



程江洲, 杨静怡, 鲍刚, 等. 2026. 基于改进 Faster R-CNN 的输变电工程塔基隐性病害 GPR 图像识别研究. 地球物理学进展, 41 (1): 0442-0452, doi:10. 6038/pg2026H0563.

CHENG JiangZhou, YANG JingYi, BAO Gang, et al. 2026. Research on GPR image recognition of hidden diseases of tower foundation in power transmission and transformation project based on improved Faster R-CNN. *Progress in Geophysics* (in Chinese), 41 (1): 0442-0452, doi:10. 6038/pg2026H0563.

基于改进 Faster R-CNN 的输变电工程塔基隐性病害 GPR 图像识别研究

Research on GPR image recognition of hidden diseases of tower foundation in power transmission and transformation project based on improved Faster R-CNN

程江洲^{1,2}, 杨静怡^{1*}, 鲍刚¹, 罗应权¹

CHENG JiangZhou^{1,2}, YANG JingYi^{1*}, BAO Gang¹, LUO YingQuan¹

1. 三峡大学电气与新能源学院, 宜昌 443002

2. 湖北省微电网工程技术研究中心, 宜昌 443002

1. College of Electrical and New Energy, China Three Gorges University, Yichang 443002, China

2. Hubei Microgrid Engineering Technology Research Center, Yichang 443002, China

摘 要 针对输变电工程塔基因施工过程中操作不当及相关环境因素导致的混凝土隐性病害识别难题, 本文提出了一种基于改进的 Faster R-CNN 网络 GPR 图像识别方法. 首先, 以 ResNet-50 为主干网络融合通道注意力机制, 并通过层间位置对比实验优化了 SE 模块的嵌入层级与位置, 在强化关键特征提取的同时有效降低了计算冗余. 其次, 引入 soft-NMS 算法优化紧密相邻目标的边框预测精度, 提高紧密相连目标的检测能力. 最后, 采用生成对抗网络扩增 gprMax 仿真生成的刚性直柱式基础 GPR 图像数据集, 并对样本进行识别标注. 实验结果表明, 优化模型平均精度均值达到 84.49%, F-Score 为 77.58%. 相较于传统的 Faster-RCNN 目标检测模型, 改进模型识别精度提高了 6.37%.

关键词 探地雷达; 隐性病害检测; Faster R-CNN; 生成对抗网络

Abstract Aiming at the problem of invisible diseases of tower foundation concrete in power transmission and transformation projects caused by improper operation and related environmental factors during construction, this paper proposes a GPR image recognition method for hidden diseases of tower foundation in power transmission and transformation projects based on improved Faster R-CNN. Firstly, the traditional Faster R-CNN model is optimized, and ResNet-50 is used as the feature extraction backbone network, combined with the attention mechanism (SE module). By adding the SE module to different levels of the network and placing the SE module in different positions for comparative experiments, the optimal position in the model is judged, so that the model can reduce the redundant calculation burden on the basis of extracting the key information in the feature map. Secondly, the soft-NMS algorithm is used to improve the detection ability of closely connected targets. Finally, based on the measured data of the rigid straight column foundation, the simulation is carried out by gprMax, and the GPR image is processed by the generative adversarial network to expand the data set and enhance the learning ability of the model. The experimental results show that the average accuracy of the

收稿日期 2025-04-15; 修回日期 2025-10-19.

投稿网址 <http://www.progeophys.cn>

基金项目 国家自然科学基金项目“多模态数据驱动的神经网络稳定性理论研究”(62476153)资助.

第一作者简介 程江洲, 男, 1979 年生, 博士, 博士生导师, 副教授, 主要研究方向为电气设备状态在线检测及故障诊断技术、智能配电网.

E-mail: chengjiangzhou@ctgu.edu.cn

* 通讯作者 杨静怡, 女, 2001 年生, 工学硕士, 主要研究方向为输电线路工程. E-mail: 2020237301@qq.com

中图分类号 P631
文献标识码 A
doi:10.6038/pg2026I10563
CSTR:32085.14.pg2026I10563

optimized model is 84.49%, and the F-Score is 77.58%. Compared with the traditional Faster-RCNN target detection model, the recognition accuracy is improved by 6.37% on the basis of the same data set.
Keywords Ground penetrating radar; Hidden disease detection; Faster R-CNN; Generative adversarial network

0 引言

架空线路是电力系统远距离输电的重要设施,具备建设周期短、适用范围广、成本低、承载能力高和故障易定位等优势。但由于其长期暴露于自然环境中,导线、杆塔等结构易受侵蚀劣化,增加故障风险(吕宁宁,2021)。特别是钢筋混凝土结构,由于混凝土在施工过程中的配合比不适宜、搅拌不完全等问题,导致混凝土强度严重下降。此外,杆塔基础在地壳运动及土壤侵蚀等环境因素持续作用下,其结构性能亦会渐进衰退。因此,塔基实施定期检查与维护显得尤为必要(侯斐斐等,2025)。

钢筋混凝土塔基以其高承载能力和结构刚度被广泛应用于输电线路(李国伟等,2024)。为保障输电线路的功能性和可靠性,塔基需要防止在正常使用过程中发生沉降或开裂等问题。同时,其必须具备足够的抗外力稳定性,避免造成杆塔的异常工作状态。因此,塔基不仅是支撑杆塔的结构基础,更是保障输电线路整体安全稳定运行的核心结构要素。

传统探测方法如机械钻探、电磁法声波法等常导致结构损伤,且存在效率低、图像识别准确率低等问题。探地雷达(Ground Penetrating Radar, GPR)是一种基于电磁波的无损地球物理探测技术,可实现地下结构的实时成像,为地下浅层健康监测提供了有效解决方案(郭士礼等,2025)。然而,探地雷达信号解读不够直观,图像模糊,其性能也易受环境干扰。此外,对 GPR 图像的病害特征识别长期依赖人工分析,存在解析速度慢、准确度受分析人员主观影响大等局限性。为提升病害识别效率与自动化水平,许多学者致力于开发和完善探地雷达在探测地下隐性病害方面的应用(陈珂璠等,2025)。

在图像处理领域,传统机器视觉方法通常分析 GPR B-Scan 图像中的特征(如双曲线反射)。核心算法包括基于霍夫变换检测以及特征描述方法等,通过分析图像中的特定模式,实现对地下病害目标的自动或半自动识别(李妙歌等,2024)。然而,霍夫变换因庞大的参数空间和计算复杂度而受限。针对特征提取,研究者开发了如 Viola-Jones 算法(利用

Haar-like 特征)以及结合梯度方向直方图与边缘直方图描述符等技术,提升了双曲线检测的精度。尽管这些改进增强了特征提取能力,但其依赖人工标注数据,难以满足实时处理需求,且识别效果易受噪声和图像条件干扰。

现代机器视觉领域正在融合深度学习技术,通过使用卷积神经网络(Convolutional Neural Network, CNN)和其他先进的算法,可以更好地处理图像数据,提高特征提取的能力,并增强系统的泛化和实时处理能力(段克清等,2022)。在病害识别领域,Dinh 等人应用匹配滤波器预处理雷达图像,并采用 CNN 成功识别混凝土桥梁钢筋,对电缆、金属和非金属管道、不同密度的钢筋结构以及空隙等多种对象(李昊等,2023)。然而,深度学习模型的识别能力很大程度上取决于训练数据集的质量与规模。鉴于使用 GPR 设备对探测结果实地验证过程的复杂繁琐,且获取目标的先验信息的高昂成本,构建满足实际需求的数据集面临重大挑战。这导致开源数据平台普遍缺少全面的地下病害的数据集。因此,获取尽可能反映实际探测场景、包含多种病害的 GPR 图像数据集,对于训练高识别率、低误报率的深度学习模型至关重要。

针对以上问题,本文提出了一种基于改进 Faster R-CNN 算法的输变电工程塔基隐性病害 GPR 图像识别方法,首先采用 GAN 对原始数据进行合成扩充,获得更多数据集,并对样本进行标注;其次,通过改进现有的目标检测框架,如采用 RseNet-50 作为特征提取主干网络并结合 SE 模块,增强关键病害特征的响应权重;然后,引入 soft-NMS 算法优化紧密相邻目标的边框预测精度;最后将数据集输入改进 Faster R-CNN 网络模型中训练,且测试本文模型的识别效果。本文提出的技术能够更有效地识别和定位潜在的混凝土病害,提高隐性疾病特征的检测效率和准确性。

1 改进 Faster R-CNN 网络模型

1.1 Faster R-CNN 网络模型

图 1 展示了 Faster R-CNN 目标检测网络模型框

架. 通过接收隐性病害的探地雷达 B-Scan 图谱作为输入, 然后卷积处理. 伴随着网络层次的增加, 模型逐步提取输变电工程塔基混凝土中隐性病害的特征信息. 整个网络由四个主要部分组成, 协同工作以实现 对病害特征的有效识别(兰天等, 2024).

如图 1 所示, 网络模型包含四级核心处理流程:

(1) 特征提取网络: 基于卷积-池化操作生成全局特征图(刘震等, 2024). 通过单次前向传播完成 全域特征提取, 避免传统 R-CNN 对每个候选区域重 复计算的特征冗余问题.

(2) 区域生成网络(Region Proposal Network, RPN): RPN 是模型中新增的关键组件, 其结构如 图 2 所示. 通过端到端训练的 二分类锚点机制, 在特 征图上高效生成多尺度候 选区域, 实现目标可能存 在区域的概率预测(张清 河等, 2023).

(3) ROI 池化层: 对 RPN 输出的候选区域特征 进行空间转换. 整合步骤 (2) 中生成的特征图以及 目标的未知信息, 进行归 一化处理, 输出具有统一 的长度, 传递到后续的全 连接层分类. 这一过程确 保网络能够从不同尺寸 的候选区域中提取一致 的特征表




图 1 Faster R-CNN 网络模型

Fig. 1 Faster R-CNN network model




图 2 RPN 结构图

Fig. 2 RPN structure diagram




图 3 不同特征提取网络对比

Fig. 3 Comparison of different feature extraction networks




图 4 SE 模块结构

Fig. 4 SE structure

示,从而提高了模型对目标分类的准确性.

(4)分类回归层:对池化层的输出进行分类,并采用边框回归算法进一步微调目标位置.这一步骤涉及对每个区域进行评估,以确定其所属的类别,并对目标的边界框进行精确调整,从而得出最终的目标位置和类别标签.

1.2 特征提取网络改进

深度神经网络在图像处理架构中扮演着特征提取的角色,其识别的准确性往往随着网络层数的增加而提升(王惠琴等,2024).然而,网络深度与识别准确率之间并非呈现线性的正相关.当网络深度超过某一阈值时,可能会导致模型训练的效率 and 检测速度降低.在当前的研究中,VGG19、ResNet-50 和 InceptionNet-V3 是广泛用于图像特征提取的几种模型.三种网络模型的网络层数以及预训练参数量如表 1 所示.

表 1 三种网络模型参数对比

Table 1 Comparison of three network model parameters

网络模型	网络层数	预训练参数量
VGG19	26	549
InceptionNet-V3	159	92
ResNet-50	168	99

如图 3 所示,相较于 VGG19 和 InceptionNet-V3, ResNet-50 模型利用其残差结构来增强网络的收敛速率.基于此优势,本研究选择 ResNet-50 作为基础网络模型.

为了提升对病害的探测能力,将一种通道注意力机制,简称 SE-Net,集成到了特征提取网络之中.如图 4 所示,该 SE-Net 通过加权特征通道来评定各个通道特征的重要性.这种结构设计有助于模型更加精准地获取到关键的病害特征.

SE-Net 通过通道注意力机制动态重标定特征通道权重,量化各通道在特征表达中的贡献度.该模块采用即插即用设计,可无缝集成于各类骨干网络.其通过建模通道间非线性依赖关系,自主学习特征通道的显著度,显著抑制低信息量通道噪声同时增强高语义通道响应,从而优化特征空间的判别能力.将 SE 模块的添加在网络的不同层级以及 SE 模块放置在不同的位置进行实验,对评估指标 Top-1 错误率和 Top-5 错误率进行比较,如图 5、图 6、表 2 和表 3 所示.

表 2 SE 模块的添加在网络的不同层级的影响

Table 2 The impact of the addition of SE modules at different levels of the network

网络层级	Top-1 err. / %	Top-5 err. / %
ResNet-50	23.30	6.55
SE_Stage_2	23.03	6.48
SE_Stage_3	23.04	6.32
SE_Stage_4	22.68	6.22
SE_All	22.28	6.03

表 3 在模型中的不同位置对比结果

Table 3 Comparison of the results at different positions in the model

放置位置	Top-1 err. / %	Top-5 err. / %
SE	22.28	6.03
SE-PRE	22.23	6.00
SE-POST	22.78	6.35
SE-Identity	22.20	6.15

实验表明(图 5、图 6),SE 模块置于各层级 ResNet 残差块后端时性能最优.因此,本研究选择在 ResNet-50 的各个卷积层后嵌入 SE-Net 模块.此外,因为 SE-Net 被集成在残差块之前,会与整个 CNN 一起进行端到端的训练,因此性能成本忽略不计.

1.3 软非最大值抑制改进

在 Faster R-CNN 框架中,非极大抑制算法(Non-Maximum Suppression, NMS)被用于评估候选框的得分,并筛选出得分最高的候选框(杨洋等,2024).然而,在 GPR B-Scan 图像的病害检测中,由于目标可能紧密相邻,为了解决这一问题,本文采用了 Soft-NMS 方法.与直接移除重叠候选框的传统 NMS 不同,Soft-NMS 通过降低重叠框得分来处理.这种方法在减少误报的同时,确保了相近位置的病害目标得以有效识别.通常,Soft-NMS 采用高斯和线性函数来调整框得分.本研究选用了线性函数进行实验,如公式(1)所示,提高模型对相邻病害目标的识别能力:

$$s_i = \begin{cases} s_i e^{\frac{\text{IoU}(M, b_i)}{\sigma}} & \forall b_i \notin D \\ s_i & \text{IoU}(M, b_i) < N \\ s_i (1 - \text{IoU}(M, b_i)) & \text{IoU}(M, b_i) \geq N \end{cases} \quad (1)$$

式中, M 代表得分最高候选框; b_i 是待评估候选框.如果 M 和 b_i 之间的重叠度 $\text{IoU}(M, b_i)$ 小于阈值 N 时,则保留 b_i 的检测分数 s_i ,反之,对 b_i 的分数进行衰减处理.




图 5 SE-Net 模块在网络的不同层级对比
Fig. 5 Comparison of SE-Net modules at different levels of the network




图 6 SE-Net 模块结构放置位置对比
Fig. 6 Comparison of SE-Net module structure placement positions




图 7 空洞病害的正演模型
(a) 圆形空洞;(b) 矩形空洞.
Fig. 7 The forward model of cavity disease
(a) Circular cavity;(b) Rectangular cavity.



图 8 裂缝病害的正演模型
Fig. 8 The forward model of fracture disease

1.4 评价指标与损失函数

输变电工程塔基隐性缺陷病害检测的准确率是判断目标模型优劣的重要指标. 本文主要采用平均准确率 A_p 、均值平均精度 mAP、精确度 P 、召回率 R 等评价指标对模型性能进行量化判断,并结合每秒传输帧数 FPS 和 F-Score 反映网络模型综合性能,表达式为:

$$A_p = \int_0^1 P(r) dr , \tag{2}$$

$$mAP = \frac{\sum_{n=1}^N A_p(n)}{N} , \tag{3}$$

$$P = \frac{T_p}{T_p + F_p}, \tag{4}$$

$$R = \frac{T_p}{T_p + F_N}, \tag{5}$$

$$\text{F-Score} = (1 + \beta^2) \times \frac{P \times R}{(\beta^2 \times P) + R}, \tag{6}$$

其中 β 是一个参数,用于平衡精确度和召回率的相对重要性. 常见的选择是 $\beta = 1$,这时 F-Score 称为 F_1 -Score.

改进 Faster R-CNN 目标检测算法中,损失函数主要包括分类损失和边界框回归损失两部分,如式(7)所示. 分类损失用于衡量模型预测的类别与真实标签之间的匹配程度,边界框回归损失用于衡量预测的边界框与真实边界框之间的差异. 公式如下:

$$L(p_i, t_i) = L_{\text{cls}}(p, i) + L_{\text{reg}}(t_i, t_i^*), \tag{7}$$

$$L_{\text{cls}}(p, i) = -\log(p_i), \tag{8}$$

$$L_{\text{reg}}(t_i, t_i^*) = \sum_i \text{smooth}(t_i, t_i^*), \tag{9}$$

$$\text{smooth}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & |x| \geq 1 \end{cases}. \tag{10}$$

2 模型训练与测试

2.1 数据采集与预处理

输变电工程塔基隐性缺陷病害检测模型需要大规模高质量数据支撑,所以对探地雷达探测数据的数量及质量提出了更高的要求. 现今搭建并扩充 GPR 数据集主要采用两种方式:一是基于实测数据资料,通过电磁场仿真软件如 gprMax 等进行仿真,获得理想数据;二是利用传统的图像处理技术,如缩放、镜像和裁剪等. 上述两种方式,第一种可以对实测数据进行补充,但是仿真耗时长,获得的模拟数据数量有限;第二种运算速度快,耗时短,但仅仅只能获得目前电磁环境下的探测结果,不能有效处理环境里复杂多变的杂波干扰.

输变电工程塔基混凝土隐性病害通常指的是在混凝土结构中不易直接观察到的内部损伤或缺陷,如裂缝和空洞等. 使用 gprMax 软件模拟与实际输变电杆塔塔基一致的正演模型,获取不同病害的 GPR 回波特征曲线. 模型考虑了实际尺寸大小和介电常数分布,对塔基常见病害进行仿真. 图 7 对圆形和矩形两种不同形态空洞缺陷病害建模,采用 gprMax 原生几何命令生成. 由于 gprMax 内置的几何命令所建立的模型是规则的,如圆球、正方体、圆柱体、三角体等,因此结合 Matlab 生成任意不规则几何形状进行

建模. 图 8 是对裂缝隐形病害建模.

表 4 探地雷达相关技术参数
Table 4 Technology parameters

技术参数	数值
采样频率/kHz	250
工作频率/MHz	400
探测深度/m	0 ~ 5
工作电压/V	12
工作电流/A	0.5
整机功耗/W	<6
雷达信噪比/dB	>110

通过 GAN 网络增强正演模拟 B-scan 数据集,其结构见图 9. 图 9 展示了包含生成器 G 和判别器 D 两个核心网络的系统.

图 9 中, G 和 D 都是基于 CNN 网络架构. G 接收随机噪声向量作为输入,并产生模拟的 GPR 目标图像 $G(z)$. 相对地, D 接收这些合成的二维图像以及使用 gprMax 软件模拟真实 GPR 二维图像作为输入,其任务是区分合成数据 $D(G(x))$ 与真实数据,并评估合成数据与真实数据相匹配的概率. 模型训练的核心目标是使合成数据的真实性尽可能地接近真实情况,其中判别器将真实数据标记为 1,将伪造数据标记为 0. 训练过程中使用的目标函数旨在优化这一过程. 模型训练的目标函数为:

$$V(G, D) = E_x[\log D(x)] + E_z[\log(1 - D(G(z)))] , \tag{11}$$

式中: $E_x[\cdot]$ 是真实数据的平均概率; $E_z[\cdot]$ 是合成数据被判别为真实的平均概率. 训练模型的目标是提高识别真实数据概率并降低误判概率,使达到最大化识别率 $D(x)$,最小化率 $1 - D(G(z))$,尽可能符合实际探测情况下的图像,获得不同病害探测数据集.




图 9 GAN 网络结构
Fig. 9 GAN network structure

使用 gprMax 仿真软件对塔基的隐性病害进行一系列正演模拟仿真. 首先,在基于单一病害模型进行仿真,以确保对每种病害类型的深入分析. 在此基础上,我们创建了一个包含多种病害的组合模型,并生成了 800 张仿真回波图像. 同时,我们还利用实地探地雷达设备收集了 200 张真实的回波图像(图 10). 使用训练好的 GAN 来扩充数据集,并将其与实际测量的 GPR 图结合(图 11). 在将目标图送入网络前,裁剪 GPR 图,确保边长不超过 1000,并采用 LabelImg 工具对 GPR B-scan 图像标注.

探地雷达 B-Scan 图像被分为训练、验证和测试三部分,比例为 8 : 1 : 1,具体分配详见表 5.

表 5 数据集具体分配情况
Table 5 Distribution of data sets

名称	数量	作用
训练集	4000	训练模型
验证集	500	验证模型是否拟合
测试集	500	评估模型性能




图 10 隐性病害分类
Fig. 10 Classification of latent diseases

GPR 图像资料解释是通过分析雷达剖面中同相轴的波形、振幅与相位变化特征,结合现场环境及地质资料,推断地下空洞、裂缝等病害体的过程. 为了提升探测精度,对塔基不同病害体的探地雷达特征和正演模拟特征图进行详细分析,总结不同病害类型 GPR 特征见表 6.




图 11 扩充 GPR 图像
Fig. 11 Expanded GPR image

表 6 不同病害的 GPR 特征		
Table 6 The GPR characteristics of different diseases		
病害类型	振幅	GPR 图像特征
空洞	整体振幅强	顶点尖锐,双翼对称张开,边缘发生绕射,多次反射
裂缝	整体振幅强	连续或断续的线性强反射,同相轴错断

2.2 改进 Faster R-CNN 模型训练

实验基于 TensorFlow 和 Keras 等框架,选择了 Windows 10 专业版作为实验的操作系统,对地下隐蔽缺陷样本进行深度学习训练. 实验初始学习率为 0.001.

同时,使用学习率递减策略,在训练过程中,按照每 2000 次迭代将学习率乘以 0.005,从而逐步降低学习率,以提高模型的收敛速度和性能. 在此基础上,阈值设定为 0.5 来判定边界框是否包含病害信息,若某边界框的 IoU 值超过 0.5,则认为其内含有地下病害相关信息;若不足,该区域视为不包含相关信息,应予以排除.

训练步骤如下:①初始化 RPN:基于 ImageNet 预训练权重微调 RPN 网络,生成初步候选框;②训练 Faster R-CNN 网络:固定 RPN 参数,利用步骤(1)的候选框独立训练 Faster R-CNN 检测头;③微调 RPN 参数:保持共享的卷积层不变,更新 RPN 参数;④优化检测网络:固定共享卷积层,使用经过 RPN 优化后的候选框,精调检测网络.

为了验证所提出的模型在识别输变电工程塔基隐性病害方面的有效性,本研究采用了 GPR 图像中典型的病害样本,并运用改进的 Faster R-CNN 算法进行识别. 研究基于仿真数据集预训练得到的模型

为基础进行进一步的训练,并设置了 2000 次迭代,以确保模型能够充分学习并优化..

针对混凝土结构中空洞与裂缝两类典型病害,搭建探地雷达实测平台开展识别实验:采用探地雷达设备对预设病害模型进行探测,获取实际 GPR 探测图部分如图 12 所示. 将 GPR 图输入训练好的检测模型,识别结果如表 7 所示.

表 7 不同病害类型的测试样本			
Table 7 Test samples of different disease types			
类型	数量	误检/漏检数	准确率/%
空洞	270	17	93.65
裂缝	230	38	83.53

如图 12 和表 7 所示,经训练后的模型在实际病害 GPR 图像的检测中表现出了良好的特征提取能力. 空洞样本中,模型实现 93.65% 的准确率;裂缝样本准确率为 83.53%,误检可能源于病害尺寸过小或者未识别出病害等其他因素. 从检测结果中可以看出,尽管实测图像与仿真结果相比,更接近真实情况,识别难度增加,但本模型仍然能准确地辨识不同病害特征.

3 结果与分析

3.1 消融试验

为了全面评估提出的模型性能,将传统模型和集成 Soft-NMS、SE-Net 注意力机制、GAN 等不同改进方法的模型进行比较,以及上述 3 种改进方法进行不同排列组合的对比. 表 8 展示了不同改进组合的 Faster R-CNN 结构的对比结果,图 13 展示了 3 种特征提取网络测试的 mAP 和 Loss 值.




图 12 实际应用隐性病害检测结果
(a) 空洞病害;(b) 裂缝病害.

Fig. 12 Measured recessive disease detection results
(a) Cavity disease;(b) Crack disease.

表 8 10 组改进 Faster R-CNN 结构对比

Table 8 Comparison of 10 groups of improved Faster R-CNN structure

组别	Soft-NMS	SE-Net	GAN	特征提取网络	mAP/%	FPS	F-Score/%
1	×	×	×	ResNet-50	77.41	12.21	71.79
2	√	×	×	ResNet-50	78.88	11.55	73.20
3	×	√	×	ResNet-50	78.04	11.68	74.21
4	×	×	√	ResNet-50	79.39	13.12	74.89
5	√	√	×	ResNet-50	78.02	11.87	75.43
6	√	×	√	ResNet-50	84.93	13.33	74.47
7	×	√	√	ResNet-50	84.00	14.71	76.11
8	√	√	√	VGG19	68.2	14.48	76.25
9	√	√	√	INET-V3	78.3	13.96	76.68
10	√	√	√	ResNet-50	84.49	14.43	77.58




图 13 3 种特征提取网络测试结果

Fig. 13 Three kinds of feature extraction network test results




图 14 目标检测模型对比

Fig. 14 Comparison of target detection models

由表 8 得到,改进后的 Fater R-CNN 准确率较高,其评价指标 mAP、F-Score 分别为 84.49%、77.58%。

3.2 不同模型对比

将改进模型与 SSD300 和 Yolo V5 进行相同数据的检测性能对比试验. 设定 IoU 值为 0.5 时,对比分析不同模型的识别效率,结果汇总于表 9. 图 14 中结果显示,改进模型在 mAP 和 F-Score 两个指标上表现更佳,且在多次测试中展现了良好的性能稳定性.

表 9 不同网络模型对比

Table 9 Comparison of different network models

检测模型	FPS	F-Score/%	mAP/%
SSD	46.36	67.4	68.72
Yolo V5	31.93	75.19	76.23
Faster R-CNN	13.69	72.16	78.12
本文模型	14.43	77.58	84.49

经过验证,模型能够准确地识别图像中的地下病害特征,GPR 目标检测结果得到实际验证,这也证明了模型的鲁棒性.同时,在病害识别过程中显示出较快的识别速度,平均用时 0.081s.与传统机器学习算法不同,该模型能够有效地探测具有多种重叠目标,提供了可靠的识别结论.

4 结 论

针对输变电塔基需要定期维护以及 GPR 图像中识别精度低、样本稀缺的瓶颈问题,本文提出了一种基于改进 Faster R-CNN 的检测算法.为应对输变电工程塔基隐性病害的识别需求,通过引入 Soft-NMS、通道注意力机制来改进已有算法,并扩充数据集,能够在处理塔基的 GPR 图像时更加精确地定位和分类病害特征.通过正演模拟及实际数据验证了该模型的可行性,得出主要结论如下:

- (1)该模型能够用于快速识别输变电工程塔基 GPR 图像中的空洞和裂缝.
- (2)经过测试,优化后的 Faster R-CNN 模型在病害识别方面 mAP、F-Score 分别为 84.49%、77.58%,能够有效地区分裂缝和空洞等主要病害类型.即便在病害特征相互重叠或出现复合病害的情况下,模型依然能够准确地进行识别.

致 谢 感谢审稿专家提出的修改意见和编辑部的大力支持!

References

Chen Y F, Wang Y, Jiang W, *et al.* 2025. Research on fracture segmentation of FMI logging images based on deep learning. *Progress in Geophysics* (in Chinese), 40(1): 143-154, doi: 10.6038/pg2025HH0480.

Duan K Q, Li X, Xing K, *et al.* 2022. Clutter mitigation in space-based early warning radar using a convolutional neural network. *Journal of Radars* (in Chinese), 11(3): 386-398.

Guo S L, Cai W C, Tian P F, *et al.* 2025. Research on GPR diagnostic system for hidden road defects based on YOLO. *Progress in Geophysics* (in Chinese), 40(2): 827-837, doi: 10.6038/pg2025II0151.

Hou F F, Zhang Z X, Cui G Y, *et al.* 2025. DETR-MCA: Intelligent detection algorithm for tunnel lining defects based on GPR images. *Journal of Railway Science and Engineering* (in Chinese), 22(4): 1840-1852, doi: 10.19713/j.cnki.43-1423/u.T20241087.

Lan T, Sheng S W, Sun X T, *et al.* 2024. Three-dimensional reconstruction method for detecting small targets within walls based on a multistage cascade U-Net approach using ground penetrating radars. *Journal of Radars* (in Chinese), 13(6): 1184-1201.

Li G W, Wang J B, Zhang Y, *et al.* 2024. Influence factor analysis on detection effect for directly buried cable based on GprMax forward modeling. *Southern Power System Technology* (in Chinese), 18(12): 10-18.

Li H, Yu H, Zhang Z Q, *et al.* 2023. Intelligent identification of hidden disease in transmission line corridor based on ground penetrating radar. *Journal of Liaoning Technical University* (Natural Science) (in Chinese), 42(5): 609-616.

Li M G, Chen B, Wang D S, *et al.* 2024. CNN model visualization method for SAR image target classification. *Journal of Radars* (in Chinese), 13(2): 359-373.

Liu Z, Gu X Y, Li J, *et al.* 2024. Deep learning-enhanced numerical simulation of ground penetrating radar and image detection of road cracks. *Chinese Journal of Geophysics* (in Chinese), 67(6): 2455-2471, doi: 10.6038/cjg2023R0090.

Lü N N. 2021. Application of GPR in defect detection of transmission line tower foundation [Master's thesis] (in Chinese). Huainan: Anhui University of Science and Technology.

Wang H Q, Luo J, He Y Q, *et al.* 2024. Identification of common underground pipelines by ground penetrating radar based on improved YOLOv5. *Chinese Journal of Geophysics* (in Chinese), 67(9): 3588-3604, doi: 10.6038/cjg2023R0431.

Yang Y, Zhao G M, Zhang Z H, *et al.* 2024. Intelligent detection method for railway subgrade diseases based on ground-penetrating radar. *Progress in Geophysics* (in Chinese), 39(6): 2471-2482, doi: 10.6038/pg2024HH0280.

Zhang Q H, Wu X Y, Liu H, *et al.* 2023. A novel method for fast forward simulation of ground penetrating radar and buried target detection based on machine learning. *Chinese Journal of Geophysics* (in Chinese), 66(8): 3482-3492, doi: 10.6038/cjg2022Q0368.

附中文参考文献

陈珂璠,王杨,蒋薇,等. 2025. 基于深度学习的 FMI 测井图像裂缝分割研究. *地球物理学进展*, 40(1): 143-154, doi: 10.6038/pg2025HH0480.

段克清,李想,行坤,等. 2022. 基于卷积神经网络的天基预警雷达杂波抑制方法. *雷达学报*, 11(3): 386-398.

郭士礼,蔡文才,田鹏飞,等. 2025. 基于 YOLO 的道路隐性病害探地雷达图谱智能诊断系统研究. *地球物理学进展*, 40(2): 827-837, doi: 10.6038/pg2025II0151.

侯斐斐,张智轩,崔广炎,等. 2025. DETR-MCA: 基于探地雷达图像的隧道衬砌内部缺陷的智能检测算法. *铁道科学与工程学报*, 22(4): 1840-1852, doi: 10.19713/j.cnki.43-1423/u.T20241087.

兰天,盛世文,孙熙韬,等. 2024. 探地雷达多阶段级联 U-Net 墙内小目标三维重建方法. *雷达学报*, 13(6): 1184-1201.

李国伟,王俊波,张殷,等. 2024. 基于 GprMax 正演模拟的直埋电缆探测效果影响因素分析. *南方电网技术*, 18(12): 10-18.

李昊,于虹,张志强,等. 2023. 基于探地雷达的输电线路走廊隐性病害智能识别. *辽宁工程技术大学学报(自然科学版)*, 42(5): 609-616.

李妙歌,陈渤,王东升,等. 2024. 面向 SAR 图像目标分类的 CNN 模型可视化方法. *雷达学报*, 13(2): 359-373.

刘震,顾兴宇,李骏,等. 2024. 探地雷达数值模拟与道路裂缝图像检测的深度学习增强方法. *地球物理学报*, 67(6): 2455-2471,

doi: 10.6038/cjg2023R0090.

吕宁宁. 2021. GPR 在输电线路塔基中的缺陷检测应用研究[硕士学位论文]. 淮南: 安徽理工大学.

王惠琴, 罗佳, 何永强, 等. 2024. 改进 YOLOv5 的探地雷达常见地下管线识别. 地球物理学报, 67(9): 3588-3604, doi: 10.6038/cjg2023R0431.

杨洋, 赵广茂, 张志厚, 等. 2024. 铁路路基病害探地雷达智能识别方法. 地球物理学进展, 39(6): 2471-2482, doi: 10.6038/pg2024HH0280.

张清河, 吴欣悦, 刘含, 等. 2023. 一种新颖的探地雷达快速正演模拟及埋地目标探测机器学习方法. 地球物理学报, 66(8): 3482-3492, doi: 10.6038/cjg2022Q0368.