

DOI:10.20033/j.1003-7241.(2026)03-0022-05

基于改进的 FasterNet 太阳能板表面损坏污染检测方法

邱心涛¹, 朱昨庆², 于士友³, 徐小林¹, 王青², 张迅²

(1. 青岛市产品质量检验研究院, 山东 青岛 266000; 2. 青岛市产品质量检验技术研究所, 山东 青岛 266000;
3. 青岛海汇德电气有限公司, 山东 青岛 266000)

摘要:为实现太阳能板表面损坏污染的智能化分类检测,提出了一种基于改进的 FasterNet 模型的检测方法。针对太阳能板表面损坏污染种类繁多且具有复杂背景的特点,首先建立了包含鸟屎、灰尘、电气灼伤等类别的太阳能板污染损坏数据集,并对图像进行预处理以增强数据多样性。然后,构建了改进的 FasterNet 分类检测模型,在模型的第1层和第3层 FasterNet Block 后添加 SimAM 无参注意力机制,并采用自适应矩估计(adaptive moment estimation, Adam)作为模型损失函数,进一步提升了网络的分类性能和训练效率。在实验过程中,通过与原始 FasterNet 模型的对比,相比于传统的太阳能板检测方法,改进后的 FasterNet 模型在实际应用中具有较好的智能化性能,能够在不增加计算复杂度的情况下提高检测精度。研究结果为实现太阳能板智能巡检提供了有效的技术支持,具有广泛的应用前景。

关键词: FasterNet; 太阳能板; SimAM 注意力机制; 检测; 智能化; 深度学习

中图分类号: TP18; TP391

文献标志码: A

文章编号: 1003-7241(2026)03-0022-05

Surface damage and pollution detection method for improved FasterNet solar panels

QIU Xintao¹, ZHU Zuoqing², YU Shiyu³, XU Xiaolin¹, WANG Qing², ZHANG Xun²

(1. Qingdao Institute of Product Quality Inspection, Qingdao 266000, Shandong, China;

2. Qingdao Institute of Product Quality Inspection Technology, Qingdao 266000, Shandong, China;

3. Qingdao Haihuide Electric corporation, Qingdao 266000, Shandong, China)

Abstract: In order to achieve intelligent classification detection of surface damage and pollution on solar panels, this paper proposes a detection method based on an improved FasterNet model. Aiming at the variety of surface damage and pollution types and the complex background characteristics of solar panels, a dataset is first established that includes categories such as bird droppings, dust, and electrical burns, and image preprocessing techniques are applied to enhance data diversity. Then, an improved FasterNet classification detection model is constructed, with SimAM parameter-free attention mechanisms added after the first and third FasterNet Blocks, and adaptive moment estimation(Adam) is used as the model loss function, further improving the network's classification performance and training efficiency. In the experimental process, a comparison with the original FasterNet model is conducted. Compared to traditional solar panel detection methods, the improved FasterNet model exhibits better intelligent performance in practical applications, improving detection accuracy without increasing computational complexity. The research presented in this paper provides effective technical support for the realization of intelligent solar panel inspection, with broad application prospects.

Keywords: FasterNet; solar panels; SimAM attention mechanism; detection; intelligence; deep learning

太阳能是重要的清洁能源,太阳能板是将太阳能转换成电能的重要手段,在我国太阳能板发电量在逐年提高^[1]。太阳能板的管理是保障正常发电的重要手段,其中太阳能板的损坏和污染将会影响其发电的效率。传统的太阳能板损坏污染检测依赖于人工检查,费时费力,如何采用智能化手段进行太阳能板巡检已成为学者研究的

热点^[2]。

近年来,深度学习技术在图像识别领域取得了显著的进展,为太阳能板表面污染的自动识别提供了新的可能。张猛等^[3]提出了一种,提出一种基于 SimAM-Ada YOLOv5 算法的太阳能电池缺陷检测方法在测试集中检测 mAP 达到 89.86%。史新科等^[4]采用基于改进 CNN 算法,搭建模

收稿日期:2024-07-30;录用日期:2024-08-19

基金项目:泰安市科技创新发展项目(2022GX074)

作者简介:邱心涛(1980—),男,硕士,高级工程师,研究方向:新能源产品检验检测。

引用本文:邱心涛,朱昨庆,于士友,等. 基于改进的 FasterNet 太阳能板表面损坏污染检测方法[J]. 自动化技术与应用, 2026,45(3):22-26. (QIU Xintao, ZHU Zuoqing, YU Shiyu, et al. Surface damage and pollution detection method for improved FasterNet solar panels[J]. Techniques of Automation and Applications, 2026,45(3):22-26.)

型进行太阳能板遮挡物分类研究。周启宸等^[5]提出一种基于改进YOLOv7的太阳能电池片表缺陷检测算法。首先,在YOLOv7网络模型的基础上引入Swin Transformer模块,以增强模型的全局信息建模;在测试集上的mAP@50%达到86.6%。

学者通过深度学习技术对相关太阳能板缺陷、遮挡等进行了检测并取得了良好的检测效果,但是针对太阳能板缺陷和污染的检测鲜有研究,为了解决对太阳能板缺陷和污染的智能化检测,本文提出了改进的FasterNet分类检测模型,在模型后两层加入SimAM无参注意力机制,采用Adam作为模型损失函数,以在不增加模型参数的同时增加检测精度,为实现智能化太阳能巡检提供支持。

1 试验与方法

1.1 图像采集与预处理

本试验图像数据采集点为青岛市胶州市胶西街道大行新村光伏发电厂并通过网络爬虫技术对太阳能板相关图像进行搜索,其中现场采集1045张,网络爬虫收集1457张。同时将所有图像尺寸调整到640mm×640mm大小。为增加数据的多样性通过随机旋转、翻转、平移手段进行扩充,最终确定4320张图像,进一步将图像分为鸟屎太阳能板图像、清洁太阳能板图像,灰尘太阳能板图像,电气灼伤太阳能板,损坏太阳能板图像,积雪覆盖太阳能板,为了训练方便对应编号分别为0、1、2、3、4、5,部分图像如图1所示。




图1 数据集部分图像

Fig. 1 Partial image of data set

1.2 FasterNet

FasterNet是一种运算速度非常快的轻量级网络,该模型采用PConv模块,以减少计算冗余和内存访问^[6]。PConv模块在输入通道的一部分上应用常规Conv进行空间特征提取,并保持其余通道不变。对于连续或规则的内存访问,将第一个或最后一个连续的通道视为整个特征图的代表进行计算。在不丧失一般性的情况下认为输入和输出特征图具有相同数量的通道^[7-8]。

如图2所示,P-shaped Conv卷积为了充分有效地利用来自所有通道的信息,进一步将逐点卷积(PWConv)附加到PConv。它们在输入特征图上的有效感受看起来像一个T形Conv,与均匀处理补丁的常规Conv相比,它更专注于中心位置。

FasterNet网络由4层FasterNet Block组成,每个层次级前面都有一个嵌入层(步长为4的常规4×4卷积)或一个合并层(步长为2的常规2×2卷积),用于空间下采样和通道数量扩展。每个FasterNet块有一个PConv层,后

跟2个PWConv(或Conv1×1)层。它们一起显示为倒置残差块,其中中间层具有扩展的通道数量,并且放置了Shortcut以重用输入特征^[9-10]。




图2 P-shaped Conv卷积结构

Fig. 2 Convolutional structure of P-shaped Conv

1.3 FasterNet网络的改进

改进后的FasterNet网络如图3所示,由图3可知,改进后的网络由3层FasterNet Block组成,第1层输入为 $c_2 \times \frac{h}{8} \times \frac{w}{8}$,第2层输入为 $c_2 \times \frac{h}{16} \times \frac{w}{16}$,第3层输入为 $c_2 \times \frac{h}{32} \times \frac{w}{32}$,并在第1层和第3层FasterNet Block添加SimAM无参注意力机制以提高改进后网络的检测性能。




图3 改进的FasterNet网络结构

Fig. 3 Improved FasterNet network architecture

1.3.1 添加 SimAM 无参注意力机制

SimAM 的设计灵感来源于人脑的注意力机制^[11]。研究者们受此启发,开发出一种独特的能量函数,用以计算每个神经元的权重,并据此评估其重要性。SimAM 在实现这一功能时,并不需要向网络添加任何额外的参数。它依赖于能量函数的闭合求解形式,能够高效地加快权重计算过程,从而有助于实现检测模型的轻量化运行。SimAM 注意力机制结构示意图如图4所示,能量函数如式(1)所示。




图4 SimAM注意力机制结构

Fig. 4 SimAM attention module structure

$$e_k^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t_k - \hat{u})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (1)$$

式中, λ 是正则项, t_k 是输入特征图在单个通道上的第 k 个神经元, \hat{u} 是所有神经元在单个通道上的均值, $\hat{\sigma}^2$ 是所有神经元在单个通道上的方差。

e_k^* 值越小表示能量越低, 神经元 k 与周围神经元的区别越大, 对视觉处理越重要。因此, 每个神经元的重要性是 e_k^* 的反比。

输出特征图 \tilde{X} 计算式为

$$\tilde{X} = \text{sigmoid} \left(\frac{1}{E} X \right) \quad (2)$$

式中, \tilde{X} 是输出特征图, X 是输入特征图

在众多注意力机制中 SimAM 注意力机制以无参数化而著称^[12], 本研究所用的 FasterNet 网络是一个轻量级的网络, 对模型的参数有严格的要求。引入无参数注意力机制后不增加网络的额外参数并能够使得模型更好地聚焦于图像中的关键信息^[13]。因此, 本研究将 SimAM 注意力机制添加到 FasterNet 网络的第 1 层和第 3 层 FasterNet Block 后添加 SimAM 无参注意力机制, 以提高模型的检测能力。

1.3.2 Adam 优化函数

损失在分类模型的构建与优化过程中, 优化函数扮演着至关重要的角色。其核心任务在于通过迭代调整模型的参数, 以最小化一个预定义的损失函数, 从而不断提升模型的预测性能^[14]。在分类任务中, 优化函数致力于使

模型的预测概率分布尽可能地逼近真实的标签分布。这通常通过最小化一个特定的损失函数来实现。这些损失函数能够有效地量化模型预测与实际标签之间的差异, 从而为优化函数提供了明确的优化目标。

优化函数的选择对于分类模型的性能具有显著影响, 不同的优化函数具有不同的收敛速度、稳定性和泛化能力^[15]。本研究选择 Adam 作为改进的 FasterNet 网络的优化函数, Adam 优化算法结合了 Momentum 和 RMSprop 的优点, 能够在训练过程中自适应地调整学习率, 从而加速模型的收敛速度并提高性能。

2 结果与讨论

2.1 试验环境

在本次试验中硬件配置如下: 采用 Intel Xeon Gold 系列多核处理器, 配备 128 GB DDR4 ECC REG 内存, 使用 1 TB NVMe SSD 作为主存储。在 GPU 方面, 选用 NVIDIA RTX 3060 显卡, 以提供强大的深度学习计算能力。软件环境方面, 采用 Ubuntu 20.04 LTS 操作系统, 安装 Pytorch1.8 深度学习框架, 并使用 Python 3.8 编程语言进行模型开发。

2.2 评价性指标

本试验选用准确率, F_1 值和混淆矩阵来进行模型可靠性评价, 具体公式^[16-17]为

$$\text{Accuracy} = \frac{T_{P+} T_N}{T_{P+} T_{N+} T_P} \times 100\% \quad (3)$$

$$\text{Precision} = \frac{T_P}{T_P + F_P} \times 100\% \quad (4)$$

$$\text{Recall} = \frac{T_P}{T_P + F_N} \times 100\% \quad (5)$$

式中, P 是精确度, R 是召回率; T_p 是真阳性, 被正确预测为正样本的数量; T_N 是真阴性, 负样本被预测为负样本的数量, F_p 是假阳性, 负样本被预测为正样本的数量, F_N 是假阴性, 正样本被预测为负样本的数量。

F_1 值是综合精确率 (Precision) 和召回率 (Recall) 的评价指标:

$$F_1 = \frac{2\text{Accuracy} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 100\% \quad (6)$$

2.3 结果与讨论

2.3.1 SimAM 无参注意力机制的影响分析

本文为了深入探究 SimAM 无参注意力机制对 FasterNet 网络性能的影响, 对比了添加 SimAM 前后的 FasterNet 网络在分类任务上的准确率和 F_1 值的影响结果如表 1 所示, 由表 1 可知, 在相同的数据集和训练条件下, 添加 SimAM 后的 FasterNet 网络在准确率上有了显著提升。原始 FasterNet 的准确率为 76.24%, F_1 值为 75.84%, 而添加 SimAM 后的准确率提升至 78.28%, F_1 值提升至 77.45%。这一结果清晰地表明, SimAM 无参注意力机制能够有效地提升 FasterNet 网络的分类性能。

表 1 使用 SimAM 注意力机制前后的识别结果

Tab. 1 Recognition results before and after using the SimAM attention mechanism

模型	SimAM 注意力模块	测试集总准确率/%	测试集 F_1 值/%	模型参数/MB
FasterNet	是	78.28	77.45	4.0
	否	76.24	75.84	4.0

2.3.2 Adam 优化函数的效果评估

本文为了深入探究不同优化函数对 FasterNet 网络性能的影响,选用了两种常见的优化函数进行对比试验,分别是 SGD(随机梯度下降)和 RMSprop。如图 5 所示为 3 种优化函数模型训练损失曲线,由图 5 可知,3 种优化函数训练的模型都得到很好效果,训练后期损失值都趋于稳定,Adam 优化器表现出了较快的收敛速度,尤其在训练初期其损失值下降迅速,且整体稳定性较好。对比结果如图 6 所示,由图 6 可知,从准确率的角度来看,Adam 优化函数在 FasterNet 网络上展现出了较高的性能。在相同的数据集和训练条件下,使用 Adam 优化函数的 FasterNet 网络在准确率上超过了 SGD 和 RMSprop,其准确率达到了 76.24%,相较于 SGD 和 RMSprop 分别提升了 3.79% 和 6.7%,其 F_1 值达到了 75.84%,相较于 SGD 和 RMSprop 分别提升了 2.29% 和 4.06%,这一结果说明,不同的优化函数对分类模型的准确率和 F_1 值有显著的影响,适合的优化函数有助于模型的整体性能提升,Adam 优化函数在优化 FasterNet 网络参数时更加高效,能够更好地找到损失函数的最优解,进一步说明了 Adam 优化函数的优越性。




图 5 不同优化函数模型训练损失曲线

Fig. 5 Training loss curves for different optimization function models




图 6 不同优化函数的识别结果

Fig. 6 Recognition results of different optimization functions

2.3.3 不同模型对比分析

为了全面评估 FasterNet 网络在图像分类任务上的性能,本文选择了几个当前流行的分类模型进行对比分析,包括 ResNet-34^[18]、VGGNet-16^[19] 以及 MobileNet-small^[20]

结果如表 2 所示。由表 2 可知,从测试集总准确率和 F_1 值来看,本文模型在所有的对比模型中展现更优的性能总精确度为 78.28%, F_1 值为 77.45%,模型大小为 4.0 MB,相较于 ResNet-50、VGGNet-16 以及 MobileNet-small 等主流模型,均表现出了更高的分类精度。这表明本文模型在特征提取和分类决策方面更具优势,能够有效地应对复杂的图像分类任务。

其次,从模型参数大小来看,FasterNet 网络在保持高性能的同时,还具有较小的模型参数。相较于 VGGNet-16 的 512 MB 和 ResNet-50 的 81.3 MB,FasterNet 网络的模型参数仅为 4.0 MB,这大大减小了模型的存储需求和计算复杂度。这使得 FasterNet 网络在实际应用中更易于部署和扩展,特别是在资源有限的场景下,如移动设备或嵌入式系统中。

通过对比不同分类模型在准确率、训练速度和模型复杂度等方面的表现,本文模型在图像分类任务上展现出了与主流模型相当甚至更优的性能。同时,该模型还具有较低的计算复杂度和参数量,这使其在实际应用中更具优势。进一步证明了本文模型的有效性。

表 2 不同模型对比的识别结果

Tab. 2 Recognition results of different model comparisons

模型	模型参数/MB	识别结果	
		测试集总准确率/%	测试集 F_1 值/%
ResNet-50	81.3	72.47	73.35
VGGNet-16	512	69.58	71.59
MobileNet-small	4.9	76.84	77.48
本文模型	4.0	78.28	77.45

2.3.4 混淆矩阵结果对比分析

在本研究中,针对改进前后的 FasterNet 网络进行了深入的混淆矩阵对比分析,以揭示两者在分类性能上的差异。对比矩阵如图 7、8 所示,图 7 为 FasterNet 的测试集混淆矩阵,图 8 为改进的 FasterNet 的测试集混淆矩阵,结果表明,原始网络在某些类别上出现了明显的误分类现象。特别是在一些相似度较高的类别 1(清洁)与 2(灰尘)之间,模型的分类边界较为模糊,导致混淆矩阵中对应位置的值偏高。在对比改进后的 FasterNet 网络混淆矩阵分析。通过引入 SimAM 无参注意力机制和采用 Adam 优化函数,改进后的网络在分类性能上取得了显著的提升。从混淆矩阵中可以看出,误分类的情况得到了有效的减少,特别是在那些原始网络容易混淆的类别上,改进后的网络展现出了更高的分类准确率,这一结果充分验证了对 FasterNet 网络改进的有效性。通过对比改进前后网络在

混淆矩阵对角线上的值可以看出,除序号 6 的值减少了 8 个数值,其他都有所提升,序号 0 提升 14 个数值,序号 1 提升 10 个数值,序号 3 提升 20 个数值,序号 4 提升 8 个数值,进一步证明了改进措施的有效性。




图 7 FasterNet 的测试集混淆矩阵

Fig. 7 Test set confusion matrix for FasterNet




图 8 改进的 FasterNet 的测试集混淆矩阵

Fig. 8 Improved test set confusion matrix for FasterNet

3 结论

本文基于实现智能化太阳能板表面损坏污染分类检测应用场景,研究了改进的 FasterNet 分类模型使之能够应用到太阳能板智能分类检测。首先,本研究针对 FasterNet 网络进行了两方面的关键改进:引入了 SimAM 无参注意力机制和采用了 Adam 优化函数。通过一系列严谨的验证,得出了以下结论:SimAM 无参注意力机制的引入显著提升了 FasterNet 网络的分类性能。其次,Adam 优化函数的采用显著加速了 FasterNet 网络的训练过程。能够更快地收敛到最优解,并减少训练过程中的震荡现象。最终改进后的模型在测试集中的总准确率为 78.28%, F_1 值为 77.45%, 模型大小为 4.0MB, 能够满足实际应用要求。

未来,将继续探索更多有效的网络结构和优化方法,以进一步推动深度学习在太阳能板智能巡检的应用。

参考文献

[1] 贾俊,袁栋,戴永东,等. 基于深度学习算法的配网设备状态智能巡检方法[J]. 自动化技术与应用, 2024, 43(12):80-83,158.

[2] 康璐,段玖祥,张文杰,等. 基于视觉激光融合的新能源发电智能巡检技术[J]. 电力科技与环保, 2023, 39(2):173-181.

[3] 张猛,尹丽菊,周辉,等. 基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J]. 电子测量技术, 2023, 46(22):17-25.

[4] 史新科,杨成佳,李丽新. 基于改进 CNN 的太阳能板遮挡物分类研究[J]. 吉林建筑大学学报, 2023, 40(5):78-83.

[5] 周启宸,王伯超. 基于改进 YOLOv7 的太阳能电池片表面缺陷检测[J]. 计算机应用, 2023, 43(增刊 2):223-228.

[6] 杨宇,高林,唐永欣,等. 基于 FG-YOLOv7-tiny 算法的耐张线夹 X 光图像压接缺陷检测[J]. 湖北民族大学学报(自然科学版), 2024, 42(1):51-58.

[7] 李茂,肖洋轶,宗望远,等. 基于改进 YOLOv8 模型的轻量化板栗果实识别方法[J]. 农业工程学报, 2024, 40(1):201-209.

[8] 唐艳凤,胡立姗,尤海正,等. 基于 YOLO-v4 的海滩垃圾识别算法研究[J]. 自动化技术与应用, 2025, 44(5):141-145.

[9] REN R, SUN H, ZHANG S, et al. FPG-YOLO: a detection method for pollenable stamen in 'Yuluxiang' pear under non-structural environments [J]. Scientia Horticulturae, 2024,328(11):2941.

[10] WANG Q, YANG L, ZHOU B, et al. YOLO-SS-Large: a lightweight and high-performance model for defect detection in substations[J]. Sensors, 2023, 23(19): 8080.

[11] 康澜,蒋晓刚,苑志江. 基于改进 YOLOv5 的轻量化早期舰船火灾烟雾检测算法[J]. 通信与信息技术, 2024(2):21-26.

[12] 张杨,辛国江,王鑫,等. 基于改进的 YOLOv5 网络的舌象检测算法[J]. 计算机技术与应用, 2024, 34(2):156-162.

[13] 张猛,尹丽菊,周辉,等. 基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J]. 电子测量技术, 2023, 46(22):17-25.

[14] 唐豪,张振东,吴兵. 基于 BP 神经网络的 HPPC 低温 SOC 优化估计[J]. 计算机系统应用, 2021, 30(6):293-299.

[15] 孟庆成,万达,吴浩杰,等. 基于卷积神经网络的混凝土裂缝图像识别方法[J]. 沈阳建筑大学学报(自然科学版), 2021, 37(5): 832-840.

[16] 彭润东,李耀翔,陈雅,等. 基于 LSTM 长短期记忆网络的樟子松木材气干密度 NIRS 模型预测[J]. 中南林业科技大学学报, 2024, 44(3):179-188.

[17] 龚思宇,陈姚节,陈黎. 基于注意力机制的 TCS-YOLO 船舶检测系统[J]. 船舶工程, 2023, 45(11):108-115, 144.

[18] 刘小凯,边骥轩,张江勇,等. 基于改进 ResNet-18 模型的弧齿锥齿轮安装位置偏差分类识别方法研究[J]. 农业装备与车辆工程, 2024, 62(3):96-100.

[19] 王敬启. 改进 YOLOv7-Tiny 的电力现场作业安全装备实时检测算法[J]. 自动化技术与应用, 2025, 44(9):89-94.

[20] GU Y, CHEN R, WU K, et al. A variable-speed-condition bearing fault diagnosis methodology with recurrence plot coding and MobileNet-v3 model[J]. Review of Scientific Instruments, 2023, 94(3):034710.