

基于 PySobel-FR 的红外绝缘子异常检测

李 鸿^{1,2}, 郑皓亮³, 丁 龙³, 贾智伟², 李 灵²

(1. 怀化学院 物电与智能制造学院, 湖南 怀化 418008; 2. 长沙理工大学 电气与信息工程学院, 湖南 长沙 410014;
3. 通达电磁能股份有限公司, 湖南 长沙 410217)

摘要: 针对输电线路绝缘子红外图像依赖人工识别、且异常样本数据难以充分构建的问题, 本文提出了一种融合 PySobel 图像增强算法与特征重建机制的无监督异常检测框架(PySobel-FR)。所设计的 PySobel 算法结合高斯滤波、下采样、上采样及 Sobel 算子操作, 在提升边缘结构感知能力的同时, 有效抑制图像中的噪声干扰。整体检测框架采用双路径图像重建结构, 其中教师模型的重建结果不直接用于异常判定, 仅作为知识迁移的中介。在编码阶段, 引入可变形下采样模块, 以增强对绝缘子复杂边缘轮廓的特征提取能力; 在学生模型的解码过程中, 引入高效上卷积模块以替代传统卷积注意力机制与上采样层, 结合残差连接策略, 实现了特征聚焦与细节还原能力的提升。实验结果验证了所提三项改进策略在自建绝缘子红外图像数据集上的有效性, 最终模型在异常检测任务中达到了 90.43% 的识别精度。

关键词: 绝缘子; 图像增强; 异常检测; 无监督; 红外图像

中图分类号: TP391; TN219 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2026.02.022

Infrared insulator anomaly detection via the PySobel-FR framework

LI Hong^{1,2}, ZHENG Hao-liang³, DING Long³, JIA Zhi-wei², LI Ling²

(1. Electronics and Intelligent Manufacturing, School of Physics, Huaihua University, Huaihua 418008, China;
2. School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha 410014, China;
3. Tongda Electromagnetic Energy Co., LTD, Changsha 410217, China)

Abstract: In response to the reliance on manual inspection in infrared imagery of transmission line insulators and the scarcity of sufficient anomalous data samples, an unsupervised anomaly detection framework (PySobel-FR) integrating the PySobel image enhancement algorithm and feature reconstruction mechanism is proposed. The PySobel algorithm combines Gaussian filtering, downsampling, upsampling, and Sobel operations to enhance edge perception while suppressing noise. The framework adopts a dual-path reconstruction structure, where the teacher model serves solely as a knowledge transfer guide without directly participating in anomaly judgment. In the encoder, a deformable downsampling module is introduced to better capture complex edge features of insulators. During the decoding process of the student model, an efficient up-convolution module replaces traditional convolutional attention and upsampling layers, leveraging residual connections to improve feature focus and detail recovery. Experiments on a self-constructed infrared insulator dataset demonstrate the effectiveness of the proposed improvements, achieving an anomaly detection accuracy of 90.43%.

Keywords: insulator; image enhancement; anomaly detection; unsupervised; infrared image

基金项目: 湖南省教育厅重点项目 (No. 23A0255); 国家自然科学基金青年基金项目 (No. 62103063) 资助。

作者简介: 李 鸿 (1962 -), 男, 硕士, 教授, 长期从事测试技术研究, 主要方向为测控技术。E-mail: hongli@csust.edu.cn

通讯作者: 贾智伟 (1981 -), 男, 博士, 副教授, 长期从事电气和电子信息工程、计算机视觉方向研究, 主要方向为电力机器人。E-mail: zh113187212432@outlook.com

收稿日期: 2025-04-18; **修订日期:** 2025-06-06

1 引言

输电线路绝缘子承担电气绝缘、机械支撑及系统稳定运行等关键功能,常处于恶劣环境中,易受气候与外界因素影响,出现腐蚀、污秽及破裂等故障^[1]。因此,开展定期巡检具有重要现实意义。在现有研究中,亢洁等通过结合依赖图与 YOLOv7,实现了绝缘子的轻量、高精度检测^[2];宋岸峰等构建了基于 YOLO 的高压绝缘子缺陷检测方案^[3]。然而,有监督方法高度依赖标注样本,当检测环境或对象变化时,性能下降显著。

相比之下,无监督方法仅通过正常样本训练模型。杨珂浩等提出结合 YOLOv5 与知识蒸馏的无监督检测框架,适用于高铁接触网巡检^[4];李梅玉等设计源域与目标域双分类器结构,并引入对抗一致性约束,实现不同类型绝缘子的无监督检测^[5]。然而,前期提出的 FRAD 方法在无监督架构下虽然实现了绝缘子红外图像的异常点识别,但其在图像预处理阶段缺乏结构性增强机制,对于复杂背景下异常高温点的边缘表达不够清晰,重构过程对目标特征的聚焦能力不足。基于此,本文进行改进与拓展,具体贡献如下:

(1) 提出用于绝缘子红外图像处理的金字塔结构 Sobel 增强算法(PySobel),通过灰度输出强化目标边缘轮廓,提升模型对关键区域的关注度,从而提高无监督异常检测的准确性。

(2) 改进编码器结构,采用可变形下采样模块代替传统方式,引入位置偏移与可学习掩码,实现对复杂边缘的自适应建模,增强特征提取的精度与鲁棒性。

(3) 在学生模型解码阶段,引入高效上卷积模块,替代原有上采样与卷积注意力机制,强化特征聚焦与区域还原能力,同时简化解码路径,提升结构稳定性与性能。

(4) 构建了 PySobel-FR 无监督异常检测框架,增加了新的对比模型和评判标准,使验证过程更加充分。

2 相关工作

2.1 图像增强

红外图像由无人机悬停拍摄,易受干扰产生噪声。鉴于已有研究引入域变换模块与部分图像增强方法,本文仅呈现对比结果,并引入多种图像增强技

术提升图像质量,包括:高斯滤波通过加权平均实现像素平滑^[6];CLAHE 及 CLAHE-DP 算法分别基于局部直方图拉伸和引入上下阈值抑制噪声、保留细节^[7-8];Scene 算法基于场景感知优化图像特征^[9]。在边缘检测方面,Canny、LoG、Schar 与 Sobel 算法分别结合高斯滤波、拉普拉斯算子、梯度优化与方向梯度提取边缘信息^[10-13]。此外,高斯金字塔通过多尺度图像表示增强特征提取^[14],域变换模块结合伽马增强与中值滤波突出绝缘子轮廓与温度异常^[1]。考虑到正常样本不含高温异常点,且轮廓信息在检测中更具判别性,本文采用图像分割方式进一步增强数据集。

2.2 无监督异常检测

在图像编解码范式下,自编码器(AE)^[15]与 VAE-grad^[16]通过最小化重建误差实现异常判别;基于图像生成的方法如 GAN^[17]、f-AnoGAN^[18]与 G-anomaly^[19],则通过学习正常样本的潜在空间以区分异常。近年来,基于知识蒸馏的无监督检测方法(如 FRAD^[1]、KDAD^[20]、SQUID^[21]与 SimSID^[22])通过双路径解码结构增强图像重建能力,进一步提升异常检测性能。相较于传统编解码或生成模型,知识蒸馏范式在精度与鲁棒性方面表现更优。

3 智能算法框架

本文在前述无监督异常检测框架基础上进行了结构优化与策略改进。如图 1 所示,首先,调整图像增强算法以突出绝缘子正常样本的轮廓特征;其次,在编码阶段引入可变形卷积模块,增强对不规则边缘的特征提取能力;最后,在解码阶段采用高效上卷积模块,替代部分双线性插值与卷积注意力层,以提升特征还原效果与结构简洁性。

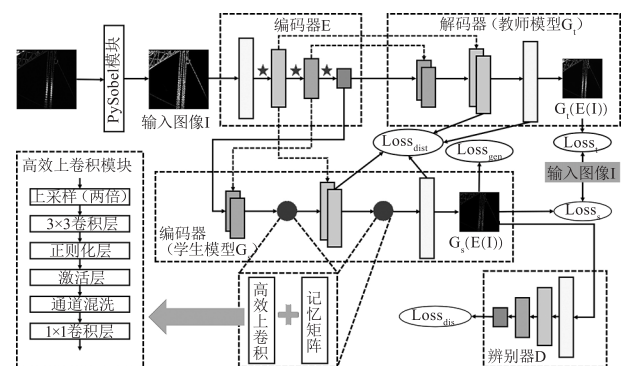


图 1 PySobel-FR 算法框架

Fig. 1 PySobel-FR algorithm framework

3.1 PySobel 算法

受高斯金字塔结构启发^[14],本文构建上下采样流程以提取关键图像特征,处理过程在灰度域内完成。

如图 2 所示,首先利用 CV2 库中核大小为 5×5 、SigmaX 为 1.4 的高斯滤波器进行初步降噪与图像平滑;随后,通过丢弃偶数行列实现下采样,在对应像素右侧与下方插入零值进行上采样。中间特征层再次引入高斯滤波,以抑制采样噪声并强化绝缘子轮廓特征,增强模型对正常样本的学习效果。最终,将该特征图与原始图进行加权融合,并引入 Sobel 算子提取边缘,生成具备显著结构特征且背景干扰较低的智能模型输入图像。

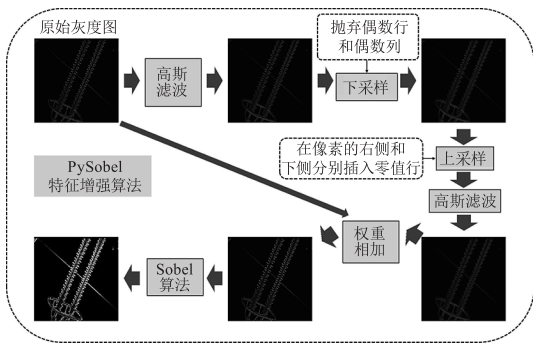


图 2 PySobel 算法处理流程

Fig. 2 PySobel algorithm process flow

3.2 无监督异常检测模型

本方法延续自编码器与知识蒸馏范式,构建无监督异常检测框架,未优化部分采用卷积、正则化、池化与激活函数的常规堆叠结构。如图 1 所示,在不涉及损失函数优化的前提下,整体架构划分为编码器、解码器(含教师模型与学生模型)及判别器三部分。各模块的具体网络结构详见图 3。




图 3 无监督异常检测模型网络特征层

Fig. 3 The network feature layer of the unsupervised anomaly detection model

3.2.1 可变形下采样模块

在进入编码器之前,图像会被切割为 $N \times N$ 个不重叠的特征小块。编码器为逐步下采样结构,其中的下采样操作由可变形下采样模块执行。可变形卷积(DCNv2)^[23]区别于传统卷积感受野过于规则的现状,通过增加偏移量和可学习权重来优化特征提取过程。如图 4 所示,可变形卷积的感受野更加随机,可以很好地捕捉特殊形状的特征,这与绝缘子不规则的边缘特征表示具有一致性,其公式为:

$$y(p_o) = \sum_{p_n \in R} w(p_n) \cdot x(p_o + p_n + \Delta p_n) \cdot \Delta m_n \quad (1)$$

式中, $x(n)$ 和 $y(n)$ 为输入与输出特征图, p_o 是滑动窗的中心点, p_n 是卷积核的采样点。在基础二维矩阵卷积计算的基础上,增加了偏移量 Δp_n (offset),使得模型能够根据输入计算偏移量,自适应地选择对哪些位置进行卷积计算^[24];增加了新的可学习权重 Δm (mask),使得偏移量的产生更为合理^[24]。

如图 4 所示,首先采用步长为 2 的可变形卷积进行下采样,提取特征并缩小图像尺寸,结果作为残差分支。随后在该分支上依次引入步长为 1 的可变形卷积与 3×3 常规卷积,并对输出进行正则化。最终,将正则化结果与残差相加,并经 ReLU 函数激活,以实现特征增强。该结构替代传统池化操作,提升模型对正常样本特征的适应性与表达能力。

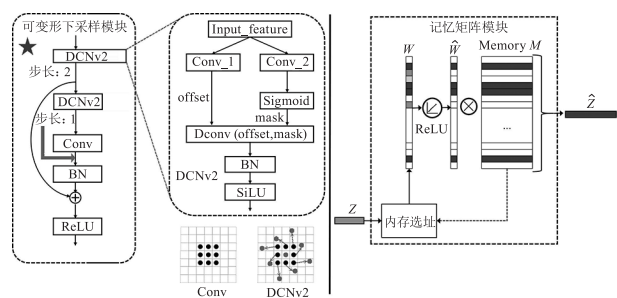


图 4 可变形下采样模块和记忆矩阵模块

Fig. 4 Deformable downsampling module and memory matrix module

3.2.2 高效上卷积记忆矩阵模块

编码后的特征被送入解码器进行重构。与原框架一致,图像特征在教师模型与学生模型两条路径上分别解码。教师模型不参与异常判别,仅通过损失函数引导学生模型学习重建能力,其结构较为简洁,由卷积上采样模块构成,采用双线性插值实现上

采样。学生模型在此基础上进行优化,引入高效上卷积模块^[25]以替代部分上采样与特征聚焦操作。如图 1 所示,该模块先进行倍率为 2 的上采样,再通过 3×3 卷积增强局部特征提取;为提升跨通道信息交互能力,引入通道混洗机制,最终通过 1×1 卷积调整通道数以适配后续结构。

如图 4 所示,记忆矩阵模块^[26]通过联合输入特征向量 Z 与记忆队列 M ,实现动态记忆寻址。该模块首先基于 Z 生成软寻址向量 W ,并经 ReLU 激活以增强非线性表达能力。随后将归一化的 \hat{W} 与记忆矩阵相乘,得到目标特征表示 \hat{Z} 。其中,记忆矩阵为尺寸为 $N \times C$ 的结构,维度 C 与编码特征向量 \hat{Z} 一致,每个记忆单元 m_i 表示一条长期上下文信息。最终输出 \hat{Z} 为各记忆单元加权求和的结果,权重由 W 确定,且各分量非负,其计算方式:

$$\hat{z} = \hat{w}M = \sum_{i=1}^N \hat{w}_i m_i \quad (2)$$

式中的 N 为超参数,它等于图像尺寸除以切片尺寸。

寻址策略基于注意力机制,计算 Z 与 M 模块汇总每一项 m_i 的相似度,从而构造注意力权重 W ,计算公式为:

$$w_i = \exp(d(z, m_i)) / \sum_{j=1}^N \exp(d(z, m_j)) \quad (3)$$

$$d(z, m_i) = zm_i^T / \|z\| \|m_i\| \quad (4)$$

使用 ReLU 函数来优化注意力权重 W ,增加寻址权重的稀疏性,进一步使得异常区域不能被很好地重构,计算公式为:

$$\hat{w}_i = \max(w_i - \lambda, 0) \cdot w_i / (|w_i - \lambda| + \varepsilon) \quad (5)$$

其中, $\max(\cdot)$ 就是 ReLU 函数, ε 为一个很小的正数项,阈值通常设置为 $[1/N, 3/N]$ 之间。

在训练过程中,记忆矩阵模块每次仅选取少量记忆单元参与特征重构,促使各内存单元逐步演化为具有代表性的特征原型,从而提升整体记忆表示的判别能力。进入测试阶段,正常样本能够匹配到特征相近的记忆单元,实现高质量重构;而异常样本由于与记忆原型差异较大,难以匹配合适记忆项,导致重构误差显著上升,为异常检测提供了有效依据。

3.2.3 判别器与损失函数

判别模块和损失函数计算未进一步优化,仍

与前述研究一致^[1]。如图 1 所示,判别模块通过度量输入图像与重构图像在像素层级上的特征差异,估算样本的异常程度。具体而言,设编码器为 E ,生成器采用师生结构,分别为教师模型 G_t 与学生模型 G_s ,判别器为 D ,其异常评分根据以下公式计算:

$$A = \Phi((D(G_s(E(I))) - \mu) / \delta) \quad (6)$$

其中, $\Phi(\cdot)$ 为 Sigmoid 函数, μ 和 δ 分别为单样本异常分数的均值和标准差。

仍考虑五个损失函数联合优化智能模型^[1],损失函数起作用的位置如图 1 所示。总损失函数的公式为:

$$Loss_{total} = \lambda_t Loss_t + \lambda_s Loss_s + \lambda_{dist} Loss_{dist} + \lambda_{gen} Loss_{gen} + \lambda_{dis} Loss_{dis} \quad (7)$$

4 实验与分析

在域变换算法基础上,加入高斯滤波、直方图优化、卷积优化和边缘分割等灰度图像处理方法进行比较,并引入峰值信噪比 (PSNR)、结构相似性指数 (SSIM)、边缘保持度 (EPI) 和处理耗时 (PT) 等指标综合评估图像处理算法^[27],每个指标为测试样本的平均值。

在无监督异常检测方面,结合图像编解码、生成与知识蒸馏范式,选择 FRAD^[1]、SimSID^[22] 等深度学习模型进行比较。本研究采用 AUC-ROC 曲线作为主要评估指标,广泛应用于无监督异常检测的标准性能度量。

4.1 实验设置

在模型训练过程中,采用 Adam 优化器进行参数更新,批量大小 (Batch Size) 设定为 16,权重衰减系数设为 1×10^{-5} 。对于学生模型与判别器模块,其初始学习率设置为 1×10^{-4} 。在自建数据集上,训练迭代 300 轮,并在第 50 轮和第 150 轮分别将学习率降低至原值的 1/5,采用节点式退火策略。为增强实验结果的可比性,本研究沿用了 FRAD^[2] 和 SQUID^[17] 中的超参数配置,其中各项损失函数的权重系数分别设定为: $\lambda_t = 0.01, \lambda_s = 10, \lambda_{dist} = 0.001, \lambda_{gen} = 0.005, \lambda_{dis} = 0.005$ 。

4.2 实验数据

自建绝缘子红外图像数据集:共采集 880 张具备分析价值的红外图像样本,其中正常样本为 675 张,含有异常高温区域的异常样本为 205 张。遵循

无监督学习框架,训练集中仅包含 470 张正常样本,而测试集则由 205 张正常样本与 205 张异常样本共同组成。所有图像均为 RGB 格式,原始分辨率为 512×512 像素。

4.3 实验分析

为验证所提图像算法在绝缘子图像预处理阶段的性能,本文从图像质量和无监督模型适配度两个方面进行了系统对比实验。如图 5 所示,实验使用分辨率为 512×512 的绝缘子红外图像灰度域表示。根据表 1,PySobel、高斯滤波、CLAHE-DP 与高斯金字塔在噪声抑制与图像清晰度提升方面表现最佳,

PSNR 值均超过 28,适合降噪处理。PySobel、CLAHE 和 CLAHE-DP 在结构保持上表现优异,SSIM 均超过 90%,有效增强对比度的同时保留细节。PySobel 在边缘匹配准确率上以 92% 领先,Canny (89%)和 LoG(85%)紧随其后,表明其在边缘提取精度上占优势,适合后续绝缘子形态特征提取。与 FRAD 仅使用 Gamma 和中值差分不同,PySobel 采用高斯金字塔范式和 Sobel 算子增强边缘,明显改善了高温点边界模糊和噪声干扰问题。在结构相同条件下,检测精度由 88.56% 提升至 89.61%,验证了图像增强的有效性。

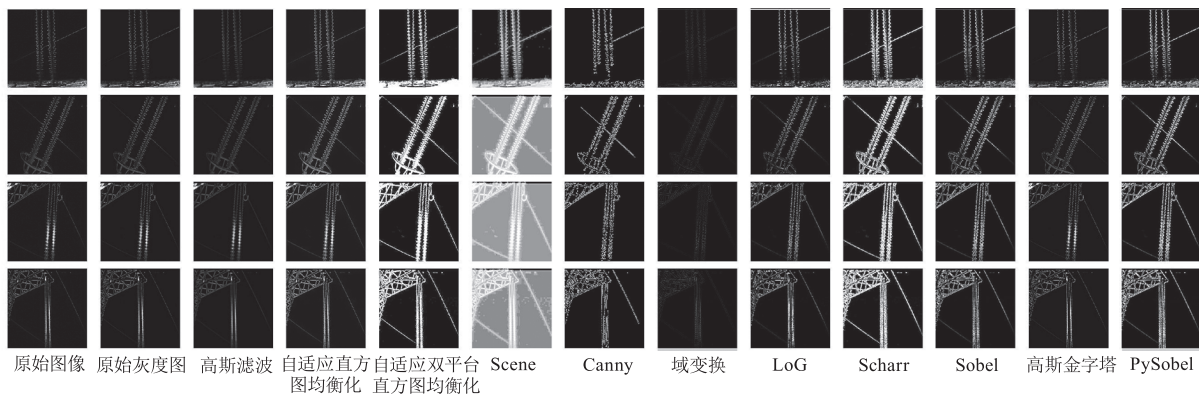


图 5 图像处理算法效果对比图

Fig. 5 Comparison chart of image processing algorithm performance

表 1 图像处理算法综合对比

Tab. 1 Comprehensive comparison of image processing algorithms

算法名称	PSNR ↑	SSIM/% ↑	边缘准确率/% ↑	平均运行时间/ms ↓
高斯滤波	28.64	89	68	12.5
自适应直方图均衡化	27.81	90	72	13.8
自适应直方图双平台均衡化	28.12	91	74	15.3
Scene	26.45	87	76	19.7
Canny	24.96	78	89	21.4
LoG	25.67	81	85	22.6
Scharr	27.12	86	82	16.5
Sobel	26.93	85	80	15.9
高斯金字塔	27.56	88	70	18.1
域变换算法	28.37	87	83	17.2
PySobel(本文)	29.64	93	92	31.3

处理后的图像被输入无监督异常检测模型进行训练。根据表 2 的结果,不同图像预处理方法对模型性能的影响显著。从图像增强角度来看,CLAHE-DP、Scene 和 Scharr 生成的图像在无监督学习中适应性较差,未能有效支持异常特征建模。相比之下,

高斯滤波、Canny、LoG 和 Sobel 方法在图像结构特征表达上具有优势,显著增强了模型对异常区域的感知能力。多算法融合方案中,PySobel 在性能指标上优于高斯金字塔和域变换方法,展现了更强的特征表达能力和适配性,尤其在无监督检测任务中显著提升了检测性能。

从无监督异常检测模型角度来看,基于知识蒸馏(KD)框架的模型表现出明显优势。与简单自编码器(AE)和基于梯度重建的 VAE-grad 相比,前者在建模绝缘子正常特征方面存在局限,难以有效捕捉关键特征,影响检测精度。虽然生成对抗网络(如 GAN、f-AnoGAN、Ganomaly)有所改进,但整体性能未达理想水平。引入知识蒸馏后,模型在处理正常与异常样本时的响应差异被放大,增强了异常模式的识别能力。在不同数据增强策略下,FRAD、KDAD、SQUID 和 SimSID 方法表现出各自的适应性。本文在 FRAD 框架基础上引入多策略融合机制,显著提高了模型在绝缘子红外图像数据集上的泛化能力。实验结果表明,除 Canny 和 LoG 处理的

图像外,所提算法在其他预处理策略下均表现出领先的检测性能,特别是与 PySobel 联合训练的无监

督模型 (PySobel-FR) 在异常检测任务中取得了 90.43 % 的准确率,验证了其优越性与实用价值。

表 2 图像预处理算法对无监督异常检测模型的作用,评价指标 AUCROC (%)

Tab. 2 The role of image preprocessing algorithms in unsupervised anomaly detection models, evaluation metric, AUCROC (%)

图像处理算法	智能模型									
	AE	VAE-grad	GAN	f-AnoGAN	Ganomaly	FRAD	KDAD	SQUID	SimSID	本文算法
高斯滤波	44.27	45.70	50.18	58.28	59.91	86.57	86.31	84.90	86.19	87.25
自适应直方图均衡化	47.82	46.33	51.85	59.87	62.36	86.98	86.77	84.82	86.34	87.41
自适应双平台均衡化	40.98	42.58	49.36	53.99	57.37	83.04	81.94	80.14	81.07	83.12
Scene	43.27	46.02	48.91	52.35	57.04	80.76	74.29	77.93	79.38	83.88
Canny	48.42	48.99	52.79	60.82	65.83	87.62	85.52	85.13	87.94	87.67
LoG	47.99	48.31	54.11	61.37	66.79	86.83	86.73	85.01	87.42	87.40
Scharr	44.83	42.18	50.67	56.39	60.01	82.38	78.29	79.80	80.60	84.36
Sobel	46.41	47.83	54.93	65.52	65.92	86.95	86.87	85.38	87.72	87.90
高斯金字塔	46.79	49.26	52.38	63.19	61.47	87.74	85.31	85.79	87.29	88.15
域变换算法	51.83	50.47	56.32	58.30	58.09	88.56	87.08	86.55	87.44	88.92
PySobel(本文)	54.93	53.76	60.28	63.44	63.90	89.61	87.89	87.35	88.03	90.43

表 3 优化策略对模型性能的影响,评价指标 AUCROC (%)

Tab. 3 Impact of optimization strategies on model performance, evaluation metric, AUCROC (%)

优化策略	原始灰度图	域变换	PySobel
FRAD	86.31	88.56	89.61
FRAD + 可变形下采样	86.86	88.90	89.97
FRAD + 高效上卷积	86.90	89.35	90.06
本文算法	87.24	89.61	90.43

在前期 FRAD 研究基础上,本文从图像预处理、编码模块和解码模块三个层面提出优化策略。根据表 2 与表 3 的实验结果,在绝缘子红外图像的无监督异常检测任务中,PySobel 预处理方法在多个性能维度上优于域变换类方法,带来了约 1 % 至 5 % 的性能提升。在编码阶段引入可变形下采样机制,在解码阶段采用高效上卷积模块,这两种优化措施在 FRAD 架构下均显著提升了模型性能。FRAD 在检测准确性上已有基础表现,但对异常区域聚焦不够、受背景干扰较大。本文在结构不变前提下,通过更优的图像处理和重建路径,将精度提升至 90.43 %。尽管提升有限,但在无监督检测中属稳定改进,且在不同增强策略下保持性能一致,具备良好泛化性。如图 6 及式(6)所示,判别器通过评估输入图像与

学生模型重建图像之间的特征差异,生成异常评分以判断样本的正常性。该异常阈值在训练结束后根据模型对特定数据集的适配性进行设定,阈值在不同数据集上可能存在差异。




图 6 智能模型异常辨识示例

Fig. 6 Example of anomaly identification by intelligent model

5 结论

本文以输电线路绝缘子的红外图像为研究对象,在前期工作的基础上,探索更高检测精度的无监督异常检测方法。为提升模型对正常样本结构特征的代表能力,引入 PySobel 图像增强算法强化边缘特征,从而提高学生网络对关键特征的保持能力。在特征编码阶段,设计可变形下采样模块增强边缘细节感知,有效保留空间信息;在解码阶段,采用高效上卷积模块与残差连接,提升重建能力与异常判

别能力。本方法在自制数据集上实现 90.43 % 的检测精度,相较 FRAD 提升约 1.9 %。在无监督异常检测中,该幅度具有代表性。对比 SQUID(87.35 %)、KDAD(87.89 %),本法在检测率、边缘感知与稳定性上均有优势,验证了图像增强与结构优化的协同增益。综上所述,所提出方法在结构设计与预处理策略两方面均有效弥补了 FRAD 架构的不足,为红外图像中异常高温点的无监督检测提供了更具实用性的解决方案。

参考文献:

- [1] Li H,Zheng H L,Liu Z W, et al. Infrared image anomaly detection algorithm of insulator based on FRAD[J]. *Laser & Infrared*,2025,55(2):250-257. (in Chinese)
李鸿,郑皓亮,刘昭卫,等.基于 FRAD 的绝缘子红外图像异常检测算法[J].*激光与红外*,2025,55(2):250-257.
- [2] Kang J,Chang Q,Wang Q, et al. A lightweight algorithm for multi-defect detection in insulators with integrated DepGraph offset regularization [J/OL]. *Computer Engineering and Applications*,2025:1-12(2025-03-27)[2025-04-09]. <https://link.cnki.net/urlid/11.2127.tp.20250326.1741.031>. (in Chinese)
亢洁,常琦,王勃,等.融合 DepGraph 偏移正则化的绝缘子多缺陷检测轻量化算法[J/OL].*计算机工程与应用*,2025:1-12(2025-03-27)[2025-04-09]. <https://link.cnki.net/urlid/11.2127.tp.20250326.1741.031>.
- [3] Song A F,Bai Y,Dai X B, et al. Intelligent detection method of high voltage insulator defect based on infrared technology[J]. *Laser Journal*,2024,45(7):260-264. (in Chinese)
宋岸峰,白杨,代鑫波,等.基于红外技术的高压绝缘子缺陷智能检测方法[J].*激光杂志*,2024,45(7):260-264.
- [4] Yang K H,Yu L,Gao S B, et al. High-speed rail insulator defect detection algorithm based on unsupervised knowledge distillation[J]. *Electric Railway*,2023,34(1):9-14. (in Chinese)
杨珂浩,于龙,高仕斌,等.基于无监督知识蒸馏的高铁绝缘子缺陷检测算法[J].*电气化铁道*,2023,34(1):9-14.
- [5] Li M Y,Li S L,Zhao M, et al. Unsupervised domain adaptation insulator detection based on adversarial consistency constraints [J]. *Journal of Image and Graphics*,2022,27(4):1148-1160. (in Chinese)
李梅玉,李仕林,赵明,等.对抗一致性约束的无监督
- 域自适应绝缘子检测[J].*中国图象图形学报*,2022,27(4):1148-1160.
- [6] Li S B,Ni L. An infrared spot location algorithm under vacuum deep low temperature [J]. *Laser & Infrared*,2024,54(8):1316-1321. (in Chinese)
李善斌,倪磊.一种真空深低温下的红外光斑定位算法[J].*激光与红外*,2024,54(8):1316-1321.
- [7] Liu Y T,Chen Z,Fu Z F, et al. Infrared image enhancement algorithm based on CLAHE[J]. *Laser & Infrared*,2016,46(10):1290-1294. (in Chinese)
刘玉婷,陈峥,付占方,等.基于 CLAHE 的红外图像增强算法[J].*激光与红外*,2016,46(10):1290-1294.
- [8] Zhu J H,Li K,Shao X J, et al. High dynamic range infrared image display method based on adaptive platform histogram[J]. *Laser & Infrared*,2024,54(7):1086-1089. (in Chinese)
朱金华,李科,邵先军,等.自适应平台直方图高动态范围红外图像显示方法[J].*激光与红外*,2024,54(7):1086-1089.
- [9] Zhang S,Yuan Q Q,Li J, et al. Scene-adaptive remote sensing image super-resolution using a multiscale attention network[J]. *IEEE Transactions on Geoscience and Remote Sensing*,2020,58(7):4764-4779.
- [10] Han L,Zhao Y T,Zuo C, et al. Infrared image enhancement algorithm based on improved Laplacian pyramid [J]. *Laser & Infrared*,2024,54(10):1626-1632. (in Chinese)
韩龙,赵雅婷,左超,等.基于改进拉普拉斯金字塔的红外图像增强算法[J].*激光与红外*,2024,54(10):1626-1632.
- [11] Fan X D,Wan W L,Zheng Y. An improved gaussian laplace pyramid transformer infrared image enhancement algorithm [J]. *Electric Power Environmental Protection*,2024,40(2):198-206. (in Chinese)
范晓狄,万文略,郑银.一种改进的高斯-拉普拉斯金字塔互感器红外图像增强算法[J].*电力科技与环保*,2024,40(2):198-206.
- [12] Jiang C,Tian P,Wang L. Quantum image edge detection algorithm based on Scharr operator [C]//*Proceedings of China Automation Conference 2023*. Chongqing: Chinese Association of Automation,2023:629-636. (in Chinese)
姜琛,田鹏,王璐.基于 Scharr 算子的量子图像边缘检测算法[C]//2023 中国自动化大会论文集.重庆:中国自动化学会,2023:629-636.
- [13] Ding Y C,Geng C,Liu J X. Research on lane edge detec-

- tion method based on improved multi-direction Sobel operator[J]. Beijing Automotive Engineering, 2025(1): 23 – 29. (in Chinese)
- 丁一川, 耿聪, 刘金雄. 基于改进的多方向 Sobel 算子的车道线边缘检测方法研究[J]. 北京汽车, 2025(1): 23 – 29.
- [14] Zhang L A, Koch R. An efficient and robust line segment matching approach based on LBD descriptor and pairwise geometric consistency[J]. Journal of Visual Communication and Image Representation, 2013, 24(7): 794 – 805.
- [15] Kingma D P, Welling M. Auto-encoding variational bayes [D/OL]. (2022 – 12 – 10). <https://arxiv.org/abs/1312.6114>.
- [16] Dehaene D, Frigo O, Combexelle S, et al. Iterative energy-based projection on a normal data manifold for anomaly localization[D/OL]. (2020 – 02 – 10). <https://arxiv.org/abs/2002.03734>.
- [17] Schlegl T, Seeböck P, Waldstein S M, et al. Unsupervised anomaly detection with generative adversarial networks to guide marker discovery [C]//Niethammer M, Styner M, Aylward S, et al. Information Processing in Medical Imaging. Cham: Springer, 2017: 146 – 157.
- [18] 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.
- [19] Akcay S, Atapour-Abarghouei A, Breckon T P. GANomaly: semi-supervised anomaly detection via adversarial training [C]//Jawahar C V, Li H D, Mori G, et al. Computer Vision-ACCV 2018. Cham: Springer, 2019: 622 – 637.
- [20] Salehi M, Sadjadi N, Baselizadeh S, et al. Multiresolution knowledge distillation for anomaly detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: CVF, 2021: 14902 – 14912.
- [21] Xiang T G, Zhang Y X, Lu Y Y, et al. SQUID: deep feature In-Painting for unsupervised anomaly detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: CVF, 2023: 23890 – 23901.
- [22] Xiang T G, Zhang Y X, Lu Y Y, et al. Exploiting structural consistency of chest anatomy for unsupervised anomaly detection in radiography images [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(9): 6070 – 6081.
- [23] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks [C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2017: 764 – 773.
- [24] Zhu X Z, Hu H, Lin S, et al. Deformable convnets v2: more deformable, better results [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: CVF, 2019: 9308 – 9316.
- [25] Rahman M M, Munir M, Marculescu R. EMCAD: efficient Multi-Scale convolutional attention decoding for medical image segmentation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: CVF, 2024: 11769 – 11779.
- [26] Park H, Noh J, Ham B. Learning memory-guided normality for anomaly detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: CVF, 2020: 14372 – 14381.
- [27] Sara U, Akter M, Uddin M S. Image quality assessment through FSIM, SSIM, MSE and PSNR-a comparative study [J]. Journal of Computer and Communications, 2019, 7(3): 8 – 18.