

基于 D² GANomaly 的轮胎缺陷检测研究 *

刘韵婷 冯欣悦 李思维 张智星

(沈阳理工大学自动化与电气工程学院 沈阳 110159)

摘要:针对 GANomaly 模型潜在向量对正样本特征表征能力不足、解码器重构图像质量欠佳以及判别器判别能力不足的问题,提出一种基于 D²GANomaly 的轮胎 X 光图像缺陷检测方法。首先,在编码器中引入多尺度动态残差模块(MDRB),通过可变核卷积(AKConv)与残差连接的组合,动态融合多尺度特征,提高细粒度特征提取能力;其次,在解码器部分引入通道残差子像素解码器(CRSD),利用双解码器并行学习,优化复杂纹理和细节的重建质量;最后,判别网络采用二元并行判别网络(DDMN),通过可切换空洞卷积(SAC)选取最优空洞扩张系数,增强模型对轮胎 X 光图像中不同大小的缺陷检测能力,进而提高判别能力。实验结果表明,在受试者工作特征曲线下面积(AUC)与平均精度(AP)两项核心性能指标上,所提方法均实现了显著提升,相较于原始模型 GANomaly AUC 值提升了 13.7%,AP 值提升了 16.4%。由此可见,改进后的模型有效提升了轮胎缺陷的检测精度。

关键词:生成对抗网络;异常检测;残差结构;可变核卷积

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 defect detection based on D²GANomaly

Liu Yunting Feng Xinyue Li Siwei Zhang Zhixing

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

Abstract: Aiming at the issues of insufficient feature representation capability of latent vectors for positive samples, suboptimal reconstructed image quality by the decoder, and inadequate discriminative ability of the discriminator in the GANomaly model, a tire X-ray image defect detection method based on D²GANomaly is proposed. First, a multi-scale dynamic residual block (MDRB) is introduced into the encoder, which combines adjustable kernel convolution (AKConv) with residual connections to dynamically fuse multi-scale features and enhance fine-grained feature extraction capabilities. Second, a channel residual sub-pixel decoder (CRSD) is incorporated into the decoder section, utilizing dual decoders for parallel learning to optimize the reconstruction quality of complex textures and details. Finally, the discriminator employs a dual discriminative module network (DDMN), which uses switchable atrous convolution (SAC) to select the optimal dilation rate, thereby enhancing the model's ability to detect defects of varying sizes in tire X-ray images and improving its discriminative performance. Experimental results demonstrate significant improvements in two core performance metrics, Area under the receiver operating characteristic curve (AUC) and average precision (AP). Compared to the original GANomaly model, the proposed method achieves a 13.7% increase in AUC and a 16.4% increase in AP. This indicates that the improved model effectively enhances the accuracy of tire defect detection.

Keywords: generative adversarial net; anomaly detection; residual structures; arbitrary kernel convolution

0 引言

随着人工智能与车联网技术的深度融合,自动驾驶正加速向 L3、L4 级高阶阶段演进^[1],对汽车架构和零部件性能提出革命性要求。轮胎作为唯一与路面接触的部件,在制造过程中,及时发现并排除潜在缺陷,确保产品质量,对于保障行车安全、提升汽车品牌形象具有重要意义。

近年来,无监督算法^[2-3]在异常检测领域内彰显出显著优势,与有监督算法^[4-5]不同,无监督方法直接处理原始数据,无需依赖人工,不仅降低了人工成本,还增强了模型的泛化能力,为检测复杂多变的轮胎缺陷提供了创新性的思路^[6-7]。其中,生成对抗网络(generative adversarial network, GAN)^[8]借助对抗式训练方式,能够从未标注的数据里学习到有效的特征表征,从而实现对异常的识别。GANomaly^[9]作为 GAN 的变体,利用其高效的特征提取和生成能力,提出基于图像的缺陷检测框架。在此基础上进行改进的 skip-GANomaly^[10]模型,引入了跳跃连接^[11],通过有效融合浅层与深层特征信息,显著提升了模型的重构性能。虽然跳跃连接的引入提高了模型的重建能力,但同时提高了过拟合的风险。其他关于 GAN 的异常检测模型还包括, Schlegl 等^[12]提出使用异常检测生成对抗网络(anomaly detection with generative adversarial networks, AnoGAN)利用隐空间迭代搜索与重构差异进行图像缺陷检测。为解决 AnoGAN 的速度与稳定性问题, Schlegl 等^[13]又在 AnoGAN 的基础上引入了编码器和优化训练策略,显著提升了检测效率与性能。Zenati 等^[14]用编码器将真实图像映射为潜在变量,将潜在变量输入到判别器内进行缺陷检测,无需生成图像进行判别,大大降低了测试时间,提高了异常检测的效率。ALAE^[15]结合了自编码器^[16]和 GAN 的优点,通过学习高质量的潜在空间表示,显著提升了正常样本与异常样本的区分能力。He 等^[17]利用级联 GAN 和边缘修

复特征融合技术,实现了对复杂背景下多样缺陷的准确检测。Li 等^[18]提出了将残差网络与注意力机制融入到生成器架构之中,显著增强了模型对复杂特征的提取效能,使其能够更为精准地捕捉到轮胎缺陷图像中的关键特征信息。

生成对抗网络中自编码器执行特征提取任务时,下采样过程往往会导致部分关键信息遗漏,造成细节丢失。而在上采样阶段,又容易将图像中的边缘和细节信息“平滑”掉,造成图像的局部结构和纹理特征模糊化,从而影响重构图像的视觉质量。而判别器可能会因为整体结构看起来合理而判定图像为真实,从而忽略了局部的缺陷细节。这些问题都会影响缺陷检测的实际效果,使检测精度与可靠性降低。针对以上问题,本文以 GANomaly 模型为基础进行改进,首先在编码器中引入了多尺度动态残差模块(multi-scale dynamic residual block, MDRB)^[19],通过可变核卷积(arbitrary kernel convolution, AKConv)^[20]与残差连接的有效组合,动态融合多尺度特征,提高细粒度特征提取能力。然后在解码器部分引入通道残差子像素解码器(channel-attention residual subpixel decoder, CRSD)^[21],优化重建图像的质量。最后,将单一的判别器改为二元并行判别网络(dual discriminative module network, DDMN)^[22],实现对图像细节处更好的判别。

1 研究内容

1.1 多尺度动态残差模块

编码器处理的原始数据结构复杂。传统卷积虽能提取局部特征,但因依赖池化操作或深层网络获取全局信息,易导致关键细节丢失,尤其影响异常检测这类对细微变化敏感的任务。本文提出在编码器中引入 MDRB,如图 1 所示。通过动态融合多尺度特征,有效提取从细粒度到粗粒度的多层次特征,减少特征缺失问题,优化了模型对异常样本的检测能力。

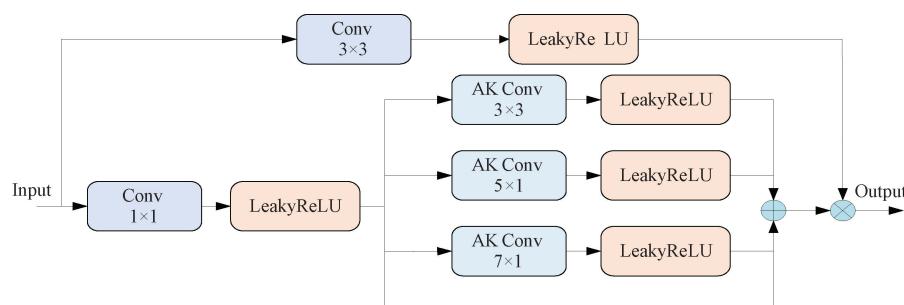


图 1 多尺度动态残差模块

Fig. 1 Multi-scale dynamic residual block diagram

多尺度特征提取与残差连接的有效组合,对于提升模型性能至关重要。通过相加和相乘的操作,能够将不同尺度和层次的特征信息进行有效结合,在轮胎缺陷检测中,小尺度特征可捕捉到轮胎表面细微的缺陷特征;大尺度特征则能把握轮胎整体的结构信息。通过融合,生成更丰富更具代表性的特征表示,有助于更准确地识别轮胎的各种缺陷,同时有效避免梯度消失等问题,提升模型在轮胎缺陷检测任务中的整体性能。

针对传统卷积核的固定结构所存在的局限性问题,在MDRB中引入AKConv(图2),该卷积支持任意形状的采样点分布,同时可以分布在输入特征图上的任何位置。每个AKConv后都紧接着LeakyReLU激活函数,进一步增强特征的非线性表达能力。AKConv的灵活性显著增强了模型对轮胎多样化缺陷形状的适应性,同时提高了对轮胎复杂结构的学习能力。此外,AKConv的采样模式还能在训练流程中不断优化,即便引入了更多自由度,依然保持高效的计算能力,确保在处理大量轮胎图像进行缺陷检测时,模型既能准确识别缺陷,又能保持较高的运行效率,为轮胎质量检测提供可靠的技术支持。

1.2 通道残差像素解码器

解码器的重建过程是异常检测的关键环节之一,重建图像质量的好坏直接影响着模型的性能。如果解码器能够高质量地重建正常样本,那么这些样本的重建误差

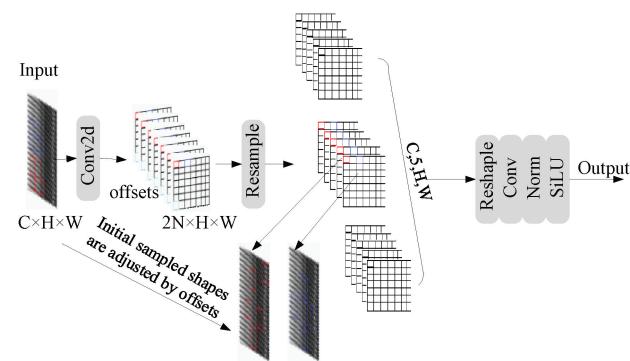


图2 可变核卷积结构的详细示意图

Fig. 2 Detailed schematic diagram of the arbitrary kernel convolution structure

会相对较小。对于异常样本,由于它们与训练数据的分布不同,解码器难以有效地重建,因此会产生较大的重建误差。这种差异使得模型更容易区分正常和异常样本,从而提高异常检测的准确性。为了提高解码器的重建能力,将原来单一的解码器改为两个并行的解码器结构。这两个解码器用于并行学习,均包含5个上采样块,最后将两个特征图进行融合。其中CRSD在5个上采样块中引入通道自适应特征注意力(channel attention and adaptive feature fusion, CAFF),如图3所示。

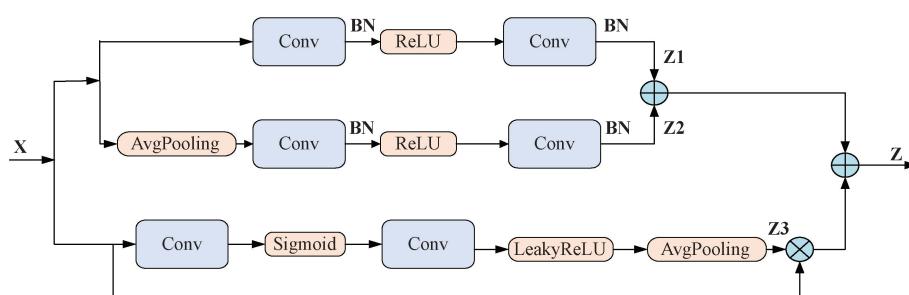


图3 通道自适应特征注意力结构

Fig. 3 Channel attention and adaptive feature fusion structure diagram

CAFF是基于多尺度通道注意模块^[23]改进而来的,其对气泡、杂质等缺陷的特征更加敏感,增强了轮胎异常检测的性能。具体训练过程如式(1)~(4)所示。

$$Z_1 = BN(PC(\delta(BN(PC(x))))) \quad (1)$$

$$Z_2 = BN(PC(\delta(BN(PC(AP(x)))))) \quad (2)$$

$$Z_3 = AP(\zeta(PC(\sigma(PC(x))))) \quad (3)$$

$$Z = (Z_1 \oplus Z_2) \oplus (x \otimes Z_3) \quad (4)$$

式中: x 表示输入; Z_1, Z_2, Z_3 表示中间过程的输出; Z 表示最终的输出; BN 表示BatchNorm层; PC 表示Conv层; δ 表示ReLU激活函数; σ 表示Sigmoid激活函数; AP 表示AvgPooling操作; ζ 表示LeakyReLU激活函数; \oplus 表示对应元素相加; \otimes 表示对应元素相乘。

随后连接子像素卷积层^[24]和3个残差块。子像素卷积层可减少训练时间、节省内存,提供更多上下文信息以提升生成轮胎图像质量,同时残差块能学习轮胎图像高频信息与细节。

改进后的模型在重构轮胎图像时,能够更精准地聚焦于轮胎的关键结构和纹理信息,这不仅有助于提高轮胎图像的重构质量,而且在检测异常轮胎时,能够更敏锐地捕捉到异常轮胎与正常轮胎图像之间的差异,从而提升对轮胎异常情况检测的准确性和鲁棒性。

1.3 二元并行判别网络

判别器通过区分真实与生成样本推动生成器优化,其学习的特征与生成器特征结合辅助异常检测。原有的

全局判别器在评估时会忽略图像不同部分可能存在的复杂性和多样性的问题。例如,一张图像中可能存在某些区域非常逼真,而其他区域则明显是由生成器伪造的,但全局判别器却只能给出一个笼统的评分,无法具体指出哪些部分更接近真实,哪些部分需要改进。这种方式不仅影响了模型训练的有效性,也导致生成器学习到不理想的图像特征。

为了改善这一问题,引入 DDMN,如图 4 所示,代替原有的全局判别器,能够捕捉到图像中不同区域的特征,增强对图像的识别能力。判别器均由四个结构块和一个二维卷积层组成,每个结构块均包括可切换空洞卷积(switchable atrous convolution, SAC)^[25]、InstanceNorm 层和 LeakyReLU 激活函数层。

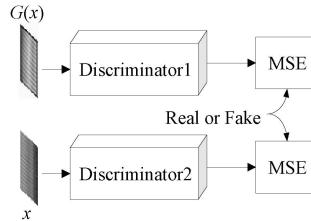


图 4 二元并行判别网络

Fig. 4 Dual discriminative module network

SAC 用于提取特征,其采用扩张率为 r 的空洞卷积,

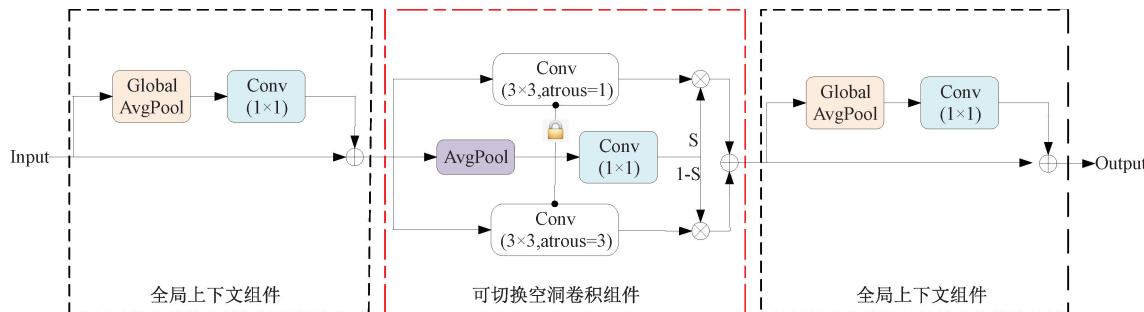


图 5 可切换空洞卷积结构

Fig. 5 Switchable atrous convolution structure diagram

1.4 整体网络结构

$D^2GANomaly$ 网络模型架构如图 6 所示。网络结构包含 3 个子网络,第 1 个子网络是一个自编码器,作为生成网络。第 2 个子网络是一个再编码器,结构与生成网络中的编码器一样。第 3 个子网络是一个判别网络。 $D^2GANomaly$ 网络模型在编码器中将 MDRB 整合至每个卷积层的后方,提高了模型特征提取的能力。而在解码器部分引入了一个 CRSD,形成双解码器结构,一个关注全局,另一个关注细节。将两个特征图进行融合,充分结合两个特征图的特点,有效提高了重构能力。此外,采用 DDMN 作为判别网络,通过结合两个判别器的输出,能够

通过在相邻卷积核元素间填充 $r-1$ 个零值元素,将原始 $k \times k$ 尺寸的卷积核扩展为 $k+(k-1)(r-1)$ 尺寸,同时避免了参数规模和计算复杂度的增加。图 5 所示是 SAC 的整体结构,输入首先进入全局上下文组件,通过全局平均池化结合 1×1 卷积操作实现特征整合,随后与原始输入进行逐元素相加融合。经初步融合的特征图被输入至可切换空洞卷积模块,该模块通过 Switch 函数动态计算标准卷积与空洞卷积的权重配比,输出二者的加权结果。最终,处理后的特征图再次进入全局上下文组件完成后续处理。如式(5)所示。

$$y = S(x) \text{Conv}(x, w, 1) + (1 - S(x)) \text{Conv}(x, w + \Delta w, r) \quad (5)$$

式中: y 为输出; x 为输入; w 表示权重; r 表示空洞率,当 $r=1$ 时代表普通卷积; Δw 为可学习的权重; $S(x)$ 为 Switch 开关函数,由 5×5 的平均池化层和 1×1 的卷积层组成。

InstanceNorm 对特征图归一化以加速训练和提升稳定性,LeakyReLU 作为激活函数解决 ReLU 在负半轴梯度为 0 的问题,利于梯度传递。判别器 1 对生成器生成的图像进行评估,判别器 2 对真实图像进行评估,判别器执行各自的任务,输出两个标量值,表示图像被视为真实的概率,并分别通过均方误差损失函数计算与真实标签之间的差异。

更全面地评估图像,提升了模型缺陷检测的能力。

1.5 损失函数

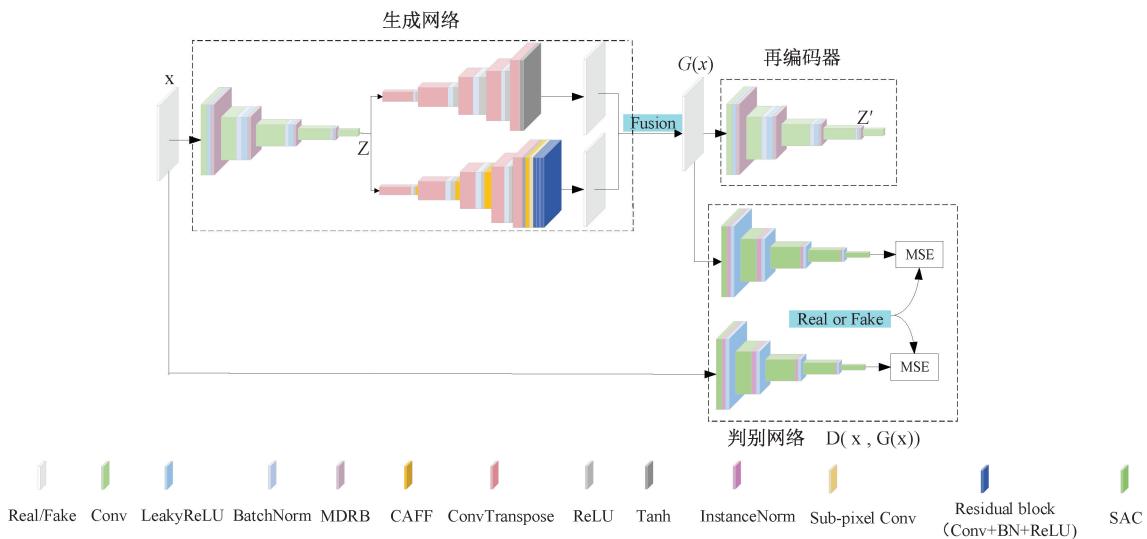
$D^2GANomaly$ 采用了 3 个损失函数,包括重建损失、编码损失和对抗损失。

1) 重建损失表示原始输入图像 x 和通过生成网络重建的图像 $G(x)$ 之间的差异,重构损失函数如式(6)所示。

$$L_{con} = E_{x \sim p_x} \| x - G(x) \|_1 \quad (6)$$

式中: $\| \cdot \|_1$ 表示 L1 范数。

2) 编码损失表示原始输入样本通过编码器得到的隐向量 Z 与重构样本再次通过编码器得到的隐向量 Z' 之

图 6 D²GANomaly 网络模型Fig. 6 D²GANomaly network model

间的差异，编码损失函数如式(7)所示。

$$L_{enc} = E_{x \sim p_x} \| \mathbf{Z} - \mathbf{Z}' \|_2 \quad (7)$$

式中： $\| \cdot \|_2$ 表示 L2 范数。

3) 对抗损失对抗损失的核心目的是通过生成器与判别器的动态博弈，强制生成器精确学习正常样本的数据分布，对抗损失函数如式(8)所示。

$$L_{adv} = E_{x \sim p_x} \| MSE(D(x)) - MSE(D(G(x))) \|_2 \quad (8)$$

式中： $D(x)$ 表示真实数据样本 x 在判别器上的输出； $D(G(x))$ 为生成数据样本 $G(x)$ 在判别器上的输出； $\| \cdot \|_2$ 表示 L2 范数。

2 实验

2.1 实验数据集

实验采用公开的 MVTec AD^[26] 数据集和实验室自制的轮胎 X 光图像数据集开展。

1) MVTec AD 数据集

MVTec AD 数据集包含 15 个类别，涵盖 5 种纹理与 10 种物体（如胶囊、榛子、拉链等），总计 5 354 张图像，1 900 个标注区域。其中，训练集包含 3 629 张无缺陷图像，测试集包含 1 725 张图像（正常样本与缺陷样本）。测试集涵盖 73 种不同类型的缺陷，如外观缺陷，结构缺陷等。该数据集类别分布呈现不平衡性、类内样本存在较大变异性、部分缺陷具有细微性，能够有效模拟真实工业场景，为算法性能的验证提供了高度贴近实际应用的测试环境。MVTec AD 数据集（胶囊）部分图片如图 7 所示。



图 7 MVTec AD 数据集展示图

Fig. 7 MVTec AD dataset display diagram

2) 自制轮胎 X 光图像数据集

实验室自制的轮胎 X 光图像数据集包含训练集、测试集、真值标注 3 部分，遵循“训练-测试-评估”的标准流程，确保模型训练、性能验证和结果量化的完整性。训练阶段选取 10 000 张无缺陷轮胎 X 光图像作为训练样本，如图 8 所示。模型完成训练后，通过测试集评估其训练效能。该测试集包含无缺陷图像与缺陷图像两类，其中缺陷图像包含 4 种不同类型的轮胎 X 光缺陷样本，无缺陷图像与缺陷图像均为 1 908 张。具体缺陷类型及数量如表 1 和图 9 所示。

2.2 实验相关参数

1) 参数设置

在模型参数优化中，选用性能稳健、收敛快的 Adam 优化器^[27]，兼具动量与自适应学习率优势。动量参数设为 $b_1 = 0.5, b_2 = 0.999$ ，其中 b_1 根据 WGAN-GP 稳定性理论^[28] 取值，增强对梯度变化的敏感度，利于对抗训练动

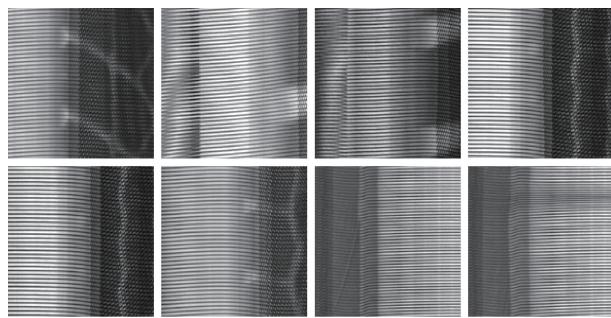


图 8 轮胎 X 光图像无缺陷样本图

Fig. 8 Tire X-ray normal sample image

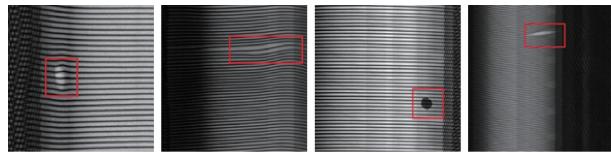


图 9 轮胎 X 光图像缺陷样本图

Fig. 9 Tire X-ray abnormal sample image

表 1 轮胎 X 光图像缺陷类型及数量

Table 1 Types and number of defects in Tire X-ray

| 缺陷类型 | 图像数量 |
|------|-------|
| 杂质 | 513 |
| 气泡 | 499 |
| 帘线弯曲 | 441 |
| 胎稀 | 455 |
| 混合 | 1 908 |

态平衡, b_2 可优化稀疏梯度^[29] 确保长期训练的鲁棒性。初始学习率设为 1×10^{-4} , 处于 Adam 典型推荐范围^[27] ($1 \times 10^{-3} \sim 1 \times 10^{-5}$) 内, 可避免训练初期梯度爆炸或震荡。隐变量维度 Z 依据 DCGAN^[30] 的基准设置为 100, 可有效捕捉并表征数据中的关键特征。模型训练 100 轮, 第 80~100 轮模型进入稳态, 此轮次被广泛验证能平衡训练充分性与效率^[28,30-31]。

2) 实验平台配置

实验的开发平台配置为 Python3.8 和 Pytorch1.10.0, 深度卷积神经网络开发工具。计算机的硬件配置为 Intel (R) Xeon (R) Gold 6430、NVIDIA GeForce RTX 4090 GPU、24 G 内存。编程环境为 Ubuntu20.04 操作系统。

3) 评价指标

本文采用受试者工作特征曲线下面积 (area under curve, AUC) 和平均精度 (average precision, AP) 作为核心评价指标, 对不同模型在检测任务中的性能展开量化评估与对比分析。

(1) 评价指标 AUC

AUC 指代的是受试者工作特征曲线 (receiver

operating characteristic curve, ROC) 曲线下面积。ROC 曲线以假正类率 (false positive rate, FPR) 为横轴, 真正类率 (true positive rate, TPR) 为纵轴, 反映模型区分正常样本与缺陷样本的整体能力。FPR 和 TPR 计算如式(9)所示。

$$\begin{cases} FPR = \frac{FP}{FP + TN} \\ TPR = \frac{TP}{TP + FN} \end{cases} \quad (9)$$

式中: FP 为误判为缺陷的正常样本数; TN 为正确识别的正常样本数; TP 为正确识别的缺陷样本数; FN 为漏检的缺陷样本数。

AUC 借助遍历所有可能分类阈值, 得到不同的 FPR 和 TPR 点, 连接这些点就形成了 ROC 曲线, 而 AUC 用于评估模型性能, 取值范围在 0~1 之间, AUC 值越大, 表明模型区分正样本和负样本的能力越强。

(2) 评价指标 AP

AP 是对精确率-召回率曲线 (precision-recall curve, PRC) 的量化评估指标。PRC 曲线以召回率为横轴, 精确率为纵轴, 能够更真实地反映模型在目标类别上的识别效能。召回率和精确率的计算如式(10)所示。

$$\begin{cases} Recall = \frac{TP}{TP + FN} \\ Precision = \frac{TP}{TP + FP} \end{cases} \quad (10)$$

AP 是通过对 PRC 曲线上不同召回率点对应的精确率进行加权平均得到的, 本质上是对 PRC 曲线所反映信息的进一步提炼和总结, 用于综合衡量模型在识别正例方面的性能。

2.3 实验结果分析

1) MVTec AD 数据集

为了验证所提方法的有效性, 将本文方法与 4 种典型的异常检测方法在 MVTec AD 数据集上进行详细对比分析, 实验结果如表 2 所示。

从表 2 可知, 改进后的 D²GANomaly 模型在 MVTec AD 数据集的 15 类缺陷检测中, AUC 均值为 0.781, 较原始 GANomaly 模型提升了 0.138。相较于 AnoGAN、F-AnoGAN 和 Skip-GANomaly, AUC 均值分别提升了 0.209、0.203 和 0.094, 验证了改进方法的有效性。在不同模型对同种缺陷的 AUC 值对比中, AnoGAN 在 grid 缺陷检测、GANomaly 在 transistor、wood、zipper 缺陷检测以及 Skip-GANomaly 在 zipper 缺陷检测上, 呈现出一定的优势。这是因为不同类型缺陷的图像背景在复杂程度上存在差异, 且模型复杂度各不相同。在处理一些具有简单纹理或几何特征的缺陷时, 复杂度较低的模型反而能更聚焦于这些缺陷的关键特征, 因此个别模型会在检测精

度上体现出优势。不过,总体而言,多数缺陷种类在不同模型下的AUC值仍低于改进后的D²GANomaly模型。综

上所述,改进后的D²GANomaly模型在异常检测任务中具有较强的普适性。

表2 MVTec AD数据集AUC值实验结果对比

Table 2 Comparison table of experimental results for AUC values on MVTec AD dataset

| 种类 | AnoGAN ^[12] | F-AnoGAN ^[13] | GANomaly ^[9] | Skip-GANomaly ^[10] | D ² GANomaly(本文) |
|------------|------------------------|--------------------------|-------------------------|-------------------------------|-----------------------------|
| bottle | 0.680 | 0.503 | 0.747 | 0.764 | 0.820 |
| cable | 0.560 | 0.612 | 0.627 | 0.613 | 0.803 |
| capsule | 0.593 | 0.534 | 0.531 | 0.671 | 0.780 |
| carpet | 0.302 | 0.543 | 0.443 | 0.625 | 0.752 |
| grid | 0.879 | 0.762 | 0.801 | 0.808 | 0.844 |
| hazelnut | 0.654 | 0.637 | 0.676 | 0.668 | 0.804 |
| leather | 0.691 | 0.588 | 0.694 | 0.648 | 0.814 |
| metal_nut | 0.350 | 0.426 | 0.428 | 0.673 | 0.752 |
| pill | 0.384 | 0.435 | 0.456 | 0.617 | 0.838 |
| screw | 0.720 | 0.652 | 0.667 | 0.760 | 0.820 |
| tile | 0.669 | 0.721 | 0.593 | 0.619 | 0.778 |
| toothbrush | 0.438 | 0.552 | 0.680 | 0.690 | 0.748 |
| transistor | 0.545 | 0.527 | 0.723 | 0.623 | 0.698 |
| wood | 0.579 | 0.578 | 0.781 | 0.746 | 0.753 |
| zipper | 0.537 | 0.605 | 0.809 | 0.781 | 0.716 |
| 均值 | 0.572 | 0.578 | 0.643 | 0.687 | 0.781 |

2) 实验室自制数据集

为了进一步验证改进后的模型在图像缺陷检测方面相较于其他模型具备更优越的性能,在实验室自制数据集上进行了详细的对比实验分析。对GANomaly和当下具有代表性的模型与D²GANomaly进行比较,得到的ROC和PRC对比如图10、11所示。

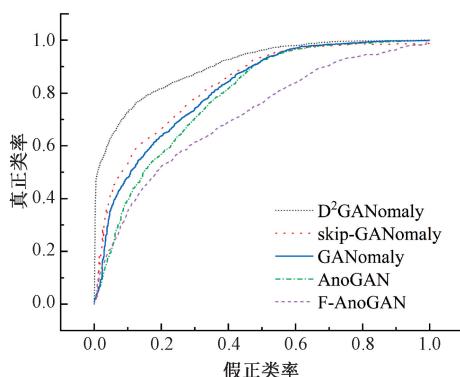


图10 ROC对比

Fig. 10 ROC comparison chart

观察图10可以看到,假正类率较低时,D²GANomaly的真正类率最高,曲线下覆盖面积最大,表明D²GANomaly能以更低的误报率,识别出更多真实异常(轮胎缺陷),对异常的识别与区分能力更强,性能最优。

观察图11可知,D²GANomaly曲线整体处于上方区域,在召回率变化过程中,其精确率始终维持相对较高水平,曲线覆盖面积更大。这表明D²GANomaly既能有效

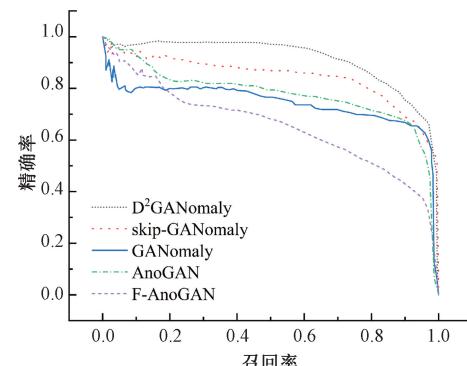


图11 PRC对比

Fig. 11 PRC comparison chart

识别更多真实轮胎缺陷,又能降低将正常样本误判为异常的情况,性能表现尤为突出。

(1) 对比实验

本文对模型AnoGAN、F-AnoGAN、GA-Nomaly、Skip-GANomaly以及D²GANomaly进行训练和测试,得到的结果如表3所示。

表3 轮胎X光图像实验结果对比

Table 3 Comparison table of experimental results

values of tire X-ray images

| 模型 | AUC | AP |
|----------------------------------|--------------|--------------|
| AnoGAN ^[12] | 0.741 | 0.803 |
| F-AnoGAN ^[13] | 0.669 | 0.682 |
| GANomaly ^[9] | 0.786 | 0.747 |
| Skip-GANomaly ^[10] | 0.807 | 0.792 |
| D²GANomaly(本文) | 0.923 | 0.911 |

根据以上数据分析,改进后的 D²GANomaly 模型在相同的轮胎 X 光图像数据集上,其 AUC 值和 AP 值均展现出显著的提升。具体而言,相较于原始的 GANomaly 模型,D²GANomaly 的 AUC 值提高了 0.137,AP 值提高了 0.164。此外,与 AnoGAN、F-AnoGAN 和 Skip-GANomaly 相比,D²GANomaly 在 AUC 值上分别提升了 0.182、0.254 和 0.116,在 AP 值上分别提升了 0.108、0.229 和 0.119。这一系列实验结果有力地验证了 D²GANomaly 模型的有效性。

编码损失衡量的是输入图像的潜在表示和重构图像的潜在表示之间的差距。基于模型的结构组成,基础模型与改进后的模型进行了编码损失对比,对比如图 12 所示。

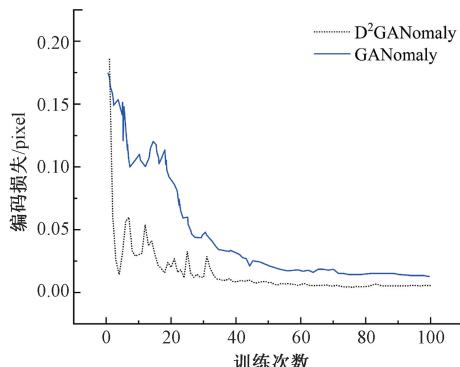


图 12 编码损失函数曲线对比

Fig. 12 Comparison of encoding loss curves

观察图 12 可以发现,GANomaly 模型编码损失的收敛值为 0.022,改进后的模型 D²GANomaly 的收敛值为 0.016,编码损失下降了 0.006。

表 4 消融实验数据表
Table 4 Ablation experiment data table

| 模型 | 气泡 | 杂质 | 胎稀 | 帘线弯曲 | 混合 |
|--------------------------------|--------------|--------------|--------------|--------------|--------------|
| GANomaly | 0.815 | 0.804 | 0.769 | 0.745 | 0.786 |
| GANomaly+MDRB | 0.816 | 0.841 | 0.892 | 0.861 | 0.850 |
| GANomaly+CRSD | 0.809 | 0.826 | 0.948 | 0.862 | 0.855 |
| GANomaly+DDMN | 0.754 | 0.804 | 0.939 | 0.959 | 0.878 |
| GANomaly+MDRB+CRSD | 0.853 | 0.877 | 0.977 | 0.965 | 0.913 |
| GANomaly+MDRB+DDMN | 0.831 | 0.854 | 0.989 | 0.986 | 0.910 |
| GANomaly+MDRB+CRSD+DDMN | 0.848 | 0.828 | 0.980 | 0.980 | 0.923 |

本次消融实验的数据,不仅验证了 D²GANomaly 在轮胎 X 光图像缺陷检测任务中的有效性,还揭示了不同模块对于提升模型性能的重要作用,从混合缺陷的数据来看,各模块对模型识别缺陷的能力均有显著提升:单独引入 MDRB 时,基础特征提取得到优化,AUC 值提升至 0.850;单独引入 CRSD 时,在提升重构图像质量的同时优化了混合异常识别能力,AUC 值上升至 0.855;将 DDMN 模块替换原全局判别器后,识别重构图像与真实

重构损失衡量的是输入图像和生成器生成的重构图像之间的差距,依据模型结构组成的特点,选取当前具有代表性的模型进行比较,对比如图 13 所示。

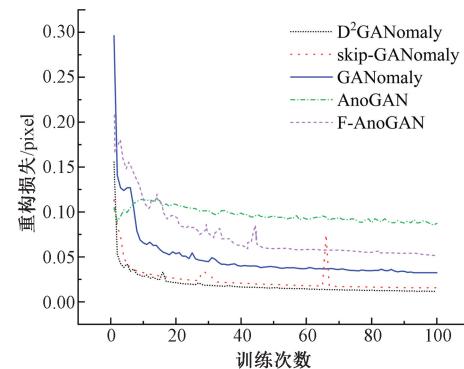


图 13 重构损失函数曲线对比

Fig. 13 Comparison of reconstruction loss curves

观察图 13 可以发现,D²GANomaly 的重构损失函数比其他几个模型都要小,D²GANomaly 的重构损失基本上接近 0.015,表明模型具有很好的重构能力。

综上结果表明,改进后的模型在捕捉和重建图像方面具有较强的能力,确保了更高质量的图像重建,提高了模型的异常检测能力。

(2) 消融实验

在相同实验条件下,通过消融实验评估各模块对模型性能的贡献。以 GANomaly 为基准模型,在轮胎 X 光图像数据集上展开测试。所有实验均遵循先前提及的相同参数设置,以确保实验的一致性和准确性。实验结果如表 4 所示。

图像之间差异的能力增强,AUC 值上升至 0.878。而当 3 个模块协同作用时,混合 AUC 值跃升至 0.923,不仅突破了单模块的局限,更全面提升了缺陷检测的能力。

3 结论

本文提出的 D²GANomaly 模型,在原始的 GANomaly 模型的基础上,编码器部分引入 MDRB,提高了对细节的特征提取能力;解码器部分引入 CRSD,提高处理复杂背景和细节的能力,进而提升了重构图像质量;用 DDMN

代替原有的全局判别器，增强了鉴别能力。实验结果表明，该方法在轮胎X光图形缺陷检测任务中具有较高的准确率和鲁棒性。然而，实验发现，相较于其他类型的缺陷，杂质缺陷区域与正常背景的灰度差异较小，导致D²GANomaly模型对其检测效果欠佳。未来研究将聚焦于缺陷与背景差异较小场景下的检测方法，重点探索如何放大低对比度缺陷与正常背景间的细微特征差异，进一步提升异常检测的判别精度。

参考文献

- [1] 夏以柠. 生成式人工智能技术进展及其在自动驾驶领域的应用与展望[J]. 汽车技术, 2023(9):43-48.
- XIA Y N. Progress of generative artificial intelligence technology and its application and prospects on autonomous driving[J]. Automobile Technology, 2023(9): 43-48.
- [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] 李阳,蒋三新. 基于改进生成对抗网络的无监督晶圆缺陷检测[J]. 电子测量技术, 2023,46(6):91-99.
- LI Y, JIANG S X. Unsupervised wafer defect detection based on improved generative adversarial network [J]. Electronic Measurement Technology, 2023, 46 (6) : 91-99.
- [4] 宋晔,吴一全. 基于无人机航拍的风力发电机叶片表面缺陷检测综述[J]. 仪器仪表学报, 2024,45(10):1-25.
- SONG Y, WU Y Q. Review of wind turbine blade surface defect detection based on UAV aerial photography [J]. Chinese Journal of Scientific Instrument, 2024,45(10): 1-25.
- [5] 邹磊,冯治国,梁鹏翔,等. 基于U-Net的启闭机钢丝绳缺陷定位方法研究[J]. 国外电子测量技术, 2024, 43(9):155-160.
- ZOU L, FENG ZH G, LIANG X P, et al. Research on steel wire rope breakage fault localization based on U-Net [J]. Foreign Electronic Measurement Technology, 2024, 43(9): 155-160.
- [6] 李洪奎,陈浩,刘韵婷,等. 基于改进自编码器结构的轮胎缺陷检测[J]. 电子测量与仪器学报, 2024, 38(10):170-179.
- LI H K, CHEN H, LIU Y T, et al. Tire defect detection based on improved autoencoder structure [J]. Journal of Electronic Measurement and Instrumentation, 2024,38 (10) : 170-179.
- [7] 张兴伟,刘韵婷,陈浩,等. 基于U-Net判别器的轮胎图像缺陷检测方法研究[J]. 电子测量技术, 2024, 47(16):139-146.
- ZHANG X W, LIU Y T, CHEN H, et al. Research on tire image defect detection method based on U-Net discriminator [J]. Electronic Measurement Technology, 2024,47(16):139-146.
- [8] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [J]. Advances in Neural Information Processing Systems, 2014,27(2):2672-2680.
- [9] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Ganomaly: Semi-supervised anomaly detection via adversarial training [C]. Asian Conference on Computer Vision. Cham: Springer International Publishing, 2018: 622-637.
- [10] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Skip-GANomaly: Skip connected and adversarially trained encoder-decoder anomaly detection [C]. Proceedings of the International Joint Conference on Neural Networks. IEEE, 2019: 1-8.
- [11] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.
- [12] SCHLEGL T, SEEBÖCK P, WALDSTEIN S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery [C]. International Conference on Information Processing in Medical Imaging. Cham: Springer International Publishing, 2017: 146-157.
- [13] 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.
- [14] ZENATI H, FOO C S, LECOUAT B, et al. Efficient GAN-based anomaly detection[J]. ArXiv preprint arXiv: 1802.06222, 2018.
- [15] PIDHORSKYI S, ADJEROH D A, DORETTO G. Adversarial latent autoencoders [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 14104-14113.
- [16] SAKURADA M, YAIRI T. Anomaly detection using autoencoders with nonlinear dimensionality reduction [C]. Machine Learning for Sensory Data Analysis, 2014.
- [17] HE L, SHI N, MALIK K, et al. Unsupervised defect

- inspection algorithm based on cascaded GAN with edge repair feature fusion [J]. Applied Intelligence, 2022, 52(2) : 2051-2069.
- [18] LI C, FU R, LIU Y. Algorithm for generating tire defect images based on RS-GAN [C]. International Conference on Neural Information Processing. Singapore: Springer Nature Singapore, 2023: 388-399.
- [19] PENG J, SHAO H, XIAO Y, et al. Industrial surface defect detection and localization using multi-scale information focusing and enhancement GANomaly [J]. Expert Systems with Applications, 2024, 238: 122361.
- [20] ZHANG X, SONG Y, SONG T, et al. LDConv: Linear deformable convolution for improving convolutional neural networks [J]. Image and Vision Computing, 2024, 149: 105190.
- [21] MIN F, WANG L, PAN S, et al. D²UNet: dual decoder U-net for seismic image super-resolution reconstruction [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-13.
- [22] LYU J, FU Y, YANG M, et al. Generative adversarial network-based no contrast CT angiography for aorta and carotid arteries [J]. Radiology, 2023, 309(2): e230681.
- [23] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion [C]. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2021: 3560-3569.
- [24] LIU M, JUN D, LU Z, et al. CM-UNet: Hybrid CNN-Mamba UNet for remote sensing image semantic segmentation [J]. ArXiv preprint arXiv: 2405.10530, 2024.
- [25] QIAO S, CHEN L C, YUILLE A. Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10213-10224.
- [26] BERGMANN P, FAUSER M, SATTLEGGER D, et al. MVTec AD —A comprehensive real-world dataset for unsupervised anomaly detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2019: 9584-9592.
- [27] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. ArXiv preprint arXiv: 1412.6980, 2014.
- [28] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein GANs [C]. Proceedings of the 31st International Conference on Neural Information Processing System, 2017: 5769-5779.
- [29] LIN Y, HAN S, MAO H, et al. Deep gradient compression: Reducing the communication bandwidth for

distributed training [J]. 2017.

- [30] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. ArXiv preprint arXiv: 1511.06434, 2015.
- [31] KARRAS T, AITTALA M, HELLSTEN J, et al. Training generative adversarial networks with limited data [J]. Advances in Neural Information Processing Systems, 2020, 33: 12104-12114.

作者简介



刘韵婷(通信作者),2015 年获东北大学博士学位,现为沈阳理工大学副教授,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

Liu Yunting (Correspondence author),

received her Ph. D. degree from Northeastern University in 2015. She is now an associate professor and M. Sc. supervisor of Shenyang University of Technology. Her main research interests include wireless sensor networks, artificial intelligence technology and data analysis.



冯欣悦,2023 年于山东工商学院获学士学位,现为沈阳理工大学硕士研究生,主要研究方向为异常检测。

E-mail: fxy010828@163.com

Feng Xinyue received her B. Sc. degree

from Shandong University of Commerce in 2023. She is now a M. Sc. candidate at Shenyang University of Technology. Her main research interest includes anomaly detection.



李思维,2021 年于沈阳理工大学获学士学位,现为沈阳理工大学硕士研究生,主要研究方向为异常检测。

E-mail: 18512448215@163.com

Li Siwei received her B. Sc. degree from

Shenyang University of Technology in 2021. She is now a M. Sc. candidate at Shenyang University of Technology. Her main research interest includes anomaly detection.



张智星,2023 年于河北建筑工程学院获学士学位,现为沈阳理工大学硕士研究生,主要研究方向为异常检测。

E-mail: 1736241818@qq.com

Zhang Zhixing received his B. Sc.

degree from Hebei Institute of Architecture and Engineering in 2023. He is now a M. Sc. candidate at Shenyang University of Technology. His main research interest includes anomaly detection.