



计算机科学

COMPUTER SCIENCE

一种面向工业产品表面缺陷图像的色调增强方法

罗月童, 李超, 段昶, 周波

引用本文

罗月童, 李超, 段昶, 周波. 一种面向工业产品表面缺陷图像的色调增强方法[J]. 计算机科学, 2023, 50(11A): 230200089-6.

LUO Yuetong, LI Chao, DUAN Chang, ZHOU Bo. [Hue Augmentation Method for Industrial Product Surface Defect Images](#) [J]. Computer Science, 2023, 50(11A): 230200089-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于边缘引导的多尺度医学影像分割方法](#)

Medical Image Segmentation Based on Multi-scale Edge Guidance

计算机科学, 2023, 50(11A): 220900059-7. <https://doi.org/10.11896/jsjcx.220900059>

[基于语义注意力的医学图像超分辨率方法](#)

Medical Image Super-resolution Method Based on Semantic Attention

计算机科学, 2023, 50(11A): 221200107-6. <https://doi.org/10.11896/jsjcx.221200107>

[一种基于因果推理的垃圾分类方法](#)

Novel Method for Trash Classification Based on Causal Inference

计算机科学, 2023, 50(11A): 220800218-6. <https://doi.org/10.11896/jsjcx.220800218>

[接诉即办智能派单业务调度算法研究](#)

Study on Scheduling Algorithm of Intelligent Order Dispatching

计算机科学, 2023, 50(11A): 230300029-7. <https://doi.org/10.11896/jsjcx.230300029>

[一种基于CutMix的增强联邦学习框架](#)

Enhanced Federated Learning Frameworks Based on CutMix

计算机科学, 2023, 50(11A): 220800021-8. <https://doi.org/10.11896/jsjcx.220800021>

一种面向工业产品表面缺陷图像的色调增强方法

罗月童^{1,2} 李超¹ 段昶¹ 周波^{1,2}

1 合肥工业大学计算机与信息学院 合肥 230601

2 安全关键工业测控技术教育部工程研究中心 合肥 230009

(ytluo@hfut.edu.cn)

摘要 在基于深度学习的工业缺陷检测中,采样数据的色调分布、缺陷的位置分布往往与检测数据存在着差异,这会导致检测模型性能不佳,基于GAN(Generative Adversarial Networks)的数据增强方法为常用的解决方法,文中设计了HC-GAN和T-GAN来分别进行色调和缺陷位置的增强。在HC-GAN中,通过构建语义保持模块和色调控制模块,能够在不改变缺陷特征的前提下实现基于参考数据的色调增强;在T-GAN中,通过输入、输出数据的成对设定,实现了缺陷位置转移;在实际应用中,两个GAN的串联使用能降低训练数据在色调和空间上的不均衡性,提高了模型的检测性能。最后进行了实验验证,结果表明,所提方法生成的数据实现了缺陷图像的色调增强和位置增强,提高了工业产品表面缺陷检测的精度。

关键词:生成对抗网络;深度学习;数据增强;缺陷检测

中图分类号 TP391.41

Hue Augmentation Method for Industrial Product Surface Defect Images

LUO Yuetong^{1,2}, LI Chao¹, DUAN Chang¹ and ZHOU Bo^{1,2}

1 School of Computer and Information, Hefei University of Technology, Hefei 230601, China

2 Engineering Research Center of Safety Critical Industrial Measurement and Control Technology, Ministry of Education, Hefei 230009, China

Abstract The hue distribution of industrial sampling data and the spatial distribution of defects are often different from test data, which often leads to poor performance of defect detection models based on deep learning. Therefore, data augmentation based on generative adversarial networks(GAN) is a common solution. Two GANs (HC-GAN and T-GAN) are designed to perform hue augmentation and defect location augmentation respectively. By constructing content consistency module and hue controlled module, HC-GAN can achieve hue augmentation based on reference data without changing defect characteristics. By pairing the input and output data, T-GAN realizes the defect location transfer. In addition, two GANs can also be used in tandem to achieve both hue augmentation and position transfer. Finally, hue distribution statistics and object detection effect tests are carried out on the generated data. The results show that the data generated by the proposed method can achieve hue augmentation and position augmentation, and improve the accuracy of surface defect detection of industrial products.

Keywords GAN, Deep learning, Data augmentation, Defect detection

1 引言

随着深度学习的发展,基于有监督的深度学习目标检测算法凭借着速度快、精度高等优点被应用于工业产品的表面缺陷检测中^[1]。在实际应用中,基于有监督的深度学习模型的训练往往需要大量的训练数据才能取得较好的检测结果,而在工业检测中,样本数据一般为人工获取,数量通常有限,且不同批次的工业数据往往存在色调分布差异、空间分布差异,已有采样样本往往难以覆盖检测数据上的缺陷分布,这就导致漏检的风险增加^[2]。而工业产品中通常良品(无缺陷图像)较多,获取方便快速,能够覆盖采样图像的所有色调分布,基于此,本文拟采用GAN^[3]进行数据增强,通过学习同批次大量无缺陷图像的色调分布,使得生成器能够将训练数据中

缺陷图像的色调转换至与无缺陷图像色调分布一致,并串联了一个GAN来实现缺陷位置转移,从而达到均衡缺陷色调分布和位置分布的目的。

当前基于GAN的相关研究主要应用在以下场景:在风格迁移场景中,Isola等提出了一个基于成对数据的通用框架pix2pix^[4],用于完成两种图像的风格转换,例如将图像由灰度色调转换至彩色色调;Zhu等消除了前者对于成对数据的限制,提出了一种无需配对数据的循环一致性生成对抗网络CycleGAN(Cycle-Consistent Adversarial Networks)^[5],虽然其减少了对成对数据的要求,但其依赖更多的数据用于信息建模;在妆容迁移场景中,Li等提出了一个双输入、双输出生成对抗网络BeautyGAN^[6],用于自动上妆和卸妆,通过在局部区域使用像素级直方图损失,实现了实例级的妆容色调

基金项目:国家自然科学基金(61602146);国家重点基础研究发展计划(2017YFB1402200)

This work was supported by the National Natural Science Foundation of China (61602146) and National Basic Research Program of China (2017YFB1402200).

通信作者:周波(zhoubo810707@hfut.edu.cn)

转换,但在两种妆容图像存在表情和姿态差异的情况下,其色调迁移效果往往不佳。为了解决以上问题,Jiang 等提出了 PSGAN (Pose and Expression Robust Spatial-Aware GAN)^[7],在原始图像与参考图像存在差异的情况下,仍能出色地完成妆容迁移;在图像上色场景中,Cao 等^[8]基于条件生成对抗网络,设计了一种用于无监督多样化着色的方法,实现了灰度图到彩色图的色调转换,然而该方法在进行色调建模时依赖大量数据。为了解决该问题,Yoo 等提出了一种新颖的记忆增强模型 MemoPainter^[9],实现了在少样本数据的情况下产生高质量的上色效果。综上,尽管近年来在 GAN 应用上取得了一定成果,但在工业检测中的应用依然面临着如下挑战:GAN 通常基于大量真实的缺陷图像来学习图像分布,在缺陷图像数量有限的情况下,学习到的分布与真实缺陷图像分布往往存在较大偏差,导致生成的缺陷图像在视觉上不够真实,难以利用其进行有效的数据增强^[10]。

基于此,本文提出了一种面向工业表面缺陷数据的色调增强方法,其主要贡献有:(1)通过引入 Content Consistency 模块、Hue Controlled 模块,在保留缺陷特征的前提下,设计了能将所参考的无缺陷图像色调分布迁移到有缺陷图像上的 HC-GAN(Hue Controlled GAN),实现了基于色调分布的工业缺陷数据增强;(2)通过缺陷图像与对应的无缺陷芯片图像构成成对输入数据的设计,使得在仅使用少量成对缺陷图像的前提下,实现了 T-GAN(Transfer GAN)生成图像上缺陷能够在指定位置生成,完成了工业缺陷的位置移动,增加了工业缺陷位置的多样性。

2 本文方法

2.1 本文方法的结构

本文设计了两种 GAN 串联的方式来实现上述内容,HC-GAN 用于解决图像色调不均衡的问题,T-GAN 用于转移缺陷位置,T-GAN 中生成图像可以作为 HC-GAN 中的输入,网络结构如图 1 所示。

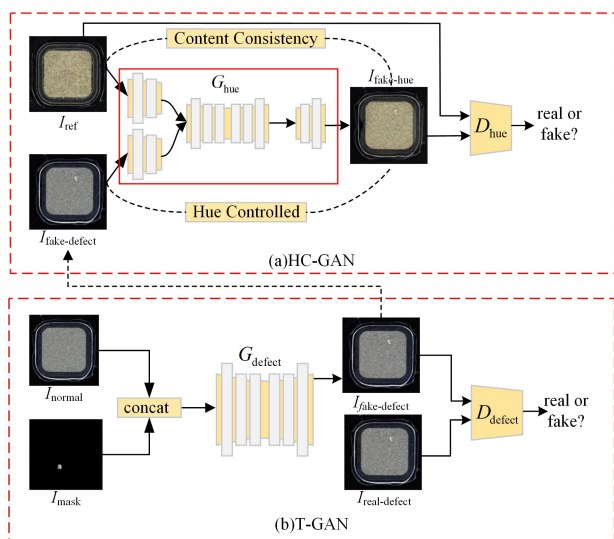


图 1 整体网络结构

Fig. 1 Overall network structure

在 HC-GAN 的设计中,为使生成图像在色调分布上与参照图像保持一致,设计了 Hue Controlled 模块,但由于生成器 G_{hue} 在学习无缺陷图像色调分布的同时,也学习到了参照图

像的语义特征,带缺陷图像在色调转换后,有可能导致缺陷特征丢失,为保证除色调外的特征不发生变化,本文设计了 Content Consistency 模块。HC-GAN 网络结构如图 1(a)中的虚线框所示,其生成器 G_{hue} 接收两个输入,分别为缺陷图像 $I_{fake-defect}$ 和用于色调参考的无缺陷图像 I_{ref} ,输出图像为 $I_{fake-hue}$,拟通过对抗训练使得 $I_{fake-hue}$ 具有 $I_{fake-defect}$ 图像的内容和 I_{ref} 图像的色调;HC-GAN 中判别器 D_{hue} 接收的输入为无缺陷的色调参考图像 I_{ref} 和生成器 G_{defect} 生成图像 $I_{fake-hue}$,通过色调判断,将 $I_{fake-hue}$ 和 I_{ref} 区分开。下文将分别介绍 HC-GAN 中 Content Consistency 模块、Hue Controlled 模块、HC-GAN 的损失函数的设计,以及缺陷转移 GAN(T-GAN)。

2.2 Hue Controlled 模块

在 HC-GAN 中,判别器 D_{hue} 的正样本输入为无缺陷色调参考图像,直接进行训练难以保证其仅将色调信息作为区分正负样本的标准。为了解决以上问题,本文引入了 Hue Controlled 模块,以保证生成图像色调与参考图像一致。具体做法如下,首先对 $I_{fake-defect}$ 和 I_{ref} 采用直方图匹配算法^[11]进行直方图匹配,得到重映射图像,随后计算生成图像 $I_{fake-hue}$ 和重映射图像之间的均方差,用于衡量两者的距离,将其作为 Hue Controlled 模块的损失函数。Hue Controlled 模块中损失函数如式(1)所示,其中 HM 表示直方图匹配算法。在训练过程中,通过最小化损失函数来优化生成器 G_{hue} 的参数,使生成图像和重映射图像之间的分布距离逐渐减小,从而保证生成图像的色调分布与 I_{ref} 一致。

$$L_{hc} = [I_{fake-hue} - HM(I_{fake-defect}, I_{ref})]^2 \quad (1)$$

2.3 Content Consistency 模块

在深度神经网络中,浅层部分网络的感受野较小,重叠区域也较小,提取到的特征一般为图像的细粒度信息,例如图像的颜色、纹理、边缘、棱角信息等,而随着网络层数的加深,感受野逐渐变大,感受野之间的重叠区域增加,提取到的图像特征被压缩,获取到的信息为高度抽象的语义信息^[12]。在本文中,为确保图像内容不发生变化,即为保证缺陷语义不发生变化,需要采用深层网络进行特征提取,基于此,本文引入了 Content Consistency 模块。

Content Consistency 模块由已在 ImageNet^[13] 数据集上预训练好的 VGG-16^[14] 网络组成,其输入为带缺陷图 $I_{fake-defect}$ 和生成图 $I_{fake-hue}$,两者经过 VGG-16 网络进行特征提取,过滤掉了色调等低维信息,得到对应的高维特征向量,然后使用均方差来衡量两个高维特征之间的距离。Content Consistency 模块损失函数如式(2)所示,其中 VGG_{ij} 表示 VGG 网络最后一层第 (i, j) 位置处的激活值。在 GAN 的训练中,通过不断优化 L_{cc} 损失,来缩小小图像间的特征距离,使得生成器 G_{hue} 生成的图像 $I_{fake-hue}$ 在语义上与 $I_{fake-defect}$ 保持一致,进而实现缺陷图像在色调变换的同时缺陷内容不受改变的功能。

$$L_{cc} = [VGG(I_{fake-defect}) - VGG(I_{fake-hue})]_{ij}^2 \quad (2)$$

2.4 生成位置可控的缺陷图像

为了增加缺陷位置的多样性,提升缺陷检测模型的泛化能力,本文设计了 T-GAN,实现了缺陷转移功能。T-GAN 网络的结构如图 1(b)所示,生成器 G_{defect} 接收两个输入,即参考图 I_{normal} 和缺陷 I_{mask} ,得到一个输出 $I_{fake-defect}$, $I_{fake-defect}$ 表示 I_{normal} 和 I_{mask} 融合之后得到的缺陷图像。判别器 D_{defect} 接收

两个输入 $I_{fake-defect}$ 和 $I_{real-defect}$, 并对输入图像进行判断, 输出其为真实图像的概率, 其中 $I_{real-defect}$ 表示真实的缺陷图像, 作为输入的正样本, $I_{fake-defect}$ 作为输入的负样本。判别器 D_{defect} 旨在学习到真实缺陷图像的分布, 并区分生成的缺陷图像的分布是否与 $I_{real-defect}$ 一致, 通过对抗训练, 使生成器 G_{defect} 学习到 I_{normal} 和 I_{mask} 之间的融合系数, 进而生成缺陷图像, 且可通过改变 I_{mask} 的位置来改变缺陷图像中缺陷的位置。在训练阶段, 考虑到工业缺陷中采样数据的稀缺性, 本文借鉴了 pix2pix^[4] 的思想, I_{normal} , I_{mask} , $I_{real-defect}$ 三者是成对存在的。

2.5 损失函数

本节的总损失函数如式(3)所示, 其中 L_{HC-GAN} 表示 HC-GAN 的损失函数, L_{T-GAN} 表示 T-GAN 的损失函数。下面将分别介绍两个损失函数的具体细节。

$$L_{total} = L_{HC-GAN} + L_{T-GAN} \quad (3)$$

HC-GAN 的损失函数如式(4)所示, 其中 G_{hue} 为 HC-GAN 中的生成器, 用于转换缺陷图像色调, D_{hue} 为 HC-GAN 判别器, ref 表示色调参考图像, fd 表示待转换色调的缺陷图像, L_{cc} 表示内容一致性损失, 用于监督 G_{hue} 来保持生成的图像与 $I_{fake-defect}$ 内容一致, L_{hc} 表示色调控制损失, 用于监督 G_{hue} , 使得生成图像在色调上与 ref 保持一致, α 和 β 表示控制各项损失之间重要程度的权重因子, 本文中 α 和 β 的取值为 0.5。

$$L_{HC-GAN} = \min_{G_{hue}} \max_{D_{hue}} E_{x \sim ref} [\log D_{hue}(x) + E_{y \sim fd, z \sim ref} [\log(1 - D_{hue}(G_{hue}(y, z)))] + \alpha L_{cc} + \beta L_{hc} \quad (4)$$

T-GAN 的损失函数如式(5)所示, 其中 G_{defect} 表示 T-GAN 中的生成器, 用于生成位置可控的缺陷图像, D_{defect} 为 T-GAN 中的判别器, rd 表示真实的缺陷图像, $normal$ 表示无缺陷图像, $mask$ 表示缺陷 $mask$ 图像。

$$L_{T-GAN} = \min_{G_{defect}} \max_{D_{defect}} E_{x \sim rd} \log D_{defect}(x) + E_{y \sim normal, z \sim mask} \log(1 - D_{defect}(G_{defect}(y, z))) \quad (5)$$

3 实验与分析

3.1 实验数据与实验设计

本文实验采用的数据集是由合作公司提供的工业 LED (Light-Emitting Diode) 芯片表面缺陷图像, 该数据通过工业相机拍摄后切割得到, 样图及缺陷特征如图 2 所示, 其中用红色框标记的为工业 LED 表面缺陷, 左图为 LED 芯片表面存在破损, 右图缺陷为 LED 芯片表面存在划伤。




图 2 LED 芯片及缺陷特征(电子版为彩图)

Fig. 2 LED chip and defect characteristics

为了评估实验数据的色调分布, 本文使用图像的平均色调值作为图像的色调指标, 计算方法如下: 将 RGB 图像转换至 HSV 格式, 将各像素点 H 分量值进行求和, 并除以图像的像素点个数, 得到平均色调。依次对已有训练数据、无缺陷数据亮度分布进行了统计, 得到了色调分布图(见图 3)。由图 3 可知, 训练数据色调分布(见图 3(a))与无缺陷图像色调分布

(见图 3(b))相差较大, 训练数据集平均色调分布在 [85, 90] 这一区间的分布数据较多, 占比约 54%, 而无缺陷图像色调分布较为平均, 各个色调期间的数据占比均在 25% 左右, 两者在色调分布上存在着较大差异。因此, 通过增加训练集中色调分布缺失段的缺陷数据预计能够提高模型的检测能力。




图 3 缺陷数据和无缺陷数据的平均色调分布

Fig. 3 Average hue distribution of defect data and defect-free data

为评估 HC-GAN 对缺陷图像进行色调增强后是否具备逼真的视觉效果, 以及色调增强对 RetinaNet 算法缺陷检测精度的影响, 本文采用将缺陷区域直接拷贝到无缺陷图像上的方法生成数据与 HC-GAN 生成数据进行对比实验, 下文称此方法为朴素粘贴法。本文共设计了两组实验: (1) 工业图像色调增强实验, 从图像是否自然、能否实现色调迁移等方面进行视觉评判; (2) 数据增强效果测试实验, 分别使用本文方法、朴素粘贴法来进行数据增强, 进行目标检测训练, 比较两种数据增强方法对 RetinaNet^[15] 算法检测精度 (AP) 的影响。AP 为 P-R 曲线围成的面积, P 表示准确率, R 表示召回率, 计算式如式(6)、式(7)所示, 其中 TP 为被正确检测为正例的个数, FP 表示被错误检测为正例的个数, FN 表示被错误检测为负例的个数。

$$P = TP / (TP + FP) \quad (6)$$

$$R = TP / (TP + FN) \quad (7)$$

本文实验所采用的环境如下: 操作系统为 Windows10, GPU 为 GeForce GTX Titan X, 显存为 12GB, CPU 为 Intel (R) Core(TM) i7-7700K, 内存为 32GB, 实验算法基于 pytorch 框架, 采用 python 版本为 3.6.12。

3.2 工业图像色调增强实验

3.2.1 实验获取流程

缺陷数据的制作通过破坏无缺陷芯片表面区域得到, 对破坏前后的芯片进行拍摄采样, 得到一一对应的无缺陷图像 I_{normal} 和缺陷图像 I_{defect} , 利用 Labelme 标记软件标记缺陷区域, 将非缺陷区域的图像像素置为 0, 得到缺陷 $mask$ 图像 I_{mask} 。

在实际应用中缺陷数据难以获取, 无缺陷数据容易获得, 为使实验条件更加接近实际应用场景, 在训练阶段, 本文使用 50 张成对缺陷数据作为 D_{defect} 的输入, 使用 300 张无缺陷图像作为 G_{hue} 中色调参考图像的输入。训练完成后, 使用 190 张无缺陷图像 (I_{normal})、190 张缺陷 $mask$ 图像 (I_{mask}) 输入 G_{defect} 得到 190 张缺陷图像 ($I_{fake-defect}$), 将这 190 张生成的缺陷图像和 190 张色调参考图像 (I_{ref}) 输入 G_{hue} 得到 190 张测试图像。随后, 将缺陷 $mask$ 图像进行平移来改变缺陷的位置, 再次

进行测试,得到缺陷位置变换后的生成图像(见图4),作为对比,通过朴素拷贝法将相应的缺陷区域直接拷贝到无缺陷图像上,得到对比实验的缺陷图像。

通过多次调整实验参数,在提高模型性能的同时,提高模型的检测速度,最终实验的具体参数如下:为提高模型的性能,模型训练 epoch 为 400,采用 Adam 优化器从头开始训练网络,生成器 G_{defect} 和 G_{hue} 以及判别器 D_{defect} 和 D_{hue} 的初始学习率均为 2×10^{-5} , batchsize 为 1,为提高模型检测速度,训练图像 resize 至 $128 * 128$ 。

3.2.2 实验结果及分析

本文方法生成的图像如表1所列,其中红色矩形框内为缺陷特征,第一行图像为缺陷移动前数据,第二行图像对应图

像在缺陷移动之后的数据。从第一行第二行图像的对比可知,本文方法能够在无缺陷图像上任意位置生成缺陷,且缺陷与背景融合较好;从 T-GAN 生成图像与粘贴法对比可知,本文方法生成图像在保证缺陷特征不发生变化的同时,实现了缺陷在相应背景上自然嵌入;从 HC-GAN 生成图像与参考图对比可知,HC-GAN 生成图像能保留无缺陷图像的色调;从 HC-GAN 生成图像与 T-GAN 生成图像对比可知,HC-GAN 生成图像能够在保留缺陷、背景的特征的前提下,实现基于参照图的色调迁移。由此可见,本文设计的方法在保留图像特征的同时,实现了缺陷位置的移动,完成了缺陷在背景图像上的自然嵌入,并实现了 G_{defect} 中生成的缺陷图像色调向参照图像色调的转变。

表1 本文方法和朴素粘贴方法生成图像对比

Table 1 Comparison of generated image by the proposed method and paste method

操作	无缺陷图像	缺陷mask图像	朴素粘贴方法生成图像	T-GAN生成图像	色调参数图像	HC-GAN生成图像
平移前						
平移后						

以上结果表明:(1)T-GAN 的设计中将缺陷图像分层为无缺陷图像和缺陷 mask 图像的思路是解决缺陷迁移的有效方式,生成器 G_{defect} 将无缺陷图像和缺陷 mask 图像进行融合后,通过对抗训练,生成图像将不断接近真实缺陷的分布,且 G_{defect} 学习到的融合系数与缺陷 mask 的位置无关,因此在改变缺陷 mask 图像的位置后,生成的缺陷依旧具有逼真的视觉效果;(2)HC-GAN 中生成图像在改变了图像色调的同时,保持了原始图像的内容不变,说明了 Content Consistency 模块能够对比生成图像和原始图像的高级特征,保证了生成图像的内容信息不发生变化;(3)HC-GAN 中 Hue Controlled 模块将原始图像和参考图像进行直方图匹配,用于监督生成器 G_{hue} ,使得生成的图像的色调分布不断接近重映射图像,

保证了生成图像与参考图像的色调高度一致。

3.3 数据增强效果测试实验

3.3.1 实验获取与流程

原训练数据、测试数据(真实数据)、增强后的训练数据的平均色调分布如图4所示。由图4可知,原始训练集(见图4(a))中处于 $[95, 105]$ 区间的样本占据较小比例,且绝对数量较少;而测试数据(见图4(b))中处于 $[95, 105]$ 区间的样本较多,两者亮度分布差异较大。如前文所述,本文通过 HC-GAN 和朴素粘贴的方法进行数据合成,并将生成的图像加入到训练集中,以实现数据增强的目的,增强数据的亮度分布如图4(c)所示。在前述硬件条件下,训练两个串联 GAN、400 个 epoch 总计耗时 2h40min35s,单张图片检测时间约为 50ms。




图4 表面缺陷检测测试数据和数据增强后的表面缺陷检测训练数据平均色调分布

Fig. 4 Average hue distribution of surface defect detection test data and surface defect detection training data after data augmentation

实验的具体流程为,先使用 Labelimg 标记工具,分别对 50 张真实缺陷图像、190 张使用朴素拷贝法生成的图像、190 张 HC-GAN 生成的图像进行标记,并将标记好的数据转换成 COCO 数据集^[16]格式。将数据合并得到以下 3 种训练集:仅有原始数据的训练集(对应表 1 中情况 1)、合并了朴素拷贝法生成的图像和原始数据的训练集(对应表 1 中情况 2)、合并了 HC-GAN 生成的图像和原始数据的训练集(对应

表 1 中情况 3)。测试集为未采集过训练数据的另一批次缺陷图像,随后分别利用这 3 种训练集进行模型训练,并在 243 张待检测数据集上进行了测试,结果如表 2 所列。

3.3.2 实验结果与分析

各模型测试结果如表 2 所列,从表 2 中可得出如下结论:(1)从情况 1、情况 2 的实验可知,将朴素粘贴方法生成的图像作为增强数据加入训练之后,缺陷检测模型的 AP 值反而

降低了,该结果表明该方法虽然生成了“增强图像”,但由于缺陷与无缺陷图像背景融合度不高,得到的缺陷图像偏离了真实图像的分布,从而降低了模型的检测率;(2)对比情况 1 和情况 3 的实验结果,可以看出 HC-GAN 生成的图像能够有效提升模型的检测精度,表明了 HC-GAN 能够精准控制图像的色调分布,解决了数据集中某种色调分布数据较少的问题,提升了目标检测的性能;(3)从情况 1、情况 2 的检测率对比可知,情况 3 的缺陷检测率提升了 0.59,提升较为有限,其原因在于训练良好的 RetinaNET 模型本身具有一定的泛化能力,对亮度发生了变化的测试数据具有一定的识别率,而增加的合成数据仅是根据亮度和缺陷模拟而来,其对于检测率的提升必然有限,但对于检测要求较高的工业缺陷检测场景来说具有积极的意义。

表 2 不同数据增强方法对目标检测精度的影响

Table 2 Influence of different data augmentation methods on object detection accuracy

情况	原始训练集	粘贴法增强数据	HC-GAN 增强数据	AP
1	✓	×	×	21.988
2	✓	✓	×	21.653
3	✓	×	✓	22.578

为进一步认识各个模型检测结果的不同,本文针对部分检测结果进行了整理(见表 3)。从表 3 可得出如下结论:(1)从图片 1—图片 3 的检测结果可知,原始训练集训练的模型能够将图片 1、图片 2 上的缺陷检测出来,而采用粘贴法增强数据集训练的模型则不能够检测出;而在图片 3、图片 4 的检测中,两种模型的检测结果一致,由此可见,采用朴素粘贴法生成的数据集起着反作用,这与从表 1 中得到的结论一致。(2)在图片 1—图片 3 的检测中,HC-GAN 增强训练集训练的模型明显优于其他两个模型,但在图片 4 的检测中,该模型过于自信,产生了误检,这也是导致训练 HC-GAN 增强训练集得到模型的 AP 值提高较为有限的原因之一。

表 3 检测结果对比

Table 3 Comparison of object detection results

图片	原始训练集	粘贴法增强训练集	HC-GAN 增强训练集	标记数据
1				
2				
3				
4				

综合上述实验结果可知,HC-GAN 作为一种面向色调的工业表面缺陷图像生成方法,能够有效改善缺陷图像色调分布不均衡的问题,提升了 RetinaNet 算法在工业表面缺陷数据上的检测精度。

结束语 本文针对工业缺陷数据色调分布与空间分布不均衡的问题,提出了一种面向工业表面缺陷图像的数据增强

方法。一方面,采用 GAN 对无缺陷图像进行色调建模,使生成器能够将缺陷图像的色调转换至无缺陷图像,并维持缺陷内容不变;另一方面,通过成对训练数据的设置,使得生成器学习到无缺陷图像和工业 mask 图像的融合系数,使得生成的缺陷图像位置可控,增加了缺陷位置的多样性。由实验结果可知,相比朴素像素粘贴方法,本文方法能够精准增加指定色调的缺陷数据数量,改善了工业表面缺陷数据色调不均衡的问题,提升了工业表面缺陷检测模型的平均精度。但是,本文方法的整体网络框架较为庞大,网络结构较为复杂,因此网络的训练对算力要求较高,且串联 GAN 结构训练耗时较长,未来可考虑将轻量化网络^[17]和 GAN 进行结合,以降低 GAN 的工业应用成本和时间成本。


参 考 文 献

- [1] TAO X, HOU W, XU D. A review of deep learning - based methods for surface defect detection[J]. Journal of Automation, 2021, 47(5): 1017-1034.
- [2] XU M, YOON S, FUENTES A, et al. A Comprehensive Survey of Image Augmentation Techniques for Deep Learning [J]. arXiv: 2205.01491, 2022.
- [3] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53-65.
- [4] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125-1134.
- [5] ZHU J, PARK T, ISOLA P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks [C]// 2017 IEEE International Conference on Computer Vision (ICCV). 2017: 2242-2251.
- [6] LI T, QIAN R, DONG C, et al. Beautygan: Instance-level facial makeup transfer with deep generative adversarial network[C]// Proceedings of the 26th ACM International Conference on Multimedia. 2018: 645-653.
- [7] JIANG W, LIU S, GAO C, et al. Psgan: Pose and expression robust spatial-aware gan for customizable makeup transfer[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 5194-5202.
- [8] CAO Y, ZHOU Z, ZHANG W, et al. Unsupervised diverse colorization via generative adversarial networks[C]// Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Cham: Springer, 2017: 151-166.
- [9] YOO S, BAHNG H, CHUNG S, et al. Coloring with limited data: Few-shot colorization via memory augmented networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 11283-11292.
- [10] NIU S, LI B, WANG X, et al. Defect image sample generation with GAN for improving defect recognition[J]. IEEE Transactions on Automation Science and Engineering, 2020, 17(3): 1611-1622.
- [11] GAO C, LI W, TAO R, et al. MS-HLMO: Multiscale Histogram of Local Main Orientation for Remote Sensing Image Registra-

- tion[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [12] DOU H, ZHANG L M, HAN F, et al. A review of interpretability studies of convolutional neural networks[J]. Journal of Software, 2021, 32(7): 1-27.
- [13] 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. IEEE, 2009: 248-255.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv: 1409. 1556, 2014.
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [16] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft coco: Common objects in context[C] // European Conference on Computer Vision. Cham: Springer, 2014: 740-755.
- [17] WANG J, FENG S C, CHENG Y. A review of research on lightweight neural network structures for deep learning [J]. Computer Engineering, 2021, 47(8): 1-13.
- [18] WANG J, FENG S C, CHENG Y. A review of research on lightweight neural network structures for deep learning [J]. Computer Engineering, 2021, 47(8): 1-13.



LUO Yuetong, born in 1978, Ph.D, professor, is a member of China Computer Federation. His main research interests include image processing and scientific visualization.



ZHOU Bo, born in 1981, Ph.D, associate professor. His main research interests include deep learning, image processing, and artificial intelligence.