

DOI:10.19651/j.cnki.emt.2519558

基于改进 GANomaly 网络的轮胎缺陷图像检测^{*}

刘韵婷 李思维 冯欣悦 张智星

(沈阳理工大学自动化与电气工程学院 沈阳 110159)

摘要: 工业产品中的缺陷样本获取困难,而且缺陷的表现形式多种多样,针对如何能更好的识别缺陷,提高检测精度,提出一种基于 GANomaly 改进的异常检测模型 SPGAN。首先,设计 SPAM 双注意力模块,通过空间注意力与位置感知注意力的协同机制,实现缺陷局部纹理与全局空间关系的联合感知;其次,在编解码器间引入改进的 Inception 模块,利用多尺度卷积核增强微小缺陷特征重构能力;最后,构建基于 ResNet18 的深度判别器网络,通过残差连接强化异常特征判别性能。为了验证改进网络的有效性,利用自制的轮胎数据集进行了一系列的对比实验和消融实验。实验结果表明,改进网络在自制的轮胎缺陷图像检测数据集上的检测与分割效果有了很大提升,其中 AUC 值达到了 0.948,AP 值达到了 0.885,相比于原模型 AUC 值提升了 9%,AP 值提升了 8.9%,从实验结果可以看出,该方法在工业缺陷检测领域具有较好的应用潜力。

关键词: GANomaly;SPAM 注意力;Inception 模块;ResNet 判别器;异常检测

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 510.40

Tire defect image detection based on improved GANomaly network

Liu Yunting Li Siwei Feng Xinyue Zhang Zhixing

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

Abstract: Obtaining defective samples in industrial products is difficult, and the manifestations of defects are diverse. To better identify defects and improve detection accuracy, an anomaly detection model SPGAN based on GANomaly improvement is proposed. First, a SPAM dual attention module is designed, which realizes the joint perception of local defect texture and global spatial relationships through the synergistic mechanism of spatial attention (SAM) and position-aware attention (PAM). Second, an improved Inception module is introduced between the encoder and decoder to enhance the reconstruction ability of tiny defect features using multi-scale convolutional kernels. Finally, a deep discriminator network based on ResNet18 is constructed to strengthen the discrimination performance of abnormal features through residual connections. To verify the effectiveness of the improved network, a series of comparative experiments and ablation experiments were conducted using a self-made tire dataset. The experimental results show that the improved network has significantly improved detection and segmentation performance on the self-made tire defect image detection dataset, with an AUC value of 0.948 and an AP value of 0.885, an increase of 9% in AUC and 8.9% in AP compared to the original model. The experimental results demonstrate that this method has good application potential in the field of industrial defect detection.

Keywords: GANomaly;SPAM attention;Inception module;ResNet discriminator;anomaly detection

0 引言

近年来,随着我国经济快速发展,汽车保有量持续攀升。作为汽车关键部件之一,轮胎的质量直接关乎驾乘人员的生命安全。统计数据显示,我国每年高速公路交通事故中,约有 46% 由轮胎故障引发,其中约 70% 由爆胎导致。

这一数据充分表明,轮胎质量对公共交通安全具有决定性影响,其安全性能的提升已成为不容忽视的重要课题。除此之外,对轮胎生产企业来说,也需要及时发现生产线中存在的合格产品,避免造成生产材料的浪费^[1]。如何提高出厂前轮胎质量的检测准确率成为了确保公共交通安全和避免材料浪费的重要研究课题。

收稿日期:2025-08-07

* 基金项目:辽宁省自然科学基金(2022-KF-14-02)、辽宁省教育厅面上项目(LJKMZ20220617)资助

随着深度学习技术的蓬勃发展,通过对大型数据集进行训练,已在缺陷检测方向取得了显著的进展^[2-7]。其中生成对抗网络(generative adversarial network, GAN)作为一种重要的无监督学习技术,已经在异常检测领域得到了广泛应用^[8-11],并取得了显著的成效。

Goodfellow 等^[12]首次将 GAN 用于图像生成并在这一领域取得了显著进展。原始的 GAN 模型由生成器和判别器组成,但是该结构较浅,出现训练稳定性差,图像分辨率低,且容易过拟合或欠拟合等问题。为了解决这些问题,不断优化结构,许多研究者对 GAN 进行了多方面的深入研究。RADFORD 等提出了深度卷积生成对抗网络(DCGAN)^[13]结合卷积层和批归一化技术,提高了生成图像的质量,还增强了训练过程的稳定性。但是该模型仍面临特征提取能力不足、模型框架不稳定、生成图像质量较差等问题。Schlegl 等^[14]提出使用生成对抗网络(anomaly detection with generative adversarial networks, AnoGAN)进行图像缺陷检测,AnoGAN 是一种基于生成对抗网络的异常检测模型,通过学习正常样本的潜在表示来识别异常数据。该方法在生成过程中评估样本的重构误差,从而有效区分正常与异常样本。但 AnoGAN 的缺点是计算量非常大,训练速度比较慢。为了解决 AnoGAN 训练速度慢的问题,2019 年,Schlegle 等^[15]提出了 F-AnoGAN (faulty anomaly generative adversarial network),通过引入特征编码器和改进的对抗训练策略,F-AnoGAN 能够更准确地捕捉正常样本的潜在特征,提升对异常样本的检测能力。

Akca 等^[16]提出了 GANomaly, GANomaly 的生成器由编码器-解码器-编码器结构组成,它结合了生成对抗网络(GAN)和自编码器的优势,为异常检测领域带来了新的思路和技术进展。GANomaly 在异常检测领域展现了优越的性能,但是仍存在重构能力不足、模式崩溃以及训练不稳定等问题。为进一步提升局部特征的保留能力, Akca 等^[17]提出的 Skip-GANomaly 在 GANomaly 基础上引入跳跃连接,实现高分辨率特征的直接传递,提升了细节重建能力。但该方法增加了模型参数与计算开销,训练更复杂,且性能依赖跳跃连接的设计与调参,存在过拟合风险。刘韵婷等^[18]提出的双判别器 GANomaly 网络通过全局和局部判别器的结合,从全局一致性与局部纹理细节两个层面提升了重建质量及异常定位的灵敏度,但训练的稳定性与局部区域的选取仍然面临挑战。针对轮胎缺陷检测等场景,后续工作进一步探索了基于注意力的变体 FAMGAN^[19],聚焦关键缺陷区域、提升局部对比度与定位能力;以及 UDGANomaly^[20]等无监督变体,旨在增强鲁棒性与泛化能力,减少对标注数据的依赖,并通过自监督信号与更灵活的分数融合提升异常检测的稳定性。总体趋势显示:通过引入全局与局部约束、注意力机制以及自监督策略,能够在提升重建质量的同时改善异常区域的可解释性与定位精度,但其同时带来额外的计算开销、超参数敏感性与训练稳定

性挑战,仍需进一步提升重构质量、训练稳定性以及对更复杂场景的细节保留能力。

因此,针对以上问题现提出一种基于 GANomaly 网络的改进生成对抗网络——SPGAN,首先在编码器和解码器中引入了 SPAM 模块,提高网络提取能力。其次,在编码器和解码器之间加入优化后的 Inception 模块,提高重建图像的质量。最后,在判别阶段,用 ResNet18 判别器替换原始的判别器,提高网络的判别性能。

1 研究内容

1.1 SPAM 双注意力模块

在轮胎缺陷图像检测中,为了更加关注图像中的重要区域,提升缺陷区域的表示能力。本研究引入空间注意力模块(SAM),由于仅考虑空间信息会使网络对图像边缘、纹理等细节的学习不足,无法更好的捕捉局部特征信息,对其进行了改进。例如,文献[21]为了捕捉更充分的局部依赖关系,在原始 GAM(global attention module)中的空间注意力子模块上并联了一个局部位置注意力模块(PAM)形成了一个双通道全局-局部位置注意力模块。而本研究在原始的 SAM 模块上并联了一个 PAM 局部位置感知模块,设计形成了 SPAM 双注意力模块,该模块通过在获得丰富的上下文依赖关系同时又能关注局部特征,从而能够更精确地捕捉特征图中的关键信息。具体结构如图 1 所示。

输入特征图分成两路,一路输入到 PAM 模块中,一路输入到 SAM 模块中。输入到 PAM 模块的特征图 $\mathbf{X} \in \mathbb{R}^{C \times H \times W}$ 首先经过一个卷积操作,产生了 3 个新的特征 $\{\mathbf{A}, \mathbf{B}, \mathbf{C}\} \in \mathbb{R}^{C \times H \times W}$ 接着将这些矩阵变形为 $\{\mathbf{A}_r, \mathbf{B}_r, \mathbf{C}_r\} \in \mathbb{R}^{C \times H \times W}$, 其中 $N = H \times W$ 是像素数。接下来将前两个矩阵进行转置相乘的矩阵运算后经过 softmax 层生成空间注意力图 $\mathbf{E} \in \mathbb{R}^{N \times N}$, 具体公式如式(1)所示。

$$\mathbf{E}_{ji} = \frac{\exp(\mathbf{A}_{ri}^T \cdot \mathbf{B}_{rj})}{\sum_{i=1}^N \exp(\mathbf{A}_{ri}^T \cdot \mathbf{B}_{rj})} \quad (1)$$

其中, \mathbf{E}_{ij} 表示第 i 个位置对第 j 个位置的影响,衡量了两个位置的相关性, T 表示矩阵的转置操作。最后将 \mathbf{C}_r 与空间注意力矩阵 \mathbf{E}_{ij} 进行矩阵相乘并将运算后的结果进行变形得到输出特征 $\mathbf{F}_p = \mathbb{R}^{C \times H \times W}$, 具体公式如式(2)所示。

$$\mathbf{F}_p = \text{reshape} \left(\sum_{i=1}^N (\mathbf{C}_r \cdot \mathbf{E}_{ji}) \right) \quad (2)$$

另一路进入 SAM 模块,输入 $\mathbf{X} \in \mathbb{R}^{C \times H \times W}$ 经过一个 3×3 卷积层,通道数减半至 $C/2$, 得到中间特征图 $\mathbf{F}_s \in \mathbb{R}^{C/2 \times H \times W}$, 对其应用 ReLU 激活函数,再经过一个 1×1 卷积层,将通道数压缩到 1,得到空间注意力图 $\mathbf{M}_s \in \mathbb{R}^{1 \times H \times W}$, sigmoid 激活函数标准化,得到最后的特征图 \mathbf{F}_s 。

接着注意力图 \mathbf{F}_p 与 \mathbf{F}_s 分别乘上一个可学习的参数后

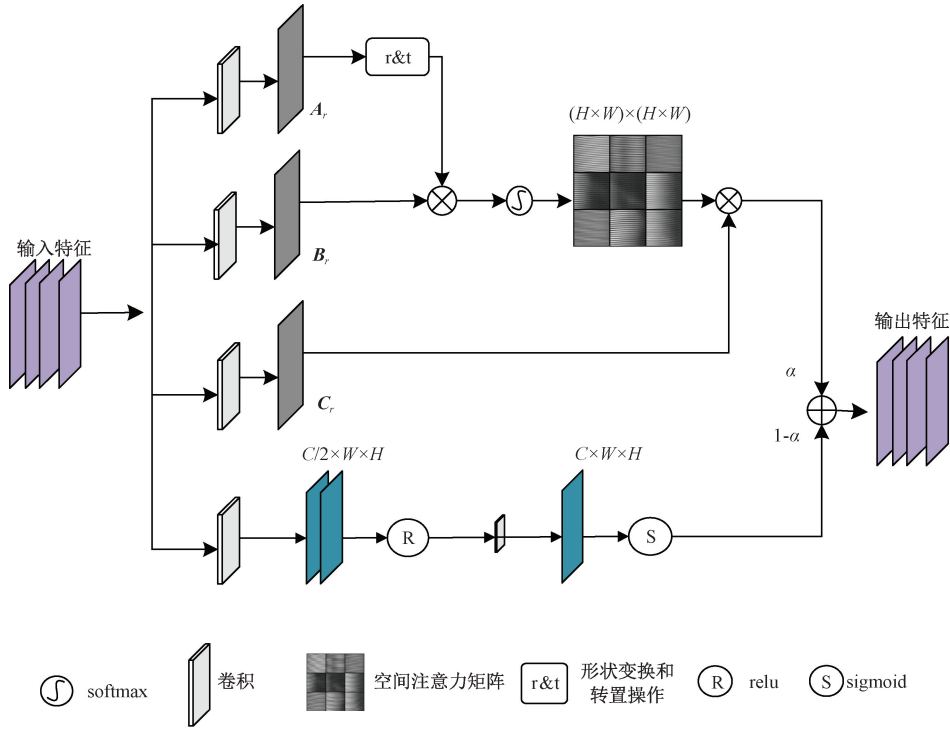


图 1 SPAM 注意力模块结构
Fig. 1 SPAM attention module structure

相加,得到最终的注意力特征图,具体公式如式(3)所示。

$$F_N = \alpha F_p \oplus (1 - \alpha) F_S \quad (3)$$

其中, $F_p = reshape(\sum_{i=1}^N (C_r \cdot E_{ji}))$ 是一个可学习的尺度标量,来调节局部位置注意力层的输出。这样的设计允许网络初期主要关注局部信息,随后逐步引入非局部信息的利用。

1.2 Inception 模块

编码器将输入数据压缩成一个低维的潜在特征向量,在这个过程中可能会丢失一些重要的细节信息。当解码器尝试从潜在向量重建原始输入图像时,可能无法完全恢复这些丢失的信息。因此,针对此问题本研究引入了优化后的 Inception 模块,相较于经典 Inception 模块,主要优化以下两个地方:引入深度可分离卷积替代标准卷积,显著降低参数量与计算开销;使用全局平均池化适配极小尺寸输入,避免池化操作失效。具体结构如图 2 所示。

1x1 卷积分支: 直接对 latent 进行 1x1 卷积操作,将通道数从 100 减少到 32。

3x3 卷积分支: 同样先进行 1x1 卷积降维至 32 通道,再进行 3x3 深度可分离卷积,提取局部特征。

5x5 卷积分支: 首先通过 1x1 卷积将通道数从 100 减少到 32,然后进行 5x5 深度可分离卷积,提取更大感受野的特征。深度可分离卷积结构如图 3 所示,具体分为两个步骤。

深度可分离卷积核主要分为逐通道卷积与逐点卷积

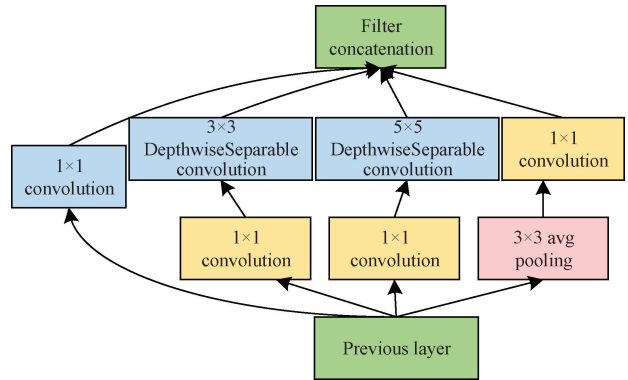


图 2 Inception 模块结构
Fig. 2 Inception module structure




图 3 深度可分离卷积结构
Fig. 3 Depthwise separable convolution architecture

两部分。在逐通道卷积阶段,每个独立卷积核仅作用于输入特征图的单一通道,实现空间维度的特征提取;逐点卷积则通过 1x1 卷积核将各通道特征进行线性组合与维度变换,最终生成具有跨通道语义融合的新特征图。

逐通道卷积的卷积核尺寸 $D_K \times D_K \times 1$, 卷积核个数为 M , 分别做 $D_F \times D_F$ 次乘法运算; 逐点卷积的卷积核尺寸为 $1 \times 1 \times M$, 卷积核个数为 N , 分别做 $D_F \times D_F$ 次乘法运算。

深度可分离卷积的参数量和计算量如式(4)、(5)所示。

$$C_1 = D_K \times D_K \times M + M \times N \quad (4)$$

$$C_2 = D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F \quad (5)$$

标准卷积的参数量和计算量如式(6)、(7)所示。

$$B_1 = D_K \times D_K \times M \times N \quad (6)$$

$$B_2 = D_K \times D_K \times M \times N \times D_F \times D_F \quad (7)$$

两者对比:

$$\frac{C_1}{B_1} = \frac{D_K \times D_K \times M + M \times N}{D_K \times D_K \times M \times N} = \frac{1}{N} + \frac{1}{D_K^2} \quad (8)$$

$$\frac{C_2}{B_2} = \frac{D_K \times D_K \times M + M \times N \times D_F \times D_F}{D_K \times D_K \times M \times N \times D_F \times D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (9)$$

由式(8)、(9)可以看出,深度可分离卷积的计算量相较于同尺寸的常规卷积核有了明显的下降,有效的起到了减少计算量的作用。

池化分支:对于 1×1 的输入,最大池化可能不起作用,因为输入尺寸已经很小,因此采用全局平均池化代替,然后进行 1×1 卷积调整通道数至 32。最后,将得到的 4 个分支的输出在通道维度上进行拼接得到最终的特征图。

1.3 ResNet 判别器

ResNet 判别器将 ResNet18 架构中的深度特征提取与简单的分类头相结合,使其在 GANomaly 中充当有效判别器,有助于解决网络训练不稳定和模式崩溃问题。相比于简单的 CNN 架构,ResNet18 可以通过其残差连接(residual connections)更好地处理深层次的特征表示,有助于提升模型性能。具体的判别器网络组成结构如图 4 所示。

ResNet18 主体部分初始化了一个经过 ImageNet 数据集预训练的 ResNet18 结构,用于轮胎缺陷图像的特征提取。该模型通过去掉最后的分类层,实现了特征提取而不进行直接预测。使用 ResNet18 的所有层,模型能够从输入图像中提取深度特征。

为完成分类任务,增加了一个自定义分类器,包括一个线性层和一个 sigmoid 激活函数。线性层输出一个值,sigmoid 函数将输出限制在 $(0, 1)$ 范围,适合二分类。ResNet 判别器有效结合了 ResNet18 的深度特征提取与简单的分类结构,最大化了紧凑模型的功能,提升了轮胎缺陷检测的准确性。

1.4 整体网络结构

SPGAN 的整体网络结构如图 5 所示,SPGAN 网络的主体部分由生成器和判别器组成。生成器部分由编码器-

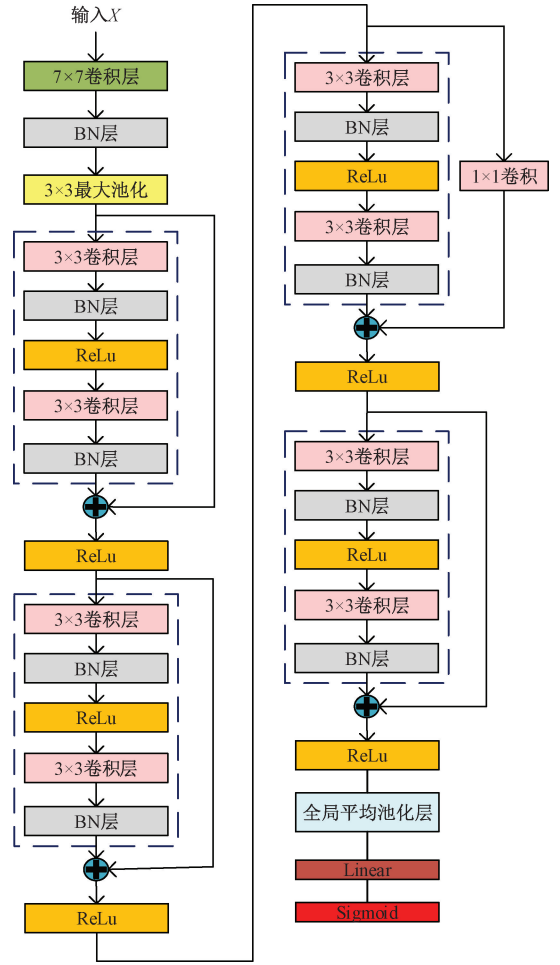


图 4 ResNet 判别器结构

Fig. 4 ResNet discriminator structure

解码器-编码器组成,先通过第 1 个编码器形成潜在特征向量,然后由解码器对潜在特征进行重构,能够更有效的识别特征信息。第 2 个编码器对生成图像下采样得到生成图像的潜在特征向量,由此可以计算出生成图像和输入图像之间的差别。

编码器具体结构包括多个卷积块,每个块由卷积层、批归一化和 ReLU 激活组成,并在每个卷积块后加入 SPAM 双注意力模块,通过逐步减少特征图大小,实现信息的深度编码。最后经过一层 conv2d 转换为潜在空间向量并和经过 Inception 模块处理后的特征图融合。生成器中两个编码器结构完全相同。

解码器由一系列反卷积(转置卷积)块组成,逐步扩大特征图的尺寸,恢复到原始图像的空间大小。每个反卷积块包括反卷积层、批归一化和 ReLU 激活函数,并在每个反卷积块后加入 SPAM 双注意力模块,确保特征的平滑复原。

判别器部分则由 ResNet18 结构组成,头部为 conv2d、batchnorm、maxpooling 这 3 个层级构成,主体部分由 8 组

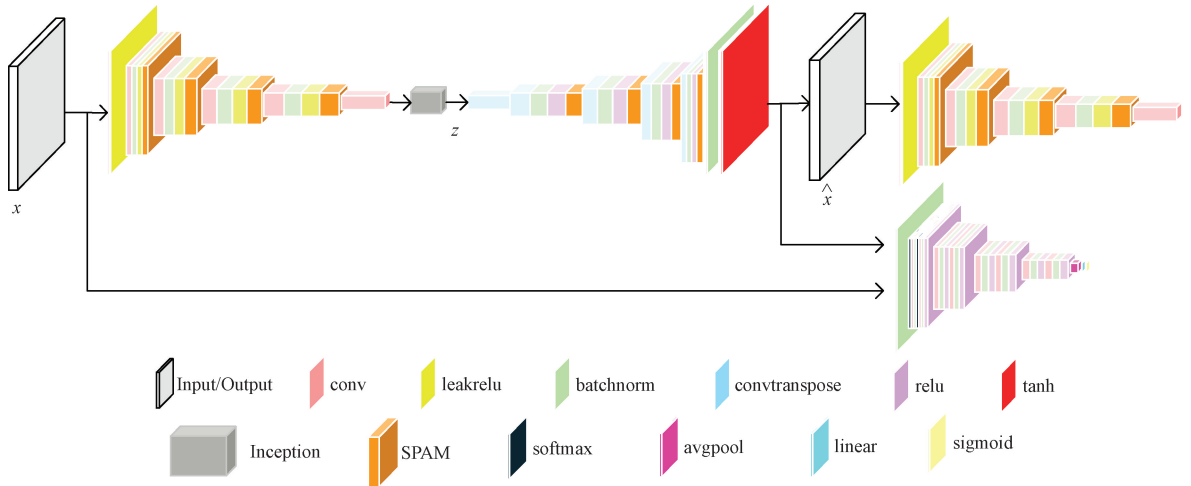


图 5 SPGAN 网络模型
Fig. 5 SPGAN network mode

conv2d、batchnorm、relu 激活函数组成，每组之间添加残差连接。尾部增加了一个自定义的分类器，由一个线性层和一个 sigmoid 激活函数组成。

SPGAN 是以 GANomaly 网络为基础模型进行改进，这些改进显著提升了在轮胎 X 光图像缺陷检测的检测精度。在编码器和解码器中加入 SPAM 注意力模块能够提高网络对图像特征的细节提取能力，在关注空间信息的同时提高对细节特征的关注。此外，在编码器和解码器之间加入优化后的 Inception 模块，此模块通过多尺度卷积核并行处理输入数据，可以捕捉多种尺度的特征信息，这对于轮胎缺陷检测尤为有利。用 ResNet18 判别器替代原有的单一判别器，使整体训练过程更稳定。

1.5 损失函数

生成器的损失函数包括 3 个，分别为：

1) 对抗损失

对抗损失是一种在生成器和判别器之间引入的损失函数，用于促使生成器生成更真实、更逼真的数据。通过让生成器和判别器在训练中相互竞争，逐步提高生成样本的质量，具体如式(10)所示。

$$L_{adv} = \| D(x) - D(G(x)) \|_2 \tag{10}$$

其中， $D(x)$ 为判别器对真实数据的输出， $D(G(x))$ 为判别器对生成数据样本的输出， $\| \cdot \|_2$ 表示 L_2 范数。

2) 重构损失

重构损失是衡量模型输出与目标数据之间差异的指标，它促使模型生成的结果尽可能接近真实输入或目标数据，重构损失函数如式(11)所示。

$$L_{con} = E_{x \sim p_x} \| x - G(x) \|_1 \tag{11}$$

其中， x 表示原始输入， $G(x)$ 表示重建输出， $\| \cdot \|_1$ 表示 L_1 范数。

3) 编码损失

编码损失主要用来保证编码的效果，使得编码后的表

示能够较好地还原原始数据。编码损失函数如式(12)所示。

$$L_{enc} = E_{x \sim p_x} \| Z - Z_1 \|_2 \tag{12}$$

其中， Z, Z_1 分别为生成器中第 1 个编码器和第 2 个编码器的输出。

SPGAN 生成器总的损失函数如式(13)所示。

$$L_G = \omega_1 L_{adv} + \omega_2 L_{con} + \omega_3 L_{enc} \tag{13}$$

其中， $\omega_{con}, \omega_{adv}, \omega_{enc}$ 是 3 个损失函数对应的权重参数。判别器的损失函数如式(14)所示。

$$L_D = E_{x \sim p_x} [\log D(x_i)] + E_{z \sim p_z} [\log(1 - D(G(z)))] \tag{14}$$

其中， D 为判别器、 E 为编码器、 G 为生成器、 Z 为潜在空间向量、 x 为真实数据样本。

综上所述，GANomaly 的生成器损失函数由对抗、重构、编码损失等组成，能够有效促进生成器和判别器之前的对抗，对于保证生成样本的质量和多样性至关重要。

2 实 验

2.1 实验数据集

1) 训练数据集

选取自制数据集中 3 000 张轮胎无缺陷图像进行预处理，对每个图片进行随机裁剪为 4 张 128×128 大小的子图，共 12 000 张，然后用裁剪后的轮胎 X 光无缺陷图像子图进行模型的训练，如图 6 所示。

2) 测试数据集

测试数据集由无缺陷图像和缺陷图像组成。其中无缺陷图像有 1 900 张，缺陷图像有 1 900 张，如表 1 和图 7 所示。轮胎缺陷数据集中共有杂质、气泡、帘线弯曲、侧壁裂缝 4 种缺陷类型，数量分别为 510、500、440、450，数量相近，避免了出现因为数据集种类不平和导致可能出现的过拟合风险。




图6 训练数据集
Fig. 6 Training dataset

表1 测试图像类型及数量

Table 1 Testing image types and quantities

图像大类	图像类型	图像数量
缺陷图像	杂质	510
	气泡	500
	帘线弯曲	440
	侧壁裂缝	450
无缺陷图像		1 900




图7 测试数据集
Fig. 7 Test dataset

2.2 实验平台配置

实验平台采用 linux 操作系统,处理器型号为 Intel (R) Xeon (R) Platinum 8352V,显卡型号为 NVIDIA GeForce RTX 4090 GPU、计算机内存为 30 G。采用 Python3.9、Pytorch1.12.1 深度学习框架编程环境为 Ubuntu22.04 操作系统。

2.3 实验相关参数

SPGAN 模型的具体参数如表 2 所示。

2.4 实验评估指标

为了评估模型对轮胎 X 光缺陷图像的检测性能,本实

表2 参数设置

Table 2 Parameter settings

参数类型	参数设置
Image size	128×128
优化器	Adam
Learning rate	0.000 3
b1	0.5
b2	0.999
epoch	50
batchsize	32

验使用了 4 种常用于缺陷检测的指标来评估模型对缺陷检测的精确度,分别是受试者工作特征曲线(receiver operating characteristic curve, ROC)、 F_1 分数(F_1)、Acc (accuracy)和阈值(threshold)。

F_1 分数、Acc 具体计算表达式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (16)$$

其中, $Precision$ 为准确率, $Recall$ 为召回率,召回率主要关注的是模型正确识别出正确样本的能力,即真正例占所有实际正例的比例,精确率则是指模型预测为正例中真正是正例的比例。 TP 表示正确识别为阳性的样本数, FN 为漏检的阳性样本数, FP 为误判为阳性的样本数, TN 则是正确识别为阴性的样本数。

AUC-ROC 是分类模型的性能指标,用于衡量模型在各种阈值下的分类准确性。ROC 曲线是用假阳性率(FPR)绘制的曲线 x 轴和 y 轴上的真阳性率(TPR)。 FPR 表示在所有阴性样本中被错误预测为阳性的阴性样本的比例,而 TPR 表示在所有阳性样本中被正确预测为阳性的阳性样本的比例。通过在模型输出的异常分数上设置不同的阈值,可以计算相应的 FPR 和 TPR 值,生成一组形成 ROC 曲线的数据点。这条曲线下面积表示 AUC-ROC 度量。

$$\begin{cases} TPR = \frac{TP}{TP + FN} \\ FPR = \frac{FP}{FP + TN} \end{cases} \quad (17)$$

阈值在机器学习和数据分析中,它通常指的是用于将连续型预测结果转换为离散决策或分类的一个临界值。在二元分类问题中,模型输出一个介于 0~1 的概率值,表示某个样本属于正类的概率。阈值决定了这个概率值如何被解释成实际的类别标签。

2.5 对比实验

1) 不同模型对比

将 GANomaly、SPGAN 和其他常见 GAN 模型进行了对比试验,ROC 对比图和 PRC 对比图如图 8 和 9 所示,具体实验数据如表 3 所示。

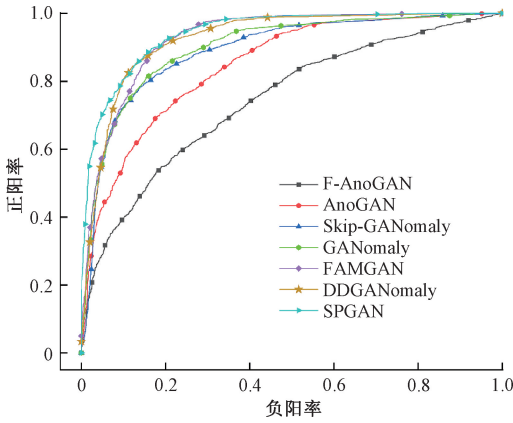


图 8 ROC 对比

Fig. 8 ROC comparison

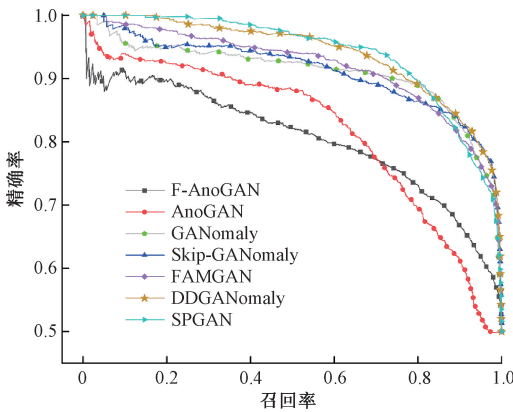


图 9 PRC 对比

Fig. 9 PRC comparison

表 3 不同模型实验结果对比

Table 3 Comparison of experimental results of different models

模型	AUC	AP
GANomaly	0.858	0.796
AnoGAN	0.813	0.750
F-AnoGAN	0.725	0.701
Skip-GANomaly	0.833	0.821
DDGANomaly	0.920	0.876
FAMGAN	0.893	0.833
SPGAN	0.948	0.885

SPGAN 在轮胎缺陷检测中表现显著优于 GANomaly、AnoGAN、DDGANomaly、FAMGAN 模型。其 AUC 达 0.948, 分别高出 GANomaly(0.858)、AnoGAN(0.813)、F-AnoGAN(0.725)、Skip-GANomaly(0.833)、FAMGAN(0.893) 和 DDGANomaly(0.920), 展现出更强的判别能力; AP 为 0.885, 同样领先所有模型, 表明其在精确率与召回率之间实现了更优平衡, 尤其在类别不平衡场景下仍保持高检测精度。

从 ROC 曲线可知, SPGAN 的曲线最接近左上角, 说明其在不同阈值下均能维持较高的真阳性率和较低的假阳性率, 具备优异的异常识别能力。相比之下, F-AnoGAN 和 AnoGAN 曲线明显靠下, 反映其区分能力较弱。DDGANomaly 和 FAMGAN 虽有改进, 但整体性能仍逊于 SPGAN。PRC 曲线进一步验证了这一优势: SPGAN 在高召回率区间仍保持较高精确率, 曲线始终位于其他模型之上, 尤其在低召回阶段表现突出, 说明其在稀有缺陷检测中具有更强的鲁棒性。而 F-AnoGAN 和 AnoGAN 在召回率上升时精确率迅速下降, 反映出误报问题严重。

DDGANomaly 和 FAMGAN 基于 GANomaly 框架引入双判别器或特征对齐机制以提升性能, 但其改进仍受限原始结构的表达能力。而 SPGAN 通过更合理的网络设计, 在生成质量与特征学习方面实现全面优化。损失分析显示, SPGAN 的重建损失持续稳定下降, 编码损失也显著低于 GANomaly, 说明其训练过程更稳定, 生成图像质量更高, 特征表示更具判别性。综上, SPGAN 不仅在量化指标上全面领先, 且在实际应用中具备更高的稳定性与可靠性。重建损失对比图和编码损失对比图如图 10、11 所示。

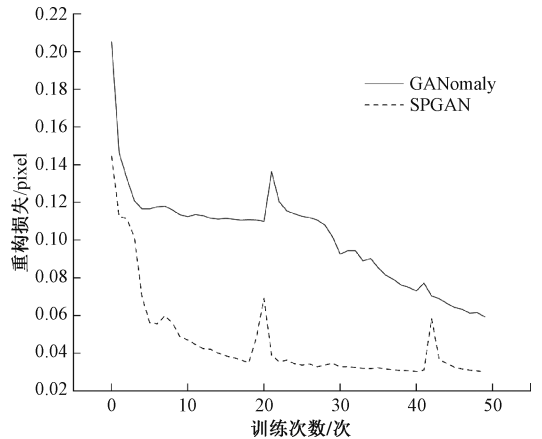


图 10 重建损失对比

Fig. 10 Reconstruction loss comparison chart




图 11 编码损失对比

Fig. 11 Encoding loss comparison chart

此外,还将 SPGAN 输入图片与重建图片做了对比如图 12 所示。从对比图中可以看出无缺陷图像背景纹理基本

保持一致,重建效果较好。气泡、杂质、侧壁裂缝、帘线弯曲这些缺陷区域在重建图像中仍能识别,但细节略有模糊。

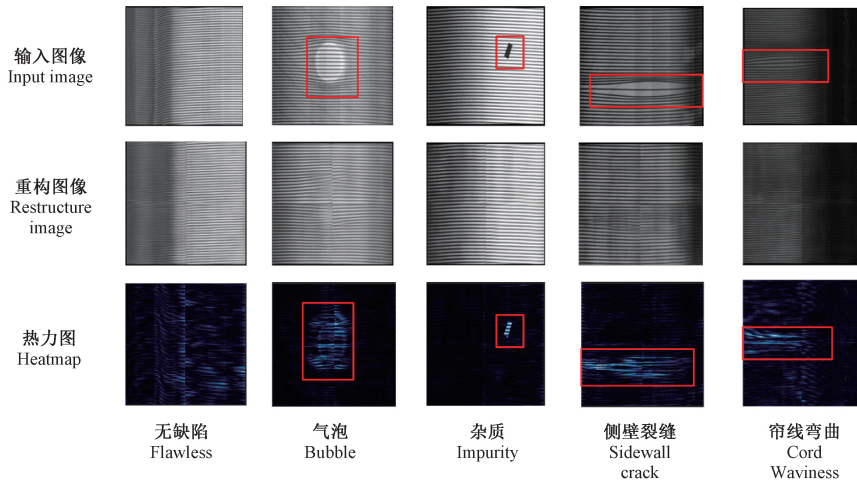


图 12 原图与重建图像对比

Fig. 12 Comparison between the original image and the reconstructed image

总体而言,模型能够较好地保留背景纹理,但在处理具体缺陷时存在一定的误差,需要进一步优化以提高缺陷区域的重建准确性。

2) 不同判别器对比

本研究对比了多种判别器结构在异常检测模型中的性能表现。实验结果表明,采用 ResNet 作为判别器时性能最优,AUC 达到 0.907,AP 为 0.869,显著优于原模型及其他变体。PatchGAN 表现次之,AUC 为 0.876,AP 为 0.852,显示出其在局部特征判别上的有效性。VGG19 与原模型性能相近,但均弱于 ResNet 与 PatchGAN。结果表明,深层残差网络结构更有利于捕捉图像中的细微异常。

此外,还对比了 ResNet18、ResNet34、ResNet50 和 ResNet101 这 4 种变体。如表 4 所示,尽管均基于残差结构,不同深度的 ResNet 对异常检测性能影响显著。其中,ResNet18 取得了最佳性能,明显优于更深的 ResNet34、ResNet50 和 ResNet101。这表明,网络并非越深越好,过深的结构可能导致过拟合或优化困难,反而降低判别能力。相比之下,ResNet18 在特征表达能力与模型复杂度之间达到了更优平衡,显著提升了检测的准确性与鲁棒性。

表 4 不同判别器实验结果对比

Table 4 Comparison of experimental results of different discriminator

模型	AUC	AP
PatchGAN	0.876	0.852
VGG19	0.856	0.801
ResNet18	0.907	0.869
ResNet34	0.824	0.773
ResNet50	0.867	0.741
ResNet101	0.728	0.705

2.6 消融实验

为了验证引入的 SPAM 注意力机制、Inception 模块和 ResNet 判别器的效果,进行了较为全面的消融实验。所有实验均采用与主实验相同的参数设置,包括数据集、训练方式和超参数,以保证条件一致,结果具有可比性。

综合来看,表 5 的结果清晰地展示了每个改进组件对模型性能的具体贡献。实验结果显示,这 3 个改进组件在分别作用于网络时 AUC 值都有提升,3 个改进共同作用可

表 5 AUC 值消融实验结果

Table 5 AUC ablation results

模型结构	气泡	杂质	帘线弯曲	侧壁裂缝	混合缺陷
GANomaly	0.826	0.849	0.893	0.912	0.858
GANomaly+SPAM	0.833	0.852	0.945	0.961	0.919
GANomaly+Inception	0.857	0.883	0.942	0.936	0.893
GANomaly+ResNet18	0.812	0.833	0.901	0.921	0.907
GANomaly+SPAM+Inception	0.858	0.897	0.927	0.953	0.925
GANomaly+SPAM+ResNet18	0.876	0.911	0.968	0.962	0.933
GANomaly+Inception+ResNet18	0.871	0.875	0.929	0.945	0.920
GANomaly+SPAM+Inception+ResNet18	0.901	0.920	0.992	0.988	0.948
平均	0.858	0.881	0.943	0.952	0.920

以显著提升轮胎缺陷检测的准确率。对于气泡缺陷和杂质缺陷的检测准确率较低,还有待提高。

3 结 论

SPGAN 是基于 GANomaly 的改进模型,其创新不仅提升了模型的鲁棒性和泛化能力,还显著增强了轮胎 X 光图像缺陷检测的精度。通过在编码器和解码器中加入 SPAM 注意力模块,SPGAN 提高了对图像特征的提取能力,特别是对细节特征的关注。此外,优化的 Inception 模块通过多尺度卷积核并行处理,捕捉各类尺度特征,对于轮胎缺陷检测尤为有效。使用 ResNet18 判别器替代单一判别器也使训练过程更为稳定。基于自制的轮胎缺陷数据集对 SPGAN 进行了训练和测试,实验结果表明其在检测轮胎缺陷图像上表现优异。尽管如此,重建图像的效果仍需加强,特别是在识别气泡和杂质缺陷方面。

参考文献

- [1] 孙贺,刘胜波,冷于浩,等. 基于机器视觉的轮胎表面缺陷检测系统的研究与应用[J]. 工业控制计算机, 2022, 35(1): 29-30,34.
SUN H, LIU SH B, LENG Y H, et al. Research and application of tire surface defect detection system based on machine vision [J]. Industrial Control Computer, 2022, 35(1): 29-30,34.
- [2] 刘金海,赵真,付明芮,等. 基于主动小样本学习的管道焊缝缺陷检测方法[J]. 仪器仪表学报, 2022, 43(11): 252-261.
LIU J H, ZHAO ZH, FU M R, et al. A defect detection method for pipeline welds based on active small sample learning[J]. Chinese Journal of Scientific and Instrument, 2023, 37(12): 58-66.
- [3] 罗仁泽,唐祥,余泓,等. 基于改进 Faster RCNN 的射线图像焊缝缺陷检测方法[J]. 电子测量技术, 2023, 46(22): 160-168.
LUO R Z, TANG X, YU H, et al. A method for detecting weld defects in ray images based on improved faster rcnn[J]. Electronic Measurement Technology, 2023, 46(22): 160-168.
- [4] 李大华,徐傲,王笋,等. 基于改进 YOLOv5 的印刷电路板缺陷检测[J]. 电子测量技术, 2023, 46(23): 112-119.
LI D H, XU AO, WANG S, et al. Defect detection of printed circuit boards based on improved YOLOv5[J]. Electronic Measurement Technology, 2023, 46(23): 112-119.
- [5] 陈利琼,梅后金,胡洪宣,等. 基于改进 Faster R-CNN 的焊缝缺陷检测方法[J]. 科学技术与工程, 2025, 25(5): 2027-2033.
CHEN L Q, MEI H J, HU H X, et al. Weld defect detection based on improved Faster R-CNN method[J]. Science Technology and Engineering, 2025, 25(5): 2027-2033.
- [6] 陈帅,李焕锋,沙杰,等. 基于 YOLOv5 的砂纸表面缺陷检测方法研究[J]. 电子测量技术, 2023, 46(14): 73-79.
CHEN SH, LI H F, SHA J, et al. Research on sandpaper surface defect detection method based on yolov5 [J]. Electronic Measurement Technology, 2023, 46(14): 73-79.
- [7] 凌鸿伟,张建敏. 基于改进生成对抗网络的晶圆表面缺陷检测[J]. 现代信息科技, 2024, 8(20): 37-42, 47.
LING H W, ZHANG J M. Wafer surface defect detection based on improved generative adversarial network[J]. Modern Information Technology, 2024, 8(20): 37-42, 47.
- [8] 刘慧,卢云志,张雷. 基于 Dropout 改进的 SRGAN 网络 DrSRGAN[J]. 科学技术与工程, 2023, 23(23): 10015-10022.
LIU H, LU Y ZH, ZHANG L. Improved SRGAN network based on Dropout called DrSRGAN [J]. Science Technology and Engineering, 2023, 23(23): 10015-10022.
- [9] 宋航,周凤,熊伟. 基于自相关-变分对抗学习的物理系统异常检测[J]. 计算机工程, 2024, 50(12): 358-366.
SONG H, ZHOU F, XIONG W. Anomaly detection of physical systems based on autocorrelation-variational adversarial learning [J]. Computer Engineering, 2024, 50(12): 358-366.
- [10] WANG Z Q, DU H C, PENG Z. A method for detecting surface defects of printing rollers by improving the GANomaly model[J]. Information and Computer, 2022, 34(23): 190-193, 256.
- [11] SHUAN G, YUN D, YONG CH X, et al. Generative adversarial network-assisted image classification for imbalanced tire X-ray defect detection[J]. Transactions of the Institute of Measurement and Control, 2023, 45(8): 1492-1504.
- [12] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27(2): 2672-2680.
- [13] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. ArXiv preprint arXiv:1511.06434, 2015.
- [14] SCHLEGL T, SEEBOCK 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, 2017.
- [15] SCHLEGL T, SEEBOCK 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] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Ganomaly: Semi-supervised anomaly detection via adversarial training[C]. Asian Conference on Computer Vision, 2018.
- [17] AKCAY S, ATAPOUR-ABARGHOUEI A, BRECKON T P. Skip-GANomaly: Skip connected and adversarially trained encoder decoder anomaly detection[C]. International Joint Conference on Neural Networks, 2019: 1-8.
- [18] 刘韵婷, 谭明晓, 高宇, 等. 基于双判别器的 GANomaly 异常检测方法研究[J]. 电子科技大学学报, 2024, 53(4): 568-575.
- LIU Y T, TAN M X, GAO Y, et al. Research on GANomaly anomaly detection method based on dual discriminator[J]. Journal of University of Electronic Science and Technology of China, 2024, 53(4): 568-575.
- [19] 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. Defect detection of tire X-ray images based on FAMGAN [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 58-66.
- [20] 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.
- [21] 翟永杰, 刘璇, 王新颖, 等. 基于全局与局部注意力的车辆方位场景识别[J]. 电子测量技术, 2024, 47(14): 96-107.
- ZHAI Y J, LIU X, WANG X Y, et al. Vehicle orientation scene recognition based on global and local attention [J]. Electronic Measurement Technology, 2024, 47(14): 96-107.

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

李思维, 硕士研究生, 主要研究方向为异常检测。

E-mail: 18512448215@163.com

冯欣悦, 硕士研究生, 主要研究方向为异常检测。

E-mail: 1482323625@qq.com

张智星, 硕士研究生, 主要研究方向为异常检测。

E-mail: 1736241818@qq.com