

基于双通道生成对抗网络的镜片缺陷数据增强

孟奇¹, 苗华^{1*}, 李琳¹, 国博¹, 刘婷婷¹, 米士隆²

¹ 长春理工大学光电工程学院, 吉林 长春 130022;

² 东莞市宇瞳光学科技股份有限公司研发技术中心, 广东 东莞 523841

摘要 针对小样本条件下深度学习缺陷检测算法识别率较低的问题,提出一种基于双通道生成对抗网络的数据增强方法。由全局鉴别层和局部鉴别层两通道组成生成对抗网络,其中局部鉴别器可以增加缺陷类型的置信度损失,实现对局部信息的增强。采用所提方法在镜片缺陷图像数据集上进行实验。实验结果表明,所提方法的最近邻留一指标、最大均值差异和 Wasserstein 距离分别达到 0.52、0.15 和 2.81;对于麻点、划痕、气泡和异物的缺陷类型图像,生成的图像质量优于条件生成对抗网络、Wasserstein 距离生成对抗网络和马尔科夫判别器。双通道生成对抗网络生成的镜片图像有着多样性的全局信息和高质量的细节特征,可以有效增强镜片缺陷数据集。

关键词 机器视觉; 神经网络; 数据增强; 生成对抗网络; 缺陷检测; 镜片缺陷; 计算机视觉

中图分类号 TP391.9; TH165+.4

文献标志码 A

doi: 10.3788/LOP202158.2015001

Data Enhancement of Lens Defect Based on Dual Channel Generative Adversarial Networks

Meng Qi¹, Miao Hua^{1*}, Li Lin¹, Guo Bo¹, Liu Tingting¹, Mi Shilong²

¹ School of Opto-Electronic Engineering, Changchun University of Science and Technology, Changchun, Jilin 130022, China;

² R&D Center, Dongguan Yutong Optical Technology Co., Ltd, Dongguan, Guangdong 523841, China

Abstract Aiming at the problem of the low recognition rate of the deep learning defect detection algorithm under the condition of small samples, a data enhancement method based on two-channel generative adversarial network is proposed. The generative adversarial network is composed of two channels, such as global discriminator and local discriminator. The local discriminator can increase the confidence loss of the defect type and realize the enhancement of local information. The proposed method is used to conduct experiments on the lens defect image dataset. Experimental results show that the nearest neighbor index, maximum mean difference, and Wasserstein distance of the proposed method are 0.52, 0.15 and 2.81, respectively. For the defect type images of pitting, scratches, bubbles and foreign bodies, the generated image quality is better than that of conditional generated adversarial network, Wasserstein distance generated adversarial network and Markov discriminator. The lens image generated by the dual-channel generation confrontation network has diverse global information and high-quality detailed features, which can effectively enhance the lens defect data set.

Key words machine vision; neural networks; data enhancement; generative adversarial network; defect detection; lens defect; computer vision

OCIS codes 150.3040; 150.1835; 100.4996

收稿日期: 2020-11-28; 修回日期: 2020-12-18; 录用日期: 2021-01-02

基金项目: 吉林省科技发展计划(20200404157YY)

通信作者: * ilev24@163.com

1 引言

镜片作为光学镜头的核心部件之一,是实现光学性能的最基本保障。然而受到生产工艺和一些外在不可控因素的影响,镜片上会形成各种类型的缺陷,如划痕、异物、气泡和麻点等。传统的镜片缺陷检测方法主要依靠人工视觉,但该检测方法受到主观因素的影响大,致使检测精度低,检测速度慢,无法满足企业生产的需求^[1]。近年来,由于深度学习模型在诸多计算机视觉领域的成功表现,众多学者将其引入缺陷检测中^[2-7],以提高镜片缺陷的检测精度。深度学习模型优秀的检测识别能力依赖于大量的数据样本,但镜片的缺陷数据样本较少,而图像数据的采集需要较高的成本^[8-9],因此基于已有的数据进行数据增强来解决图像数据数量和质量不足等问题是极为必要的。

传统的数据增强方法有翻转、旋转、缩放变形、裁剪、旋转畸变变换和极坐标变换等。虽然上述方法能够实现数据增强,但是生成图像的深度特征重复,有很多冗余信息,不能有效提高检测网络模型的性能。生成对抗网络(GAN)自2014年由Goodfellow等^[10]提出,其在数据增强方面有显著效果,被誉为近十年来最富想象力的深度学习网络模型。带条件约束的条件生成对抗网络(CGAN)^[11-15]可以对生成的图像直接进行标注并生成指定标签的图像,但是训练难度较大,图像生成的稳定性较差。带梯度惩罚的Wasserstein GAN(WGAN)^[16-19]成功解决了GAN训练不稳定的问题,确保了生成样本的多样性,但造成生成图像的细节变模糊。马尔科夫判别器(Patch GAN)^[20]将鉴别器换成了全卷积网络,在数据增强中保持了高分辨率和多细节的特性,但其在提升整体图像质量的同时弱化了缺陷目标,并且对于低对比度目标的生成效果较差。

本文将缺陷图像理解成由缺陷背景和缺陷目标二者组成。缺陷背景是无规则的纹理图像,缺陷目标是具有一定特征(形状、大小和位置等)的图像。针对镜片缺陷图像的这一特点,提出一种基于双通道生成对抗网络(DualC-GAN)的缺陷图像数据增强方法,该方法可以解决缺陷检测过程中样本数量少的问题。使用双通道鉴别器分别判断生成的整体缺陷图像和缺陷目标的真实性^[21-22],对缺陷目标进行鉴别可以使生成的图像贴合缺陷样本,保留了缺陷目标的深度信息,能够鉴别出缺陷目标

的类别。

2 基本原理

生成对抗网络所生成的图像不同于传统方法得到的图像,生成的图像是通过提取已有数据集的高维特征组合而成,完全不同于数据集中的任何一张图像。因此在训练分类识别网络的过程中能够提供更多的图像特征,而且能够在一定程度上提升分类识别网络的泛化能力。

2.1 生成对抗网络的原理

GAN是从二人零和博弈中受到的启发,通过两个神经网络的相互对抗来达到最好的生成效果。这两个神经网络一个是生成器G,一个是鉴别器D。生成器G的作用是将服从某种分布的随机向量 z 输入到生成器G中,最终生成一张图像 $G(z)$ (高维向量)。鉴别器D的作用是将一张图像 x 输入到鉴别器D中以得到一个在0~1之间的数值 $D(x)$,当数值更接近于1时,判定输入的图像更接近于训练样本图像。实际上,GAN的训练目的就是使生成器G生成的图像 $G(z)$ 与样本图像 x 更相似,将鉴别器D生成的图像判断为真;同时鉴别器D的训练目的就是能够准确地分辨出输入的样本图像 x 和生成图像 $G(z)$ 。生成对抗网络的生成器损失函数 L_G 和鉴别器损失函数 L_D 可表示为^[10]

$$L_G = E_{z \sim p_z(z)} \{ \ln \{ D[G(z)] \} \}, \quad (1)$$

$$L_D = E_{x \sim p_x(x)} \{ \ln \{ D(x) \} \} + E_{z \sim p_z(z)} \{ \ln \{ 1 - D[G(z)] \} \}, \quad (2)$$

式中: p_z 为服从某种分布的随机噪声; p_x 为真实样本的分布; E 为期望算子; $z \sim p_z(z)$ 为 z 服从某种分布的随机噪声; $x \sim p_x(x)$ 为 x 服从真实样本的分布。

2.2 DualC-GAN

2.2.1 网络框架

镜片缺陷图像可以理解成是缺陷目标(前景)分布在镜片(背景)上的图像,DualC-GAN的作用是通过生成器来生成镜片缺陷图像,双通道鉴别器除了判断整张图像的真伪,同时鉴别局部的缺陷目标并标记出缺陷类型,即双通道鉴别器分别鉴别全局信息与局部信息。

生成器的输入为 $1 \times 1 \times 100$ 大小的高斯噪声和缺陷标签,标签作为条件用来限制生成缺陷的类型。通过投影整形(project and reshape)将输入层连接到 $14 \times 14 \times 128$ 大小的特征层上,再经过5次转置卷积模块可以得到 $448 \times 448 \times 3$ 大小的

特征层,最后使用 tanh 激活函数对其进行激活,输出 $448 \times 448 \times 3$ 大小的镜片缺陷图像。其中转置卷积模块由转置卷积层、批标准化层以及 ReLU 激活层组成,转置卷积核的大小为 3×3 ,步长为 2。生成器的框架如图 1 所示。

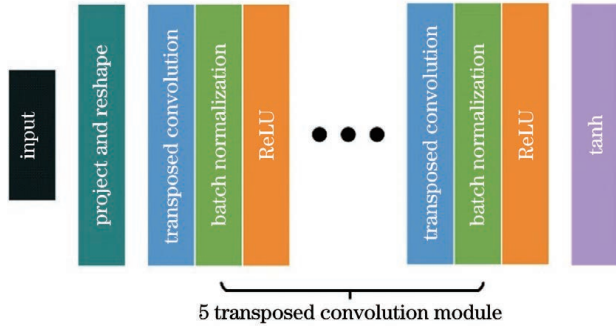


图 1 生成器的框架

Fig. 1 Framework for generator

鉴别器的输入为 $448 \times 448 \times 3$ 大小的图像和缺陷标签,特征提取层采用改进的 VGG-16 (Visual Geometry Group Network 16) 特征提取层。输入层之后增加一层卷积层,卷积核的大小为 3×3 ,步长为 2,用来增大网络的感受野以提取更高分辨率图像的特征,同时在池化层之后加上批标准化和 Leaky ReLU 激活函数,最后一层使用全连接层将特征转换成 $1 \times 1 \times 4096$ 大小的向量。鉴别器的框架如图 2 所示。

全局鉴别器 (D_{global}) 通道经过一次全连接后可以得到 $1 \times 1 \times 1$ 大小的向量,再通过 Sigmoid 层激活可以鉴别样本图像和生成图像的真假。局部鉴别器 (D_{local}) 通道经过一次全连接后输出 $14 \times 14 \times 10$ 大小的向量,此处使用 YOLO (You Only Look Once) 网络^[23-25] 对图像的局部信息进行识别,并判断局部信息为镜片缺陷的置信度。



图 2 鉴别器的框架

Fig. 2 Framework for discriminator

双通道鉴别器的优势:在保证全局信息多样性的前提下,使生成的局部信息更加真实,并且在全局和局部信息上保持较好的一致性。

2.2.2 损失函数

生成对抗网络是通过生成器和鉴别器之间的对

抗学习来训练网络,使用损失函数来驱动二者达到平衡,从而使生成器生成的假图像更加真实。本文的多通道鉴别器可以分别鉴别全局信息和局部信息。根据 CGAN 模型和改进的 WGAN (WGAN-GP) 模型,生成器的损失函数为

$$L_G(G) = E_{z \sim p_z, c \sim p_{data}} \left\{ \text{lb} \left\{ D_{global} [G(z, c), c] \right\} + \text{lb} \left\{ D_{local} [G(z', c), c] \right\} \right\}, \quad (3)$$

式中: z 为高斯噪声; c 为缺陷标签; $c \sim p_{data}$ 为 c 服从样本标签分布; z' 为由局部鉴别器识别到以生成

图像的缺陷为中心的局部图像。

全局鉴别器 D_{global} 的损失函数为

$$L_{D_{global}}(D) = E_{x, c \sim p_{data}} \left\{ \text{lb} [D_{global}(x, c)] \right\} + E_{z \sim p_z} \left\{ \text{lb} \left\{ 1 - D_{global} [G(x, c), c] \right\} \right\} + \lambda E_{x, c \sim p_{data}} \left(\left\| \nabla_x D_{global}(x, c) \right\|_2 - 1 \right)^2, \quad (4)$$

式中: λ 为梯度惩罚项权值; $E_{x, c \sim p_{data}} \left(\left\| \nabla_x D_{global}(x, c) \right\|_2 - 1 \right)^2$ 为 WGAN-GP 模型的梯度惩罚项。

优化生成器和全局鉴别器的损失函数可以使生成的图像更加真实,但是在图像中的缺陷区域存在一

定程度的模糊。本文提出的局部鉴别器可以有效地提高图像细节信息。局部鉴别器 D_{local} 的损失函数为

$$L_{D_{\text{local}}}(D) = E_{x_c, c \sim p_{\text{data}}} \{ \text{lb} [D_{\text{local}}(x_c, c)] \} + E_{z \sim p_z} \{ \text{lb} [1 - D_{\text{local}}(z, c)] \} + \sum_{c' \in c} [p(c') - \hat{p}(c')]^2, \quad (5)$$

式中: x_c 为以镜片缺陷为中心进行人工标注的局部样本图像; c' 为某种缺陷类型; $p(c')$ 为预测缺陷类型的概率; $\hat{p}(c')$ 为实际缺陷类型的概率; $\sum_{c' \in c} [p(c') - \hat{p}(c')]^2$ 为局部鉴别器对缺陷类型判断的置信度。

同时引入像素级损失函数 L_{pix} , 即利用生成图像和样本图像之间的 L_1 范数来改善模糊问题^[13], 表达式为

$$L_{\text{pix}} = \|x - G(z, c)\|_1. \quad (6)$$

综上, 双通道生成对抗网络的损失函数为

$$L = L_g + L_{D_{\text{global}}} + \lambda_1 L_{D_{\text{local}}} + \lambda_2 L_{\text{pix}}, \quad (7)$$

式中: λ_1 和 λ_2 分别为局部鉴别器损失和像素级损失在整个损失函数中的权值。

3 数据采集与评价方法

3.1 总体工作流程

实验的总体工作流程如图 3 所示, 处理步骤如下。

1) 数据准备: 通过机器视觉系统来采集镜片图像, 对采集到的图像进行预处理并进行缺陷标记, 作成数据集。

2) DualC-GAN 框架训练: 设计网络结构并使用镜片缺陷数据集进行模型训练, 生成镜片缺陷图像。

3) 性能评估: 使用最近邻留一(1-NN)、最大均值差异(MMD)和 Wasserstein 距离(WD)三种生成质量评估指标对由 DualC-GAN 生成的样本质量进行评估。

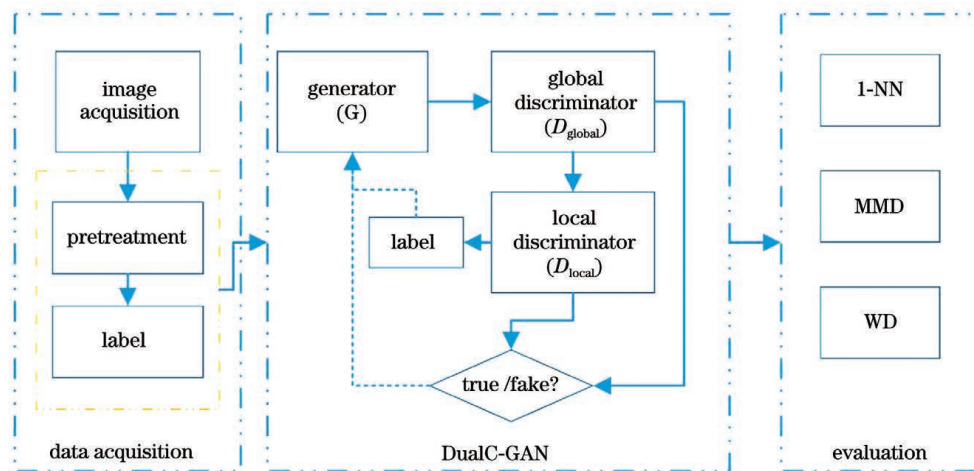


图 3 总体工作流程

Fig. 3 Overall workflow

3.2 数据准备

本文通过图 4(a) 的机器视觉镜片缺陷检测系统来采集图像, 该系统可以实现对宽度在 $60 \mu\text{m}$ 以上的划痕、异物、等效直径在 $400 \mu\text{m}$ 以上的气泡和麻点等缺陷的检测。

镜片缺陷图像中包含镜片托盘和镜片, 训练网络前需要将单个镜片图像单独裁剪出来。首先对图像进行预处理, 将单镜片分割出来, 预处理后的分割镜片如图 4(b) 所示; 接着通过 labelimg 工具对缺陷的位置、大小和类别进行人工标注, 结果如图 4(c) 所示, 标注信息如表 1 所示。每个镜片图像的裁剪尺

表 1 缺陷类型的标注

Table 1 Annotation of defect types

No.	Defect	Label	Count
1	Bubble	Bubble	332
2	Scratch	Scratch	303
3	Spot	Spot	325
4	Smudge	Smudge	318

寸为 $448 \text{ pixel} \times 448 \text{ pixel}$, 各类型缺陷的宽度大于 8 pixel 。最终获得气泡、麻点、划痕和异物 4 种类型的缺陷图像各约为 300 张。

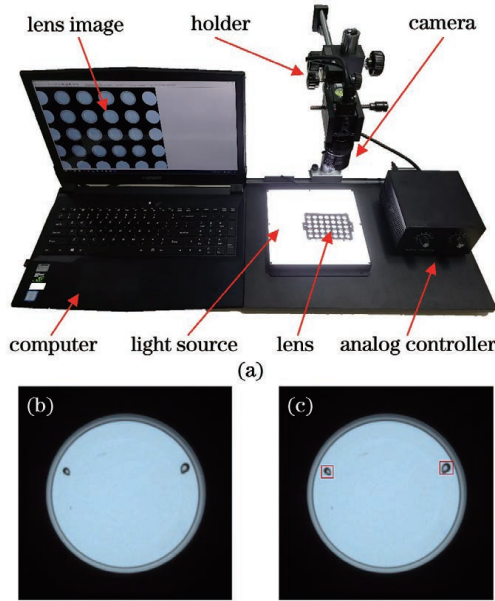


图 4 数据集的获取系统及结果。(a) 机器视觉镜片缺陷检测系统；(b) 预处理分割镜片；(c) 缺陷标注

Fig. 4 Dataset acquisition system and results.
(a) Machine vision lens defect detection system;
(b) pretreatment of segmented lenses; (c) defect labeling

3.3 性能评估指标

为了评估所提方法生成的图像质量,使用

三种质量评估指标进行评价,即 1-NN、MMD 和 WD。

1-NN 是判定样本数据集分布 (p_{data}) 和生成数据集分布 (p_g) 是否相同,若相同则证明生成模型的性能好。1-NN 是理想的度量指标,其可以检测过拟合和模式崩溃情况等问题。1-NN 的表达式为

$$\mathbf{x} \sim p_{\text{data}}, \mathbf{y} \sim p_g, |p_{\text{data}}| = |p_g|, \quad (8)$$

式中: \mathbf{y} 为生成的图像; $|p_{\text{data}}|$ 为样本数据分布的距离; $|p_g|$ 为生成数据分布的距离。当生成模型的效果足够好,且 $|p_{\text{data}}| = |p_g|$ 都非常大时,1-NN 服从约为 50% 的留一验证 (LOO) 的准确率。如果生成模型产生了过拟合,那么 LOO 的准确率会低于 50%。

MMD 是在希尔伯特空间对两个分布差异的一种度量,作为生成质量的评价指标,应用在生成模型中就是度量 p_{data} 和 p_g 之间的距离。若 MMD 值越小,则表示 p_{data} 和 p_g 越接近,生成模型的性能越好。计算 MMD 的过程中,首先要选择一个核函数 $k(\mathbf{x}, \mathbf{y})$,这里使用高斯核函数,表达式为

$$k(\mathbf{x}, \mathbf{y}) = \exp(-\|\mathbf{x} - \mathbf{y}\|^2). \quad (9)$$

则 MMD 的表达式为

$$E_{\mathbf{x}, \mathbf{x}' \sim p_{\text{data}}} [k(\mathbf{x}, \mathbf{x}')] - 2E_{\mathbf{x} \sim p_{\text{data}}, \mathbf{y} \sim p_g} [k(\mathbf{x}, \mathbf{y})] + E_{\mathbf{y}, \mathbf{y}' \sim p_g} [k(\mathbf{y}, \mathbf{y}')], \quad (10)$$

式中: \mathbf{x}' 为除 \mathbf{x} 以外的样本图像; \mathbf{y}' 为除 \mathbf{y} 以外的生成图像。WD 与 MMD 类似,若 WD 值越小,则生成模型的性能越好。WD 的估算值为

$$S = \frac{1}{N} \sum_{i=1}^N D(\mathbf{x}_i) - \frac{1}{N} \sum_{i=1}^N D(\mathbf{y}_i), \quad (11)$$

式中: N 为样本集的样本数量。WD 指标可以探测到生成样本的简单记忆情况和模式崩溃情况,并且计算比较快捷方便。

4 实验与结果讨论

4.1 训练参数的选择

实验将 DualC-GAN 应用在镜片缺陷数据增强中,以 $1 \times 1 \times 100$ 大小的高斯噪声和缺陷类型作为输入,实现生成指定类型的镜片缺陷图像。鉴别器的输入为 $448 \times 448 \times 3$ 大小的图像,判别输入是否为真实图像。实验条件为 Windows 10 系统, GTX1080Ti 显卡, Keras 2.1.5 框架,训练集为采集的 4 种缺陷类型图像,每种类型图像约有 300 张,尺

寸为 $488 \times 488 \times 3$ 的 RGB (Red, Green, Blue) 图像。

DualC-GAN 模型的训练过程包括了加载训练模型和整个网络训练。首先加载 ImageNet 数据集来预训练 VGG-16 的特征提取层,使用镜片缺陷数据集对 VGG-16 的特征提取层和局部鉴别器进行训练。然后对整个网络进行训练,训练分两个阶段进行,使用 Adam 作为优化器,总训练周期为 2000 轮。第一阶段只训练鉴别器的全局通道,冻结局部通道,训练周期为 1~500,学习率为 0.00025;第二阶段对双通道进行训练,训练周期为 500~2000,学习率为 0.0001。

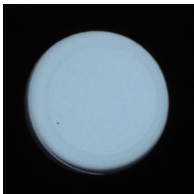
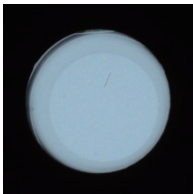
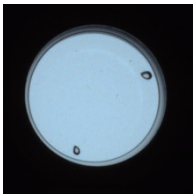
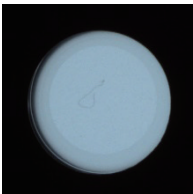
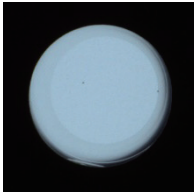
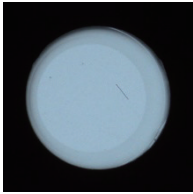
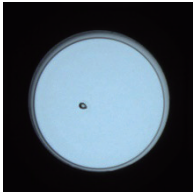
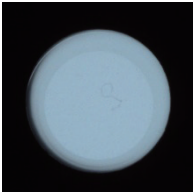
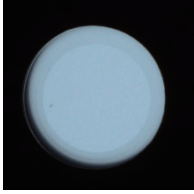
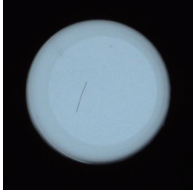
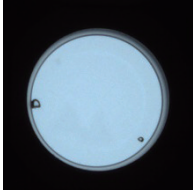
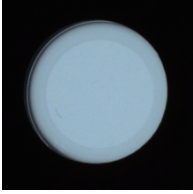
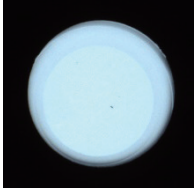
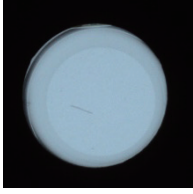
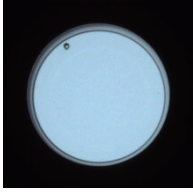

4.2 镜片缺陷生成质量的评估

为了测试所提方法在镜片缺陷图像数据增强的表现,分别使用 CGAN、WGAN-GP、Patch GAN 以及 DualC-GAN 生成的图像。选用了 1-NN、MMD 和 WD 三种评价指标来衡量模型的综合性能。为了方便对比分析,首先分析 DualC-GAN 生成的图像和样本图像之间的差别,然后以缺陷为中心截取

局部图像并对其进行观察,对比各网络的生成效果,结果如表 2 所示。

表 2 DualC-GAN 生成镜片缺陷图像的结果

Table 2 Results of lens defect image generated by DualC-GAN

Image	Spot	Scratch	Bubble	Smudge
Sample				
Fake 1				
Fake 2				
Fake 3				

从表 2 可以看到,DualC-GAN 生成的镜片缺陷图像边缘清晰,缺陷背景为清晰且无规则的纹理图像,缺陷目标随着缺陷类别的不同而具有一定的形状、大小和位置等特征,能够真实反映缺陷类型。通过主观观察来分析 DualC-GAN 生成的缺陷图像与样本图像,发现两者没有明显差别,即 DualC-GAN 生成的缺陷图像能够达到相机实拍图像的效果。镜片缺陷图像在不同算法下的对比结果如表 3 所示。

从表 3 可以看到,各模型均能够生成视觉上与样本相似的图像;对于划痕缺陷,4 种数据增强网络均表现良好,划痕缺陷特征清晰,与缺陷背景的对比较高;对于麻点缺陷,CGAN 和 WGAN-GP 生成的麻点缺陷图像中存在一定数量的没有麻点缺陷目标的图像,而 Patch GAN 和本文的 DualC-GAN 生成的麻点缺陷图像中都分布着麻点缺陷目标;对于气泡缺陷,CGAN 生成的气泡缺陷为深色的实心圆,

在气泡中间未表现出透光部分,WGAN-GP 生成的气泡缺陷虽然在气泡中间表现出透光部分,但是气泡中间与气泡边缘的对比度较低, Patch GAN 生成的气泡缺陷的对比度优于 WGAN-GP,但仍不能完全真实表达气泡缺陷,存在气泡边缘不闭合的情况, DualC-GAN 生成的气泡缺陷能够真实表达气泡缺陷特征,气泡缺陷边缘清晰流畅连贯,气泡中间透光部分的灰度值高且与气泡边缘的对比度高;对于异物缺陷,当图像中有单条异物且异物姿态不存在交叉和未形成封闭区域时,4 种数据增强网络均表现良好,当图像中存在两条异物距离较近且异物存在交叉或异物形成封闭区域时,CGAN 和 WGAN-GP 生成的异物缺陷目标在交叉处或异物形成的封闭处存在冗余像素,异物轮廓不准确, Patch GAN 也有一定数量的图像存在这种情况, DualC-GAN 生成的异物缺陷目标轮廓清晰准确,没有冗余像素的干扰。各模型生成质量的对比结果如表 4 所示。

表 3 镜片缺陷图像的生成对比

Table 3 Comparison of generation of lens defect images

















Network	Spot	Scratch	Bubble	Smudge
CGAN				
WGAN-GP				
Patch GAN				
DualC-GAN				

表 4 各模型的质量对比

Table 4 Quality evaluation of each model

Method	1-NN	MMD	WD
CGAN	0.78	0.30	4.36
WGAN-GP	0.72	0.27	3.52
Patch GAN	0.61	0.18	3.12
DualC-GAN	0.52	0.15	2.81

WD 值和 MMD 值越小,说明生成的图像质量越好。在 1-NN 值不小于 0.5 的情况下,越接近 0.5 表示生成的图像质量越好。从表 4 可以看到,所提方法的最近邻留一指标、最大均值差异和 Wasserstein 距离分别达到 0.52、0.15 和 2.81,其中 1-NN 值大于 0.5,而且比其他模型更接近 0.5,WD 值和 MMD 值也较其他网络更小。相比于其他生成模型,本文提出的 DualC-GAN 模型具有更好的生成质量,数据增强的性能更优。

5 结 论

针对镜片缺陷检测过程中图像数据不足的问题,设计双通道生成对抗网络进行数据增强,使用双通道鉴别器取代原本的单通道鉴别器并分别鉴别全局信息和局部信息,在保证生成图像具有多样性的同时改善生成图像模糊的问题,并提升局部信息的质量,使缺陷目标的轮廓更清晰。为了使生成的图像更真实,构建相应的损失函数。实验结果证明,提出的 DualC-GAN 模型相较于 CGAN、WGAN-GP 和 Patch GAN 有一定的竞争力,在 4 种缺陷类型图像的生成上,都具有较高质量的细节特征。相比于样本图像,生成图像没有明显差别,说明提出的 DualC-GAN 模型能够有效增强镜片缺陷的数据集,可用于镜片缺陷检测网络的训练与识别。

参 考 文 献

- [1] Sun L, Liu C, Yao H B. Automatic detection of

- water-mask for resin glasses by machine vision[J]. Journal of Jiangsu University (Natural Science Edition), 2018, 39(4): 425-430.
- 孙力, 刘晨, 姚红兵. 基于机器视觉的树脂镜片水印疵病检测[J]. 江苏大学学报(自然科学版), 2018, 39(4): 425-430.
- [2] Tao X, Hou W, Xu D. A survey of surface defect detection methods based on deep learning[J]. Acta Automatica Sinica, 2021, 47(5): 1017-1034.
- 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
- [3] Li S B, Yang J, Wang Z, et al. Review of development and application of defect detection technology[J]. Acta Automatica Sinica, 2020, 46(11): 2319-2336.
- 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- [4] Li D J, Li R H. Mug defect detection method based on improved Faster RCNN[J]. Laser & Optoelectronics Progress, 2020, 57(4): 041515.
- 李东洁, 李若昊. 基于改进 Faster RCNN 的马克杯缺陷检测方法[J]. 激光与光电子学进展, 2020, 57(4): 041515.
- [5] Zhang G S, Ge G Y, Zhu R H, et al. Gear defect detection based on the improved YOLOv3 network[J]. Laser & Optoelectronics Progress, 2020, 57(12): 121009.
- 张广世, 葛广英, 朱荣华, 等. 基于改进 YOLOv3 网络的齿轮缺陷检测[J]. 激光与光电子学进展, 2020, 57(12): 121009.
- [6] Li S Y, Fu G Y, Cui Z M, et al. Data augmentation in SAR images based on multi-scale generative adversarial networks[J]. Laser & Optoelectronics Progress, 2020, 57(20): 201018.
- 李诗怡, 付光远, 崔忠马, 等. 基于多尺度生成对抗网络的 SAR 图像样本增广[J]. 激光与光电子学进展, 2020, 57(20): 201018.
- [7] Chang J, Guan S Q, Shi H Y, et al. Strip defect classification based on the improved generative adversarial networks and MobileNetV3[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410016.
- 常江, 管声启, 师红宇, 等. 基于改进生成对抗网络和 MobileNetV3 的带钢缺陷分类[J]. 激光与光电子学进展, 2021, 58(4): 0410016.
- [8] Wang S, Guo R F, Dong Z Y, et al. Data enhancement method for deep learning in mixed reality assembly inspection[J]. Computer Integrated Manufacturing Systems, 2021, 27(3): 716-727.
- 王帅, 郭锐锋, 董志勇, 等. 混合现实装配检测中深度学习的数据增强方法[J]. 计算机集成制造系统, 2021, 27(3): 716-727.
- [9] Meng L, Zhong J P, Li N. Generating algorithm of medical image simulation data sets based on GAN[J]. Journal of Northeastern University (Natural Science), 2020, 41(3): 332-336.
- 孟球, 钟健平, 李楠. 基于 GAN 的医学图像仿真数据集生成算法[J]. 东北大学学报(自然科学版), 2020, 41(3): 332-336.
- [10] Goodfellow I, Pougetabadié-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014, 3(2): 2672-2680.
- [11] Mirza M, Osindero S. Conditional generative adversarial nets[EB/OL]. (2014-11-06) [2020-04-19]. <https://arxiv.org/abs/1411.1784>.
- [12] Tan B D, Yang J, Lai Q P, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network[J]. Automation of Electric Power Systems, 2019, 43(1): 149-157.
- 谭本东, 杨军, 赖秋频, 等. 基于改进 CGAN 的电力系统暂态稳定评估样本增强方法[J]. 电力系统自动化, 2019, 43(1): 149-157.
- [13] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [14] Zhao H X, Shi H B, Wu J, et al. Research on imbalanced learning based on conditional generative adversarial networks[J]. Control and Decision, 2021(3): 619-628.
- 赵海霞, 石洪波, 武建, 等. 基于条件生成对抗网络的不平衡学习研究[J]. 控制与决策, 2021(3): 619-628.
- [15] Dar S U H, Yurt M, Karacan L, et al. Image synthesis in multi-contrast MRI with conditional generative adversarial networks[J]. IEEE Transactions on Medical Imaging, 2019, 38(10): 2375-2388.
- [16] Arjovsky M, Bottou L. Towards principled methods for training generative adversarial networks[EB/OL]. (2017-01-17) [2020-04-19]. <https://arxiv.org/abs/1701.04862>.
- [17] Arjovsky M, Chintala S, Bottou L. Wasserstein GAN[EB/OL]. (2017-01-26) [2020-04-19]. <https://arxiv.org/abs/1701.07875>.
- [18] Cui Z Y, Zhang M R, Cao Z J, et al. Image data augmentation for SAR sensor via generative adversarial nets[J]. IEEE Access, 2019, 7: 42255-42268.

- [19] Mu D, Meng W, Zhao S H, et al. Intelligent optical communication based on Wasserstein generating adversarial network[J]. Chinese Journal of Lasers, 2020, 47(11): 1106005.
牟迪, 蒙文, 赵尚弘, 等. 基于 Wasserstein 生成对抗网络的智能光通信[J]. 中国激光, 2020, 47(11): 1106005.
- [20] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [EB/OL]. (2018-02-19) [2018-03-01]. <https://arxiv.org/abs/1703.10593>.
- [21] Li J X, Sun L J, Wang W J. Appearance design method of packaging product based on dual discriminator GAN[J]. Packaging Journal, 2020, 12(2): 77-83.
李佳昕, 孙刘杰, 王文举. 基于双鉴别器 GAN 的包装类产品外观设计法[J]. 包装学报, 2020, 12(2): 77-83.
- [22] Chang Y S, Lafata K, Segars W P, et al. Development of realistic multi-contrast textured XCAT (MT-XCAT) phantoms using a dual-discriminator conditional-generative adversarial network (D-CGAN) [J]. Physics in Medicine and Biology, 2020, 65(6): 065009.
- [23] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [24] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 6517-6525.
- [25] Redmon J, Farhadi A. YOLOv3: an incremental improvement [EB/OL]. (2018-04-08) [2020-05-20]. <https://arxiv.org/abs/1804.02767>.