

基于 U-Net 判别器的轮胎图像缺陷检测方法研究^{*}

张兴伟 刘韵婷 陈浩 丁海峰

(沈阳理工大学自动化与电气工程学院 沈阳 110159)

摘要: 轮胎缺陷检测对轮胎安全性能的鉴定有着重要意义,研究高性能的轮胎异常检测方法对汽车的安全性能极为重要。本文以生成对抗网络为基础提出一种基于 U-Net 判别器的网络模型 UDGANomaly,首先在判别器中引入编码与解码,编码器模块执行逐图像分类,解码器模块输出逐像素分类决策,向生成器提供空间相干反馈。其次在生成器的编码器和解码器中引入自注意力机制,进一步关注多尺度特征中包含的代表性信息。最后设计了一种改进的基于结构相似性的生成器损失函数来解决视觉上的不一致性,从而提高不规则纹理检测的鲁棒性。经过对比研究发现本文提出的网络结构在同样的轮胎数据集上异常检测性能明显优于其他传统网络模型,并且平均测试精准度高达 95.6%。

关键词: 异常检测;U-Net 判别器;深度学习;生成对抗网络

中图分类号: TN1 **文献标识码:** A **国家标准学科分类代码:** 510.4

Research on tire image defect detection method based on
U-Net discriminator

Zhang Xingwei Liu Yunting Chen Hao Ding Haifeng

(School of Automation and Electrical Engineering, Shenyang University of Science and Technology, Shenyang 110159, China)

Abstract: Tire defect detection is of great significance for the identification of tire safety performance, and researching high-performance tire anomaly detection methods is extremely important for the safety performance of automobiles. This article proposes a network model, UDGANomaly, based on U-Net discriminators, which is based on generative adversarial networks. Firstly, encoding and decoding are introduced into the discriminator. The encoder module performs image-by-image classification, and the decoder module outputs pixel-by-pixel classification decisions, providing spatially coherent feedback to the generator. Secondly, a self-attention mechanism is introduced in the encoder and decoder of the generator to further focus on the representative information contained in multi-scale features. Finally, an improved generator loss function based on structural similarity was designed to address visual inconsistency and enhance the robustness of irregular texture detection. After comparative research, it was found that the network structure proposed in this paper has significantly better anomaly detection performance than other traditional network models on the same tire dataset, and the average testing accuracy is as high as 95.6%.

Keywords: anomaly detection; U-Net discriminator; deep learning; generative adversarial nets

0 引言

子午线轮胎是机动车辆的重要部件,在高速公路上轮胎损坏而导致的公共交通意外事件占总交通事故率的 55%^[1],面对轮胎故障造成的高事故率,各企业开始改进更新轮胎缺陷检测设备。在轮胎生产过程中,缺陷检测是非常重要的一个环节。研究先进的缺陷检测技术^[2],可以有效地保证产品质量,保持生产的稳定性。目前的缺陷检测设备大都基于激光剪切散斑干涉技术^[3]、超声波探测技

术^[4]和 X 光扫描技术研制^[5]。尽管超声波探测技术能够快速、廉价地检测厚度较大的材料,还能准确地定位和量化缺陷,但在轮胎缺陷检测方面,由于波形的限制,其应用存在一定困难。X 光扫描技术具有极高的穿透性^[6],能够在不同厚度和纹理的轮胎上产生光密度差异,轮胎扫描成像细节可见度高、缺陷目标直观性强。随着深度学习技术的发展,基于深度学习进行图像缺陷检测已经取得了重大成果^[7-11]。与监督学习、半监督学习相比,无监督学习不需要进行图像标注,节省了大量的人力资源。目前基于生成对

抗网络(generative adversarial network, GAN)^[12]的异常检测方法已经取得了非常大的突破,生成对抗网络是一种经典的无监督学习方法。2017年 Schlegl 等^[13]首次提出使用 AnoGAN 进行图像缺陷检测,随后又有学者在此基础上陆续提出了 GANomaly^[14]、F-AnoGAN^[15]、MAGAD^[16]、MAGAN^[17]和 SRGAN^[18]等模型结构。2019年, Akcay 等^[19]提出了 Skip-GANomaly,该模型可以减少在进行图像重建时,生成器丢失的图像特征数量。然而,这几种新兴的生成对抗网络都存在以下缺点。例如, AnoGAN 需要重复迭代进行优化,导致耗时的迭代过程显著增加了模型推理时间。GANomaly 在获得较好的检测结果的同时,需要对生成器进行较长时间的训练,并且检测精度还有待提高。Skip-GANomaly 增强了检测能力,但是它的性能在不同类型的数据中表现出很大的差异,并且重建的异常图像携带过多的缺陷信息,使得不适合实际的缺陷检测任务。

基于以上研究,本文提出了一种基于 U-net 判别器的轮胎图像缺陷检测算法,主要工作方面是改变了传统判别器的网络架构,并在整体网络中引入了注意力机制,优化了损失函数。以达到提高缺陷检测的精准度。

1 研究方法

1.1 UDGANomaly

Skip-GANomaly 是一种基于无监督学习的异常检测

算法,其利用生成对抗网络结构来实现。Skip-GANomaly 在传统的 GAN 框架上进行了扩展。Skip-GANomaly 由一个自编码器和判别器组成。也可以把自编码器的部分看作是一个生成器。编码器与解码器之间有跳跃连接(Skip connection)。Skip-GANomaly 还添加了一个重建损失项和一个判别器后端的重建损失项,以加强异常检测的性能。

Skip-GANomaly 判别器可能在处理细微结构和细节时存在局限,不能更好的将一些细微的缺陷进行识别,将判别器的架构变成 U-Net 网络架构的样子,可以评估生成图像与真实图像之间的差别,并判断是否存在异常。U-Net 架构的运用使得判别器能够更好地捕捉图像中的细节和结构信息,从而提升异常检测的能力。U-Net 的架构允许向生成器提供详细的图像反馈,同时通过提供全局图像反馈来保持合成图像的全局一致性,有效提高模型异常检测的精度。

UDGANomaly 模型结构如图 1 所示。在生成器中加入了注意力机制,并仍采用跳连层传递轮胎图像信息。现在,鉴别器已经演变为由原有的下采样网络和一个全新的上采样网络组成的结构。这两个模块通过瓶颈连接,以及从编码器和解码器模块复制和连接特征映射的跳过连接。原始 $D(x)$ 将输入图像 x 分为真假, U-Net 鉴别器在逐像素的基础上进行分类,将图像 x 分割为真假区域,并与编码器对 x 的原始图像进行分类,完成异常检测任务。

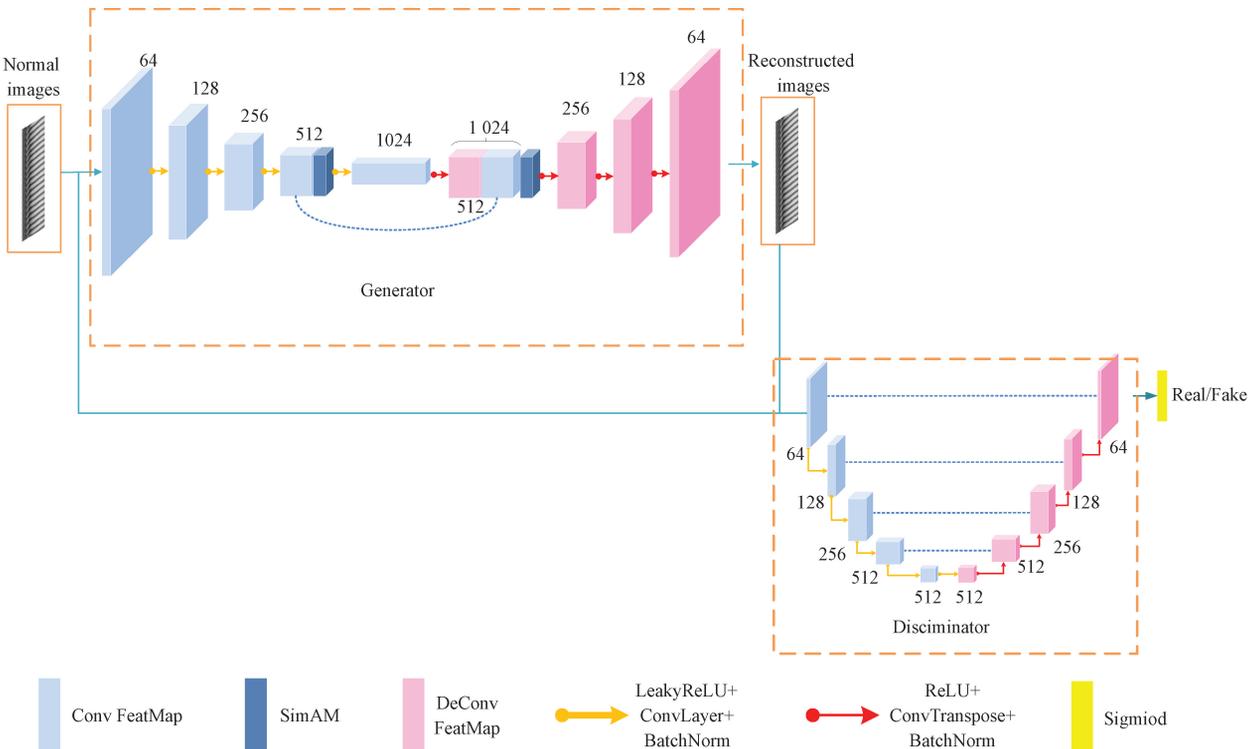


图 1 UDGANomaly 模型结构图

Fig. 1 UDGANomaly model structure diagram

1.2 SimAM 注意力机制

轻量级注意力机制(simplified self-attention module for visual tasks, SimAM)是一种简化的自注意力机制,专门设计用于视觉任务中,以提高网络模型对于空间信息的捕获能力。区别于以往的 BAM(bottleneck attention module)、CBAM(convolutional block attention module)等注意力将空间注意力与通道注意力进行并行或串行组合, SimAM 最简单的寻找重要神经元的方法就是度量神经元之间的线性可分性。基于这些神经科学的发现,针对每个神经元定义了如式(1)的能量函数:

$$e_t(\omega_t, b_t, y, x_i) = (y_t - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_o - \hat{x}_i)^2 \quad (1)$$

上述公式的最小化可以等价于通过训练来增强同一通道内神经元 t 与其他神经元之间的线性可分性。为了简化, SimAM 采用了二值标签,并添加了正则项,最终的能量函数如式(2):

$$e_t(\omega_t, b_t, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (\omega_t x_i + b_t))^2 + (1 - (\omega_t t + b_t))^2 + \lambda \omega_t^2 \quad (2)$$

上式解析式为式(3)与(4):

$$\omega_t = -\frac{2(t - \mu_t)}{(t - \mu_t)^2 + 2\sigma_t^2 + 2\lambda} \quad (3)$$

$$b_t = -\frac{1}{2}(t + \mu_t)\omega_t \quad (4)$$

由于每个通道上所有神经元都遵循相同的分布,因此可以先对输入特征在 H 和 W 两个维度上计算均值和方差,避免重复计算如式(5):

$$e_t^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{\mu})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (5)$$

计算的过程可以表示为式(6):

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (6)$$

本文在生成器的编码与解码部分加入了 SimAM,在生成器的编码阶段, SimAM 可以应用于特征图上,帮助模型更好地理解输入数据的空间关系和重要区域。具体来说, SimAM 可以通过计算特征图中每个位置的重要性分数,如图 2 所示,首先经过全局平均池化获取每个通道的特征,然后通过一个卷积来执行通道间的交互并且将空间信息与通道信息相结合,生成三维的注意力权重。最终, Sigmoid 激活用于生成通道权重,并将与其原始特征图相乘,重新加权特征。从而实现对关键信息的强调和对不重要信息的抑制。这有助于编码器捕捉到更加丰富和有区分度的特征表示,为解码器生成高质量图像提供了更好的基础。

在解码阶段, SimAM 可以帮助生成器更精细地重建图像。通过在解码器的不同层上应用 SimAM,生成器可

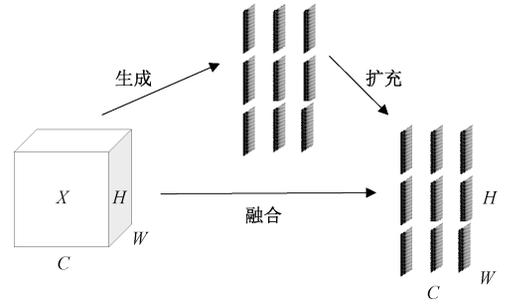


图 2 SimAM 注意力

Fig. 2 SimAM attention

以逐渐细化生成图像的细节,同时保持对全局结构的注意。这种自注意力机制的引入,使得生成器在生成图像时能够更好地平衡局部细节和全局一致性,从而提高最终生成图像的质量。

1.3 损失函数

为了考虑轮胎训练图像的亮度、对比度和结构信息相关性,本文基于结构相似性(structural similarity, SSIM)为生成器设计了改进的损失函数,以解决仅使用欧氏距离度量重建误差导致的视觉不一致问题,提高不规则纹理缺陷检测的鲁棒性。对于模型输入图像和生成图像, SSIM 值定义为式(7):

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (7)$$

其中, μ_x 和 μ_y 分别表示 x 和 y 的均值, σ_x 和 σ_y 分别表示 x 和 y 的方差, σ_{xy} 分别表示 x 和 y 的协方差, c_1 和 c_2 表示常数。基于的损失函数设计如式(8):

$$L_{SSIM}(x, y) = 1 - SSIM(x, y) \quad (8)$$

损失函数 L_{SSIM} 从亮度、对比度和结构 3 个角度对生成器进行优化,训练生成器关注样本图像的亮度变化和颜色偏差,从而保留轮胎图像的边缘、细节等高频信息,适用于规则轮胎纹理样本。使用了 L_{con} 损失和 L_{SSIM} 损失联合函数作为图像重建损失,如式(9):

$$L_{recon} = \alpha L_{con} + (1 - \alpha) L_{SSIM} \quad (9)$$

其中, α 是平衡 L_{con} 和 L_{SSIM} 权重的加权因子。最终优化函数为式(10):

$$L = \omega_{adv} L_{adv} + \omega_{recon} L_{recon} + \omega_{lat} L_{lat} \quad (10)$$

其中, ω_{adv} 、 ω_{recon} 和 ω_{lat} 均为权重参数,用于调整各损失对总优化目标函数的影响。图像重建损失 L_{recon} 、对抗损失 L_{adv} 和潜在损失 L_{lat} , 3 个子损失函数分别为式(11)、(12)、(13):

$$L_{recon} = E_{x \sim p_x} [\log D(x)] + E_{x \sim p_x} [\log(1 - D(\hat{x}))] \quad (11)$$

$$L_{adv} = E_{x \sim p_x} [\log D(x)] + E_{x \sim p_x} [\log(1 - D(\hat{x}))] \quad (12)$$

$$L_{lat} = E_{x \sim p_x} \| f(x) - f(\hat{x}) \|_2 \quad (13)$$

其中, P_x 为正态数据的分布, x 为服从的 P_x 正态数据, \hat{x} 为 x 经过生成器重构后的数据。 D 为鉴别器, α 为权重参数, $f(x)$ 和 $f(\hat{x})$ 分别为从测试样本和重构图像输入鉴别器中得到的瓶颈特征。

2 实验结果分析

2.1 实验数据集的制作

训练数据集由 12 000 张无缺陷的轮胎 X 光图像构成。具体选用子午线轮胎 X 光图像,并经过轮胎不同位置的 X 光图像对比,最后确定选用结构和背景相对简单的胎侧部分的 X 光图像,如图 3 所示。

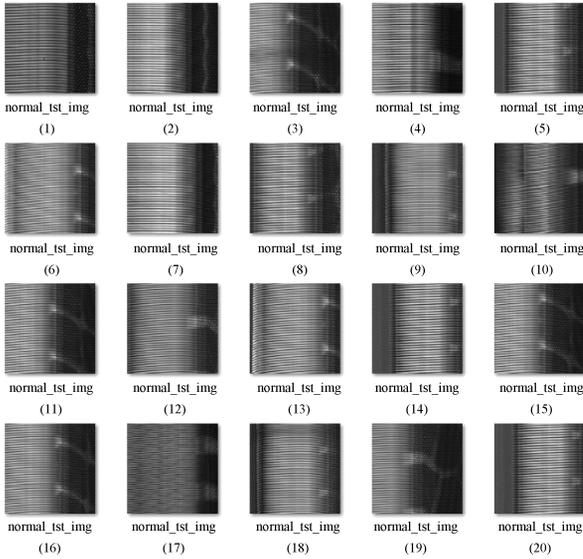


图 3 轮胎 X 光图像训练集正常轮胎样本

Fig. 3 Tire X-ray image training set normal tire samples

测试数据集由无缺陷图像和缺陷图像组成。其中无缺陷图像 1 908 张,缺陷图像 1 908 张,其中缺陷图像包括杂质图像、气泡图像、胎稀图像、与帘线弯曲图像,各类缺陷图像的数量如表 1 所示。杂质图像可能具有不规则形状,大小不一,难以与正常图像进行区分。气泡可能出现在不同尺寸和形状,且与液体相似的外观,容易被误认为是正常部分。胎稀可能在图像中呈现出不规则的形状,与周围环境融合,难以被准确检测。帘线弯曲可能具有不同的形状和弯曲程度,而且与周围纹理相似,因此也难以被准确检测。具体类型如图 4 所示。

2.2 实验相关参数

1) 参数设置

Adam;lr=0.000 1;b1=0.5;b2=0.999;隐变量维度 $Z=100$;batchsize=30;epoch=50。

2) 实验平台配置

本实验计算机的硬件配置为 Intelr-i5、Nvidia GTX1050GPU、12 G 内存。编程的环境采用 windows 操

表 1 实验数据

Table 1 Experimental data

缺陷类型	图像数量
杂质	510
气泡	501
胎稀	455
帘线弯曲	422
混合缺陷	1 908

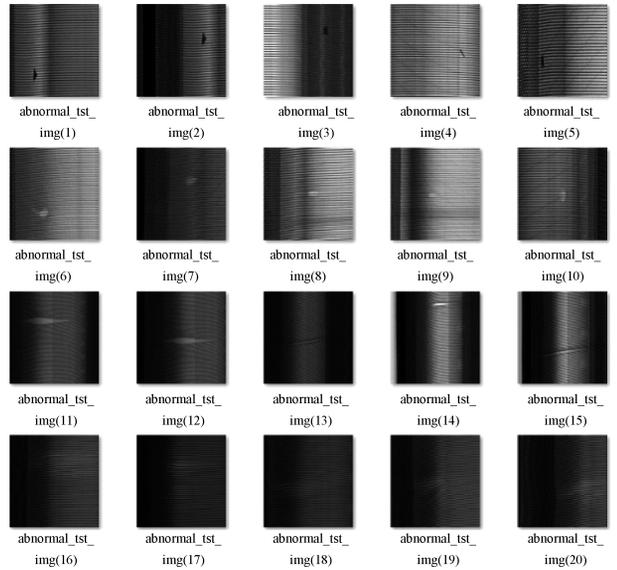


图 4 轮胎 X 光图像测试集缺陷样本

Fig. 4 Defect samples in tire X-ray image test set

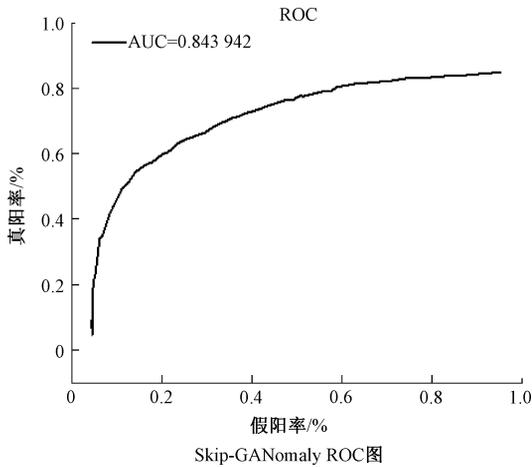
作系统,Python3.10 以及 Pytorch1.7.0 的深度学习开发工具。

2.3 实验结果分析

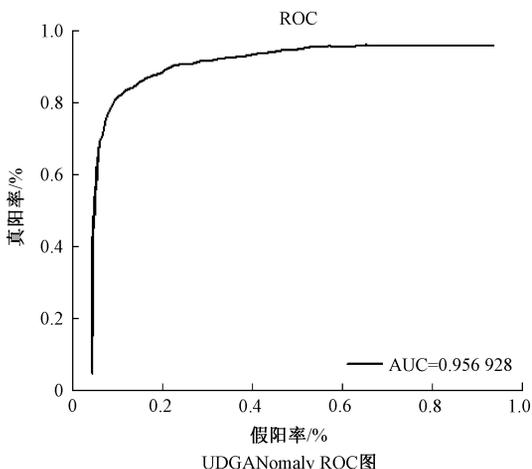
本次实验采用了受试者工作特征(ROC)曲线作为模型性能的评价方法。ROC 曲线上的横轴表示假阳率,即将实际上全部是异常数据错误地判定为正常的比例,纵轴表示真阳率,即实际上所有正常数据被正确地判断为正常的比例。ROC 的曲线越靠近坐标轴的左上角表示检测的效果就越佳,相反则是越差。ROC 曲线与横轴围成的面积代表 AUC 的值,这个值越大,同样表示检测的效果越优秀,反之越差。以轮胎 X 光图像数据集为例,原 SkipGANomaly 与改进后的模型 UDGANomaly 的 AUC 对比如图 5 所示。

1) 对比试验

AUC 值对比:为了进一步验证 UDGANomaly 模型相较于其他模型的优越性,本文选取相同的轮胎数据集对 UDGANomaly、F-AnoGAN、AnoGAN、Skip-GANomaly 等模型进行了训练和测试。通过对实验结果的分析,可以更清晰地了解各模型在异常检测任务中的表现差异,具体结果如表 2 所示。



(a) Skip-GANomaly模型ROC曲线图
(a) ROC curve of Skip-GANomaly model



(b) UDGANomaly模型ROC曲线图
(b) ROC curve of UDGANomaly model

图 5 轮胎 X 光缺陷检测 ROC 曲线图对比图

Fig. 5 Comparison of ROC curves for tire X-ray defect detection

表 2 实验数据
Table 2 Experimental data

模型	AUC	AP
GANormaly	0.835	0.823
F-AnoGAN	0.798	0.801
AnoGAN	0.840	0.839
Skip-GANomaly	0.843	0.793
UDGANomaly	0.956	0.889

可以看出改进后的模型 UDGANomaly 对相同的轮胎数据集的 AUC 有所提高,相比于原 Skip-GANomaly 模型的 AUC 均值提升了 0.113,其余的相比于另外 3 个异常检测模型 GANormaly、AnoGAN、f-AnoGAN 的 AUC 均值分别提升了 0.121、0.116、0.158。通过实验证明了该方法是有效的。

重建损失是原始输入图像与重建图像的差距,本文选取当下有代表性的模型进行比较结果如图 6 所示。

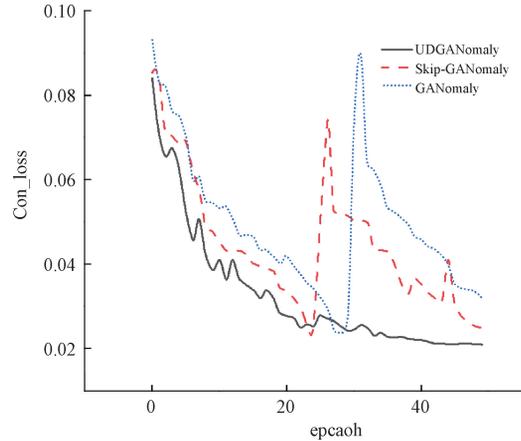


图 6 损失函数曲线图

Fig. 6 Curve of Loss function

由图 6 可以看出,UDGANomaly 的重建损失函数比 Skip-GANomaly、GANormaly 都要小,UDGANomaly 的重建损失基本上接近 0.02,重建图像更接近原始输入图像。为了评估本文的模型在不同复杂缺陷情况下的异常检测能力,对轮胎数据集帘线弯曲、气泡、胎稀和杂质进行了测试,结果如图 7 所示。

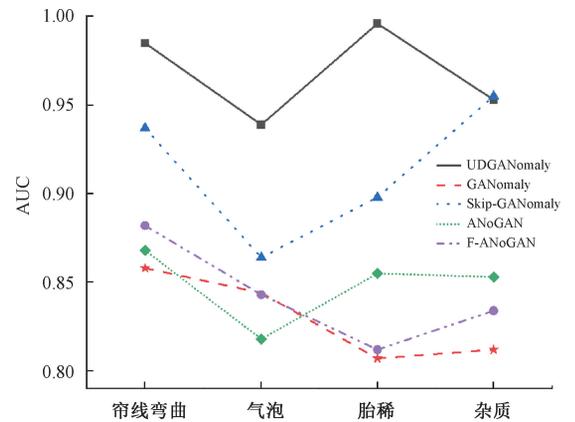


图 7 轮胎数据集 AUC 结果

Fig. 7 Tire dataset AUC results

根据图 7 可以发现改进后的模型在单独处理各种轮胎缺陷数据集时都得到了明显的提高,在相同的迭代次数下,Skip-GANomaly、GANormaly 和本文的方法都学习到了潜在空间中正态样本的足够特征分布。然而,随着迭代的不断进行,一些重复的特征信息甚至噪声会淹没具有代表性的特征信息,从而导致鉴别器的误分类和退化从而将低了模型分精精度。

重建图像和异常点定位对比:在模型训练完成后,通过热力图对比来评估各模型的性能。由于模型只接触了正常图像的特征,当异常图像输入生成器时,生成的图像

将缺乏异常特征。因此,可以通过比较原始图像和重建图像之间的差异来生成异常热力图,从而准确定位图像中的异常区域。

图 8 展示了一些异常图像、其对应的重建图像以及生成的热力图。可以观察到,AnoGAN 仅经过训练就难以学习到正态样本在潜在空间中的分布,并且难以学习到带有噪声的重建图像。Skip-GANomaly 可以很好地重构正常样本图像,但在输入缺陷样本进行检测时,由于包含了多个缺陷样本,重构后的图像会携带大量的缺陷信息,

GANomaly 部分学习了正态样本在潜在空间中的分布,但是重建后的效果不是很好,而本文提出的 UDGANomaly,利用 SSIM 对损失函数进行改进,可以兼顾训练图像的亮度、对比度和结构信息的相关性,此外还增加了注意力机制、改进了判别器,在充分学习正态样本图像编码到潜在空间的分布的同时,减少了模型推理时间,提高了检测精度。并且在重构图像只携带少量缺陷信息的情况下,可以很好地重构异常图像。UDGANomaly 能够准确地识别异常特征的位置。

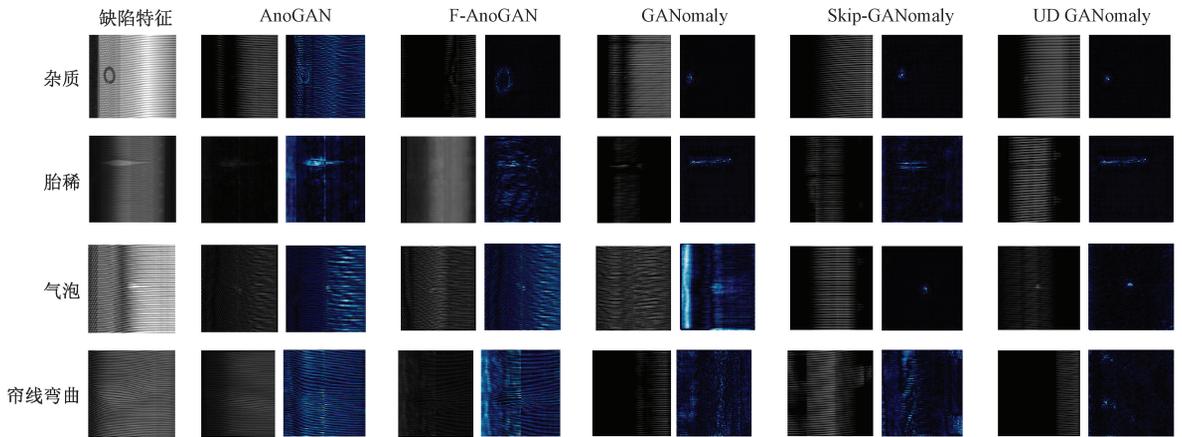


图 8 训练集热力图

Fig. 8 Thermal map of training set

2) 消融试验

为了验证本文所提出的在 Skip-GANomaly 中改变 U-net 判别器、添加注意力机制 (SimAM) 并引用了 SSIM 损失函数的有效性,进行消融实验,相同实验条件下,评估不同模块对本文模型性能的影响,最后得到的结果如表 3 所

示。通过表 3 可以看出将判别器换为 U-net 的架构,AUC 的均值提高了 0.051,在原网络模型上添加了 SimAM 注意力机制,AUC 均值提高了 0.064,并在添加注意力的基础上使用 SSIM 损失函数,AUC 均值提高了 0.106。具体结果如表 3 所示。

表 3 实验数据

Table 3 Experimental data

模型类型	基础 GAN	基础 GAN+ u-net 判别器	基础 GAN+ SimAM	基础 GAN+ SimAM+ssim	UDGANomaly
帘线弯曲 AUC	0.858	0.980	0.992	0.996	0.985
气泡 AUC	0.844	0.840	0.879	0.908	0.939
胎稀 AUC	0.807	0.960	0.946	0.999	0.996
杂质 AUC	0.812	0.894	0.902	0.952	0.953
混合 AUC	0.843	0.894	0.907	0.949	0.956
平均 AUC	0.832	0.913	0.925	0.960	0.965

3) 模块随机组合实验

为了研究 UDGANomaly 中基于 u-net 判别器、注意力机制和改进的损失函数对模型的影响,使用自制轮胎数据集进行了实验,如表 4 所示,其中使用最优阈值计算精度 (ACC)、马修斯相关系数 (MCC)、F1 分数、精度 (PRE) 和真阳性率 (TPR) 值。判别器的改进在所有方面都是对基

础网络的重大改进。分别在 SSIM 设计基础上增加注意力和改进损失函数 L_{recon} 后,AUC 值得到了显著提高。这表明自注意力机制可以捕获远程依赖并提供更丰富的上下文感知。本文设计的改进损失函数 L_{recon} 可以考虑细小缺陷结构相关性等信息,提高了不同缺陷图像下异常检测的鲁棒性和准确性。最后,随着网络的完善,模型的检测

能力得到了极大的增强,进一步提高了分析的质量,并实现了所有指标的基本最佳性能。

表 4 不同模块相结合得到的结果

Table 4 Results obtained by combining different modules

基础 GAN	u-net 鉴别器	SimAM	SSIM	AUC	ACC	MCC	F1	PRE	TPR
+				0.843	0.793	0.371	0.856	0.778	0.956
+	+			0.894	0.873	0.416	0.855	0.820	0.913
+	+	+		0.910	0.879	0.537	0.867	0.871	0.857
+	+		+	0.942	0.886	0.561	0.891	0.983	0.877
+	+	+	+	0.956	0.889	0.703	0.926	0.911	0.956

3 结 论

本文提出的 UDGANomaly 模型,在原始的 Skip-GANomaly 模型的基础上将判别器改为 U-net 的架构,有效解决了缺陷图像形状和纹理与真实图像难以区分,判别器进行图像鉴别时出现异常特征图像鉴别不稳定。通过相关的实验验证,改进后的模型 UDGANomaly 能够提升异常检测的准确率。

参考文献

- [1] 朱焕宇,王明泉,李磊磊,等. 胎体钢丝帘线缺陷的 CD-YOLO 分割算法应用[J]. 国外电子测量技术, 2023, 42(7):175-180.
ZHU H Y, WANG M Q, LI L L, et al. Application of CD-YOLO segmentation algorithm for tire steel wire cord defects[J]. Foreign Electronic Measurement Technology, 2023, 42(7): 175-180.
- [2] 张玥,陈锡伟,陈梦丹,等. 基于对比学习生成对抗网络的无监督工业品表面异常检测[J]. 电子测量与仪器学报, 2023, 37(10):193-201.
ZHANG Y, CHEN X W, CHEN M D, et al. Unsupervised surface defect detection of industrial products based on contrastive learning and generative adversarial networks [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 193-201.
- [3] 王永红,姚彦峰,李骏睿,等. 剪切散斑干涉关键技术研究及应用进展[J]. 激光与光电子学进展, 2022, 59(14):53-61.
WANG Y H, YAO Y F, LI J R, et al. Research and application progress of key technologies in shear scattering interferometry[J]. Progress in Laser and Optoelectronics, 2022, 59(14): 53-61.
- [4] 孙存英,俞嘉隆,乔卫平. 超声波探测技术原理实验[J]. 大学物理实验, 2010, 23(1):1-3.
SUN C Y, YU J J, QIAO W P. Experiment on the principle of ultrasonic detection technology [J]. Journal of College Physics Teaching, 2010, 23(1):

- 1-3.
- [5] 刘韵婷,李绅科,郭辉,等. 基于神经批采样的轮胎 X 光图像异常检测研究[J]. 电子测量技术, 2023, 46(5): 157-163.
LIU Y T, LI SH K, GUO H, et al. Research on anomaly detection of tire X-ray images based on neural batch sampling [J]. Electronic Measurement Technology, 2023, 46(5): 157-163.
- [6] 粟兴旺,王晓明,黄金玻,等. 基于可变形卷积与注意力机制的 X 光安检违禁品检测[J]. 电子测量技术, 2023, 46(10):98-108.
SU X W, WANG X M, HUANG J B, et al. Detection of contraband in X-ray security inspection based on deformable convolution and attention mechanism[J]. Electronic Measurement Technology, 2023, 46(10): 98-108.
- [7] 刘韵婷,刘鑫,高宇. 基于 FAMGAN 的轮胎 X 光图像缺陷检测[J]. 电子测量与仪器学报, 2023, 37(12): 58-66.
LIU Y T, LIU X, GAO Y. Tire X-ray image defect detection based on FAMGAN [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 58-66.
- [8] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1):198-219.
ZHAO L Y, WU Y Q. Research progress on surface defect detection methods based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [9] LIN H, LI B, WANG X, et al. Automated defect inspection of LED chip using deep convolutional neural network [J]. Journal of Intelligent Manufacturing, 2019, 30(6):2525-2534.
- [10] TABERIK D, ŠELA S, SKVAR Ć J, et al. Segmentation based deep-learning approach for surface-defect detection [J]. Journal of Intelligent Manufacturing, 2020, 31(3): 759-776.
- [11] MIRZA M, OSINDERO S. Conditional generative

- adversarial nets[J]. ArXiv preprint arXiv:1411.1784, 2014.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]. 2014 Conference on Advances in Neural Information Processing Systems 27, 2014; 2672-2680.
- [13] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery[C]. Lecture Notes in Computer Science. Switzerland: Springer, Cham, 2017; 146-157.
- [14] AKÇAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. GANomaly: Semi-supervised anomaly detection via adversarial training [C]. Computer Vision-ACCV 2018: 14th Asian Conference on Computer Vision, 2019; 622-637.
- [15] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. F-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks[J]. Medical Image Analysis, 2019, 54; 30-44.
- [16] WANG Y L, ZHANG Y L, ZHENG L, et al. Unsupervised learning with generative adversarial network for automatic tire defect detection from X-ray images[J]. Sensors, 2021, 21(20); 67-73.
- [17] TANG T W, KUO W H, LAN J H, et al. Anomaly detection neural network with dual auto-encoders GAN and its industrial inspection applications[J]. Sensors, 2020, 20(12); 3336.
- [18] ZHANG H, ZHU T, CHEN X, et al. Super-resolution generative adversarial network (SRGAN) enabled on-chip contact microscopy [J]. Journal of Physics D: Applied Physics, 2021, 54(39); 394005.
- [19] 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), 2019; 1-8.

作者简介

刘韵婷(通信作者),副教授,硕士生导师,主要研究方向为无线传感器网络、人工智能技术和数据分析。

E-mail:liuyunting0224@163.com

张兴伟,硕士研究生,主要研究方向为异常检测。

E-mail:1987792121@qq.com

陈浩,硕士研究生,主要研究方向为异常检测。

E-mail:1585436686@qq.com

丁海峰,硕士研究生,主要研究方向为运动检测。

E-mail:1010670362@qq.com