺陷样本重建效果对比图

Fig. 11 Comparison of reconstruction effect of defect samples

在模型测试时,正常样本和缺陷样本分别随机取 100 个,计算得到的异常分数分布如图 12 所示。可以看出,正常样本的异常得分都很低,而缺陷样本的异常得分较高,实验中选定异常得分 0.0185 作为阈值,缺陷样本召回率为 94.6%,虚警率为 7%。

#### 4.5 性能对比分析

针对 1000 张图像的测试集进行模型评估,并将所提方法与当前流行且表现优异的异常检测方法进行对比,结果如表 2 所示。

Skip-GANomaly 在本研究的数据集中仅获得 0.686 的 AUC,当使用所提潜在损失时,AUC 提高至 0.734。增加合成模块后,所提方法不使用潜在损失即可超越变分自动编码器(VAE)、GANomaly 以及 Skip-GANomaly 等一众方法,AUC 达到 0.916,而所提方法使用潜在损失后,AUC 进一步提升至 0.979。另一方面,不同方法的查准率-召回率( $P-R$ )曲线如图 13 所示,所提方法取得最佳的分类性能。上述结果表明,所提潜在损失和合成缺陷添加过程,可明显提升检测精




图 12 100 个正常样本和 100 个缺陷样本异常分数图

Fig. 12 Abnormal score graph of 100 normal samples and 100 defective samples

表 2 不同方法效果对比

Table 2 Effect comparison of different methods

Method	AUC	Average time of single image detection /ms
AnoGAN	0.718	7320
VQ-VAE <sup>[26]</sup>	0.883	25.1
GANomaly	0.792	52.2
Skip-GANomaly	0.686	37.4
Skip-GANomaly (+proposed $L_{lat}$ )	0.734	39.8
Proposed method without proposed $L_{lat}$	0.916	19.4
Proposed method	<b>0.979</b>	<b>19.2</b>

度和检测效率。

由于在训练过程中加入了合成缺陷,模型学到了修复缺陷的能力,因此对噪声的鲁棒性强,具有一定的抗噪能力。把 1000 张测试集图像进行随机高斯噪声添加、过曝、曝光不足处理,形成干扰数据集,如图 14 所示。其中,第 1 行是缺陷图像进行高斯噪声添加、过

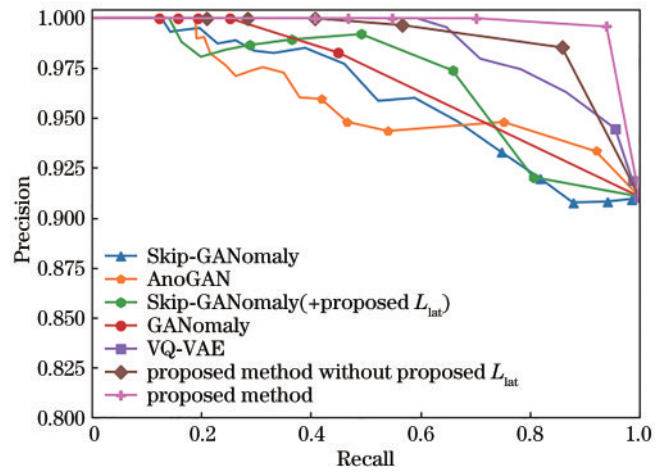


图 13 各种方法的查准-召回曲线

Fig. 13 Precision-recall curve of various methods

曝和曝光不足操作后的图像,第 2 行是正常图像进行高斯噪声添加、过曝和曝光不足操作后的图像,然后用同样的权重去测试模型,并与在正常测试数据集上测试的模型进行对比,结果如表 3 所示。

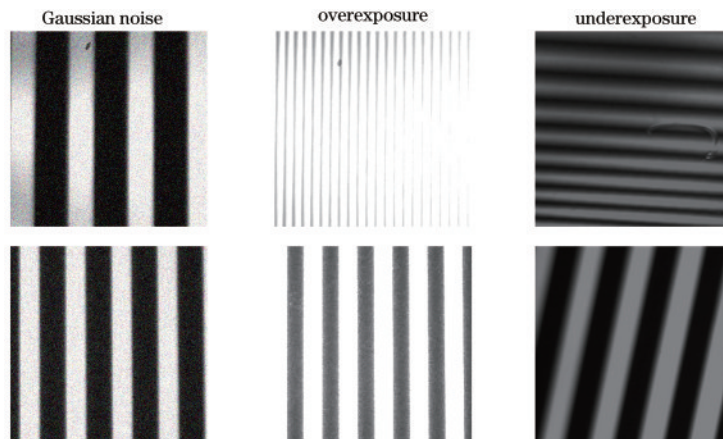


图 14 干扰数据集图像

Fig. 14 Interference dataset images



表 3 不同方法在干扰数据下与原始数据的 AUC 差距

Table 3 AUC difference between different methods and original data under interference data

Method	AUC of original test data	AUC of interference data	Decrease /%
AnoGAN	0.718	0.627	12.7
VQ-VAE	0.883	0.746	15.5
GANomaly	0.792	0.658	16.9
Skip-GANomaly	0.686	0.45	34.4
Skip-GANomaly(+proposed $L_{lat}$ )	0.734	0.641	12.7
Proposed method without proposed $L_{lat}$	0.916	0.818	10.7
Proposed method	0.979	0.933	<b>4.7</b>

可以看到,在面对干扰的数据时,所提方法的 AUC 只下降了 0.046(4.7%),保持较高 AUC 的同时相比于其他方法 AUC 的下降也是最少的,即所提方法具有良好的抗噪抗干扰能力。

## 5 讨 论

得益于背投条纹结构光的成像方法,图像具有较强烈规律性,是一种良好表示的数据,无监督 GAN 方法可以“感知”到这种规律性而减少噪声的影响。此外,相比于传统的只使用正常样本训练的方法,所提方法在训练阶段加入合成缺陷,可以取得更好效果。这是因为如果只用正常样本去训练,模型易于被训练出强大的重构能力,会使缺陷样本的缺陷区域也被重建出来,此时缺陷图像与重建图像之间的差距有限,导致异常检测失败。而在训练阶段加入合成缺陷后,训练过程就变成了网络学习如何正确修复图像缺陷区域为正常区域的过程,对于输入的缺陷图像,其生成的图像会倾向于成为没有缺陷的正常图像,此时两者的差别就会更大,易于发现异常。

相比于传统 Skip-GANomaly 只计算编码器潜在表示的差距,所提潜在表示损失通过计算原图和生成图在模型编码层的每一层特征图的距离和作为损失函数的一种惩罚,能反映图像更丰富的信息。结合在训练过程中加入合成缺陷的方法,能更好生成这种规律性的图像,可以进一步提升模型的重建效果以及修复缺陷区域,进而提高缺陷图像和生成图像之间的差异。

## 6 结 论

针对偏光片外观缺陷,提出一种新的编码解码对抗网络检测方法。通过引入合成缺陷模块,使网络捕获偏光片正常图像在潜在向量空间中的训练数据分布,在无异常样本训练模型的情况下实现了偏光片外观缺陷检测。针对 1000 张测试集图像,所提方法的检测准确率为 94.6%,平均检测时间为 19.2 ms。相比于目前流行的异常检测方法,AUC 达到 97.9%,有明显提高,具有较好的实际应用前景,未来将开发相关的自动化检测装备,在产线中进一步验证该方法的效果。

## 参 考 文 献

- [1] Yoon Y G, Lee S L, Chung C W, et al. An effective defect inspection system for polarized film images using image segmentation and template matching techniques[J]. *Computers & Industrial Engineering*, 2008, 55(3): 567-583.
- [2] Kuo C F J, Chiu C H, Chou Y C. Research and development of intelligent on-line real-time defect inspection system for polymer polarizer[J]. *Polymer-Plastics Technology and Engineering*, 2009, 48(2): 185-192.
- [3] Cheng C C, Jao H M. Application of the Haar wavelet to Mura detection for polarizer[C]//2013 IEEE International Conference on Industrial Technology, February 25-28, 2013, Cape Town, South Africa. New York: IEEE Press, 2013: 1080-1085.
- [4] Won Y, Joo H, Kim J. Classification of defects in the polarizer of display panels using the convolution neural network (CNN)[J]. *International Journal of Computing, Communication and Instrumentation Engineering*, 2017, 4(1): 139-142.
- [5] Lei H W, Wang B, Wu H H, et al. Defect detection for polymeric polarizer based on faster R-CNN[J]. *Journal of Information Hiding and Multimedia Signal Processing*, 2018, 9(6): 1414-1420.
- [6] Liu R Z, Sun Z Y, Wang A H, et al. Lightweight efficient network for defect classification of polarizers[J]. *Concurrency and Computation: Practice and Experience*, 2020, 32(11): 1-9.
- [7] Liu R Z, Sun Z Y, Wang A H, et al. Real-time defect detection network for polarizer based on deep learning[J]. *Journal of Intelligent Manufacturing*, 2020, 31(8): 1813-1823.
- [8] Huang G J, Deng Y L. Polarizer visual defect detection and classification based on improved LBP and SVM algorithm[J]. *Computer Engineering and Applications*, 2020, 56(22): 251-255.
- [9] Schlegl T, Seeböck P, Waldstein S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[M]//Niethammer M, Styner M, Aylward S, et al. *Information processing in medical imaging. Lecture notes in computer science*. Cham: Springer, 2017, 10265: 146-157.
- [10] Akcay S, Atapour-Abarghouei A, Breckon T P.

- GANomaly: semi-supervised anomaly detection via adversarial training[M]//Jawahar C V, Li H D, Mori G, et al. Computer vision-ACCV 2018. Lecture notes in computer science. Cham: Springer, 2019, 11363: 622-637.
- [11] Akçay S, Atapour-Abarghouei A, Breckon T P. Skip-GANomaly: skip connected and adversarially trained encoder-decoder anomaly detection[C]//2019 International Joint Conference on Neural Networks (IJCNN), July 14-19, 2019, Budapest, Hungary. New York: IEEE Press, 2019.
- [12] Yu C L, Chen P B, Zhong X P, et al. Saturated imaging for inspecting transparent aesthetic defects in a polymeric polarizer with black and white stripes[J]. Materials, 2018, 11(5): 736.
- [13] 王维, 王杰, 黄易杨, 等. 基于偏振透射结构光的透明物体表面缺陷检测方法[J]. 光学学报, 2021, 41(18): 1812002.  
Wang W, Wang J, Huang Y Y, et al. Surface defect detection in transparent objects using polarized transmission structured light[J]. Acta Optica Sinica, 2021, 41(18): 1812002.
- [14] Deng Y L, Xu S P, Chen H Q, et al. Inspection of extremely slight aesthetic defects in a polymeric polarizer using the edge of light between black and white stripes[J]. Polymer Testing, 2018, 65: 169-175.
- [15] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10) [2022-03-06]. <https://arxiv.org/abs/1406.2661>.
- [16] Huang H, Yu P S, Wang C H. An introduction to image synthesis with generative adversarial nets[EB/OL]. (2018-03-12)[2022-03-05]. <https://arxiv.org/abs/1803.04469>.
- [17] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 105-114.
- [18] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2242-2251.
- [19] 韩子硕, 王春平, 付强, 等. 基于空间分离表征 GAN 的遥感图像模式互转[J]. 光学学报, 2021, 41(7): 0728003.  
Han Z S, Wang C P, Fu Q, et al. Remote sensing image mode translation by spatial disentangled representation based GAN[J]. Acta Optica Sinica, 2021, 41(7): 0728003.
- [20] Zhao Z X, Li B, Dong R, et al. A surface defect detection method based on positive samples[M]//Geng X, Kang B H. PRICAI 2018: trends in artificial intelligence. Lecture notes in computer science. Cham: Springer, 2018, 11013: 473-481.
- [21] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [22] Baldi P. Autoencoders, unsupervised learning and deep architectures[C]//UTLW'11: Proceedings of the 2011 International Conference on Unsupervised and Transfer Learning workshop-Volume 27, July 2, 2011, Bellevue, Washington, USA. New York: ACM Press, 2011: 37-50.
- [23] Mahendran A, Vedaldi A. Understanding deep image representations by inverting them[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 5188-5196.
- [24] Deng Y L, Pan X Z, Zhong X P, et al. Improved imaging of extremely-slight transparent aesthetic defects using a saturation level-guided method[J]. Optics Express, 2020, 28(3): 3699-3716.
- [25] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2022-02-05]. <https://arxiv.org/abs/1412.6980>.
- [26] van den Oord A, Vinyals O, Kavukcuoglu K. Neural discrete representation learning[EB/OL]. (2017-11-02) [2022-06-05]. <https://arxiv.org/abs/1711.00937>.