

## 一种基于 ResPNet 的光伏组件红外成像故障检测方法

孙明正, 李浩\*

河海大学地球科学与工程学院, 江苏 南京 211100

**摘要** 目前利用无人机获取光伏组件红外影像数据越来越多地应用于光伏组件故障检测中。但光伏组件红外影像数据各类别样本相似度较高, 现有深度学习模型的光伏组件红外影像特征提取能力较低, 导致光伏组件多故障类型分类精度偏低。针对以上问题, 基于 ResNet(residual network)模型构建 ResPNet(residual photovoltaic network)模型进行光伏组件红外影像故障检测。ResPNet 模型在 ResNet 模型基础上, 加入了底层特征信息增强模块、多尺度特征信息增强模块、全局特征信息增强模块, 用于提升模型的光伏组件红外影像特征提取能力。在公开的光伏组件红外影像数据集 Infrared Solar Modules 上进行实验, ResPNet 模型的 12 类光伏组件红外影像分类精度达到 84.6%, 不但优于 ResNet-50 模型, 而且优于其他的光伏组件红外影像分类模型。通过级联多个 ResPNet 模型, 取得了该数据集目前已知最高的 12 类光伏组件红外影像分类检测精度(85.9%)。

**关键词** ResNet; 光伏组件; 深度学习; 红外影像; 故障检测

中图分类号 TM615

文献标志码 A

DOI: 10.3788/LOP230912

## Infrared Image Fault Detection of Photovoltaic Modules Based on Residual Photovoltaic Network

Sun Mingzheng, Li Hao\*

*School of Earth Science and Engineering, Hohai University, Nanjing 211100, Jiangsu, China*

**Abstract** At present, infrared image data of photovoltaic modules obtained by unmanned aerial vehicle is more and more used in the fault detection of photovoltaic module. However, due to the high similarity of various samples of photovoltaic module infrared image data, the existing deep learning model has a low ability to extract photovoltaic module infrared image features, resulting in low detection accuracy of photovoltaic module multi-fault types. To solve the above problems, a residual photovoltaic network (ResPNet) model is constructed based on the residual network (ResNet) model for infrared image fault detection of photovoltaic modules. On the basis of ResNet model, ResPNet adds the underlying feature information enhancement module, multi-scale feature information enhancement module and global feature information enhancement module to improve the infrared image feature extraction ability of photovoltaic modules. Experiments are conducted on Infrared Solar Modules, a disclosed infrared image dataset of photovoltaic modules. The ResPNet model achieves an infrared image classification accuracy of 84.6% for 12 types of photovoltaic modules, which is better than not only ResNet-50 model, but also other infrared image classification models. Through cascading several ResPNet models, the highest known infrared image classification detection accuracy of 12 types of photovoltaic modules in this dataset is achieved at 85.9%.

**Key words** ResNet; photovoltaic module; deep learning; infrared image; fault detection

## 1 引言

随着新能源不断发展, 光伏发电在能源供应中呈现上升趋势, 大量光伏组件需要进行维护与检修<sup>[1]</sup>。红外图像已经在设备诊断<sup>[2]</sup>、车辆识别<sup>[3]</sup>、人体检测<sup>[4-5]</sup>

等领域取得广泛应用。近年来, 该技术被越来越多地应用于光伏组件故障检测当中。

Haidari 等<sup>[6]</sup>利用 VGG (visual geometry group)<sup>[7]</sup>模型对光伏组件运行状态进行检测, 并在预处理阶段利用中值滤波去除光伏组件红外影像噪声。该方法的

收稿日期: 2023-03-22; 修回日期: 2023-04-01; 录用日期: 2023-04-20; 网络首发日期: 2023-04-30

基金项目: 国家自然科学基金(41971279)

通信作者: \*lihao@hhu.edu.cn

热点和断路故障平均检测精度为 98%。Hwang 等<sup>[8]</sup>利用卷积神经网络(CNN)模型与阈值处理方法对光伏组件热点、短路和断路故障进行检测。该方法对于上述三种光伏组件故障类型的检测精度高达 99%。但阈值选择需要手动处理且集成了多种检测方法,导致光伏组件故障检测时间较长。上述方法能够实现较高精度的光伏组件故障判别,但在多种故障类型光伏组件故障检测中检测精度偏低。姜萍等<sup>[9]</sup>基于改进的 InceptionV3<sup>[10]</sup>网络模型进行光伏组件红外影像故障检测,提升了光伏组件故障检测速率,但没有提升检测精度。Alves 等<sup>[11]</sup>基于无人机获取的红外影像数据通过构建深度学习模型对光伏组件是否存在故障进行了判别,并取得了 92.5% 的判别精度。而在光伏组件红外影像 8 类故障检测中,由于影像数据各类别样本相似度较高且模型构建相对比较简单,分类检测精度仅为 78.85%。王艳等<sup>[12]</sup>为提升光伏组件故障检测精度,提出了一种 CNN-支持向量机(SVM)混合模型,并在 Infrared Solar Modules 数据集上取得了 82.85% 的光伏组件红外影像分类精度。但该方法中 CNN 与 SVM 模型需要分别进行训练,增加了模型训练的复杂度。Le 等<sup>[13]</sup>基于改进的 ResNet-50<sup>[14]</sup>模型对光伏组件 12 个类别的红外影像数据进行划分,取得了 84.1% 的光伏组件分类精度。为解决光伏组件多类别故障分类精度偏低问题,本文基于改进的 ResNet-50<sup>[14]</sup>模型 ResPNet(residual photovoltaic network)进行光伏组件故障检测。通过增强原模型的光伏组件红外影像特征提取能力,提升了光伏组件红外影像多故障类型分类精度。最后通过级联多个 ResPNet 模型,实现了对 Infrared Solar Modules 数据集中 12 类光伏组件红外影像数据最高的分类检测精度。

## 2 基于 ResNet-50 模型构建 ResPNet 模型

ResNet 模型作为深度 CNN 模型,因其独特的残差设计,相比于 VGG 等模型拥有更强的特征提取能力,在图像分类、图像检测等任务中应用广泛。但该模型为快速获取输入影像特征,初始阶段存在特征缺失问题,并且该模型的多尺度特征以及全局特征提取能力较低。

基于 ResNet-50 模型构建 ResPNet 模型进行光伏组件红外影像故障检测。ResPNet 模型结构如图 1 所示,其中,  $s$  为卷积步长。在 ResNet-50 模型 Conv1 中调整模型初始阶段的步长参数以及 Conv2 <sub>$x$</sub>  中的层级架构,提升模型底层空间信息提取能力。将 ResNet-50 模型中残差模块替换为多尺度特征信息增强残差模块(Respblock),增强模型对光伏组件红外影像数据中灰度变化信息以及多尺度特征信息的提取。在 ResNet-50 模型 Conv3 <sub>$x$</sub> 、Conv4 <sub>$x$</sub> 、Conv5 <sub>$x$</sub>  特征提取完成后加入全局特征信息增强模块(Gblock),保证模

型在整个特征提取过程中维持较强的全局特征信息提取能力。

### 2.1 底层特征信息增强模块

ResNet-50 模型在 Conv1 卷积中选用步长为 2 的卷积,是为了减少模型参数数量,降低模型训练对硬件设备的需求。初始阶段减小特征层尺寸有利于快速获取图像中的语义信息,但不利于模型提取光伏组件红外影像数据底层信息,所以 ResPNet 将 ResNet-50 模型 Conv1 卷积的步长调整为 1。ResNet-50 在 Conv2 <sub>$x$</sub>  初始阶段使用了步长为 2 的 Maxpooling 层,该层同样也会丢失部分底层空间信息,不利于模型整体特征信息提取。如图 1 所示,底层特征信息增强模块去除了原模型的 Maxpooling 层。

通过对模型初始阶段 Conv1 卷积层步长的调整以及 Conv2 <sub>$x$</sub>  中 Maxpooling 层的去除,特征图底层信息能够更好地被保留,并且模型深层部分也能够得到更大的特征图,有利于模型整体的特征提取,从而实现更高精度的光伏组件故障检测。

### 2.2 Respblock

ResNet-50 模型通过在 Conv2 <sub>$x$</sub> 、Conv3 <sub>$x$</sub> 、Conv4 <sub>$x$</sub> 、Conv5 <sub>$x$</sub>  阶段依次堆叠多个残差连接模块提取光伏组件红外影像数据中的语义信息。较高的特征层通过卷积获取抽象特征,从而实现光伏组件红外影像类别划分。图 2 为 ResNet-50 模型的残差连接模块。该模块首先利用  $1 \times 1$  卷积进行通道数的降低,然后利用  $3 \times 3$  卷积进行特征提取,最后利用  $1 \times 1$  卷积进行通道数的提升,从而实现残差连接。光伏组件红外影像数据为单通道数据,并且数据所包含的纹理细节信息相对较少。ResNet-50 模型残差连接模块在  $1 \times 1$  卷积过程中,通道数提升了 4 倍,容易造成信息冗余。如图 3 所示,为降低特征提取过程中的通道信息冗余,Respblock 将通道数的提升倍率降低为 2。

光伏组件发生故障时,故障区域温度较高,红外影像上表现为高温区域灰度值异常升高。光伏组件故障检测中对划分故障类别较为重要的是获取光伏组件红外影像数据中的灰度变化信息以及边缘信息。如图 3 所示,结合 GoogLeNet<sup>[15]</sup>模型中 Inception 模块的多尺度特征信息提取思想,在 ResNet-50 模型原有的残差模块中加入  $1 \times 3$  卷积以及  $3 \times 1$  卷积,提升模型灰度变化信息以及边缘信息提取能力;在相同层级上加入  $5 \times 5$  卷积以及  $7 \times 7$  卷积实现多尺度特征提取;将最后的  $1 \times 1$  卷积调整为  $3 \times 3$  卷积,保证多尺度特征提取在残差模块结束阶段不仅进行通道维度的信息整合,而且进行空间维度的信息整合,提升模型整体的特征提取能力。

### 2.3 Gblock

ResNet-50 模型在堆叠残差模块的过程中,底层卷积用于提取不同空间位置的空间信息,下一层卷积用于整合不同位置空间信息以得到更深层次的语义信

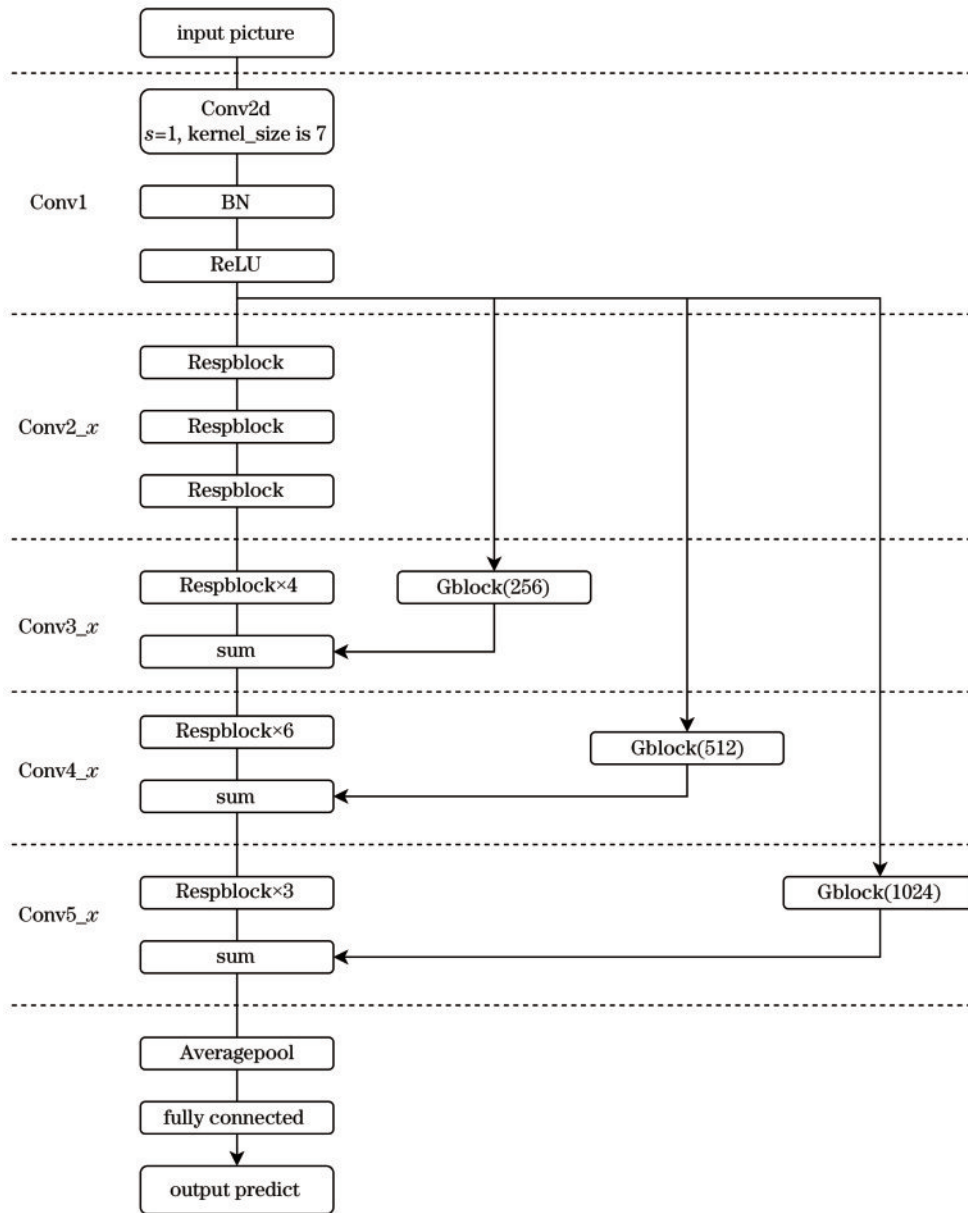


图 1 ResPNet 模型  
Fig. 1 Model of ResPNet

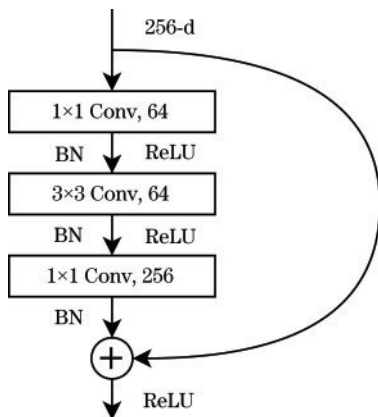


图 2 残差模块  
Fig. 2 Model of Residual block

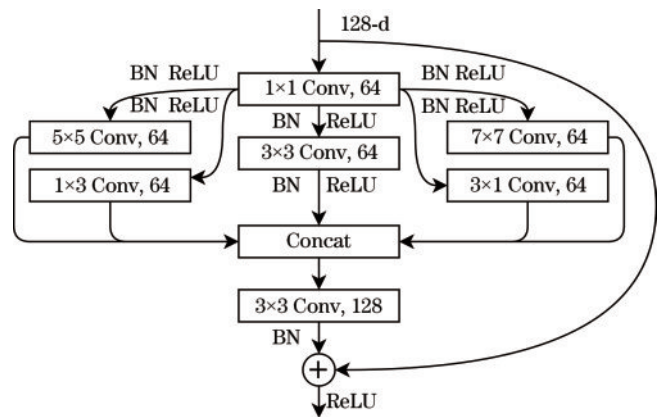


图 3 Respblock 模型  
Fig. 3 Model of Respblock



息。随着特征层尺寸的减小,全局信息存在部分丢失的情况。Transformer<sup>[16-17]</sup>模型相较于 ResNet 模型,提取全局特征信息能力更强。但 Transformer 模型参数量较大,需要大量的训练数据对参数进行调整,否则训练结果较差。本文构建一种全局特征信息提取模块,如图 4 所示。该模块通过更大尺寸卷积核提取底层特

征并连接深层特征,实现底层特征与深层特征的连接,从而增强全局特征。如图 1 所示,全局特征信息增强模块首先对 Conv1 获取的特征层进行进一步特征提取,然后将全局信息添加到 ResNet-50 模型的 Conv3<sub>x</sub>、Conv4<sub>x</sub>、Conv5<sub>x</sub> 之后,保证模型在整个特征提取过程中都能维持较强的全局特征信息提取能力。

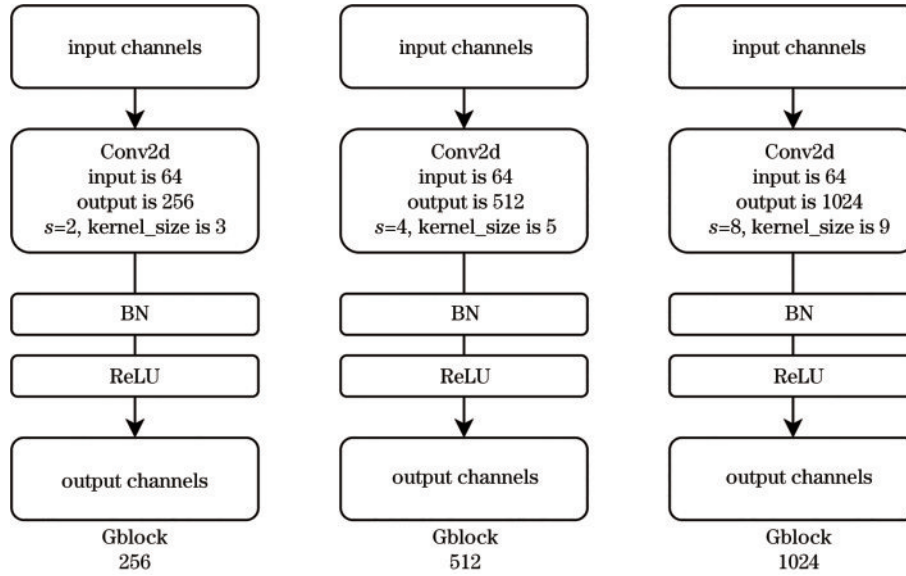


图 4 Gblock 模型  
Fig. 4 Model of Gblock

### 2.4 多模型级联

在光伏组件故障检测中,Le<sup>[13]</sup>等级联 15 个改进的 Resnet-50 模型实现了检测精度的提升。多模型级联检测过程如图 5 所示。首先训练多个光伏组件故障检测分类模型,然后对多个分类模型的预测检测结果进行求和平均,最后通过 Softmax 函数预测输出光伏组件红外影像所属类别。通过级联多个 ResPNet 模型,

可以实现更高精度的光伏组件故障检测。

## 3 实验与分析

### 3.1 数据集介绍

本文使用的数据集<sup>[18]</sup>共包含 20000 张光伏组件红外影像数据,数据集由 Raptor Maps, Inc. 团队公布,主要用于光伏组件故障检测研究。该数据集共包含 12 个光伏组件类别:热斑、多热斑、裂纹、热点、多热点、阴影、单片短路、多片短路、植物遮挡、异物遮挡、断路、无故障。类别划分依据如表 1 所示。12 个类别中 11 个类别是故障影像,1 个类别是无故障影像,影像数据如表 2 所示。影像的尺寸为 40 pixel × 24 pixel。数据由无人机搭载的中长波(3~13.5 μm)红外影像仪获取,每个像元对应的地面分辨率为 3~15 cm。

数据集以 90% 的训练数据和 10% 的测试数据随机划分。模型训练过程中训练数据划分为 70% 的训练集和 30% 的验证集。用到的数据增强方法包括随机水平翻转和随机垂直翻转。

### 3.2 实验平台及网络参数设置

所有实验均基于 Python3.8 和 PyTorch1.10 深度学习框架、CUDA11.3、Torchvision0.11.1、Torchaudio0.10.0 进行。实验模型在 6 GB 内存的 NVIDIA GeForce GTX 3060 GPU 上进行训练,优化器设置为 Adam、损失函数设置为交叉熵损失、Batchsize 设置为 32、迭代次数为 200、学习率设置为 0.0001。

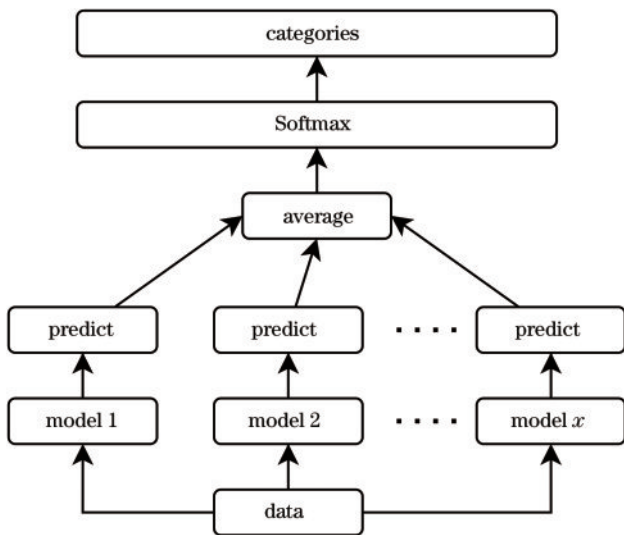
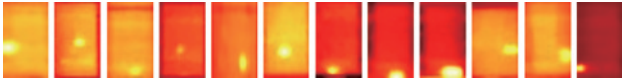
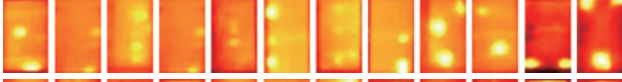



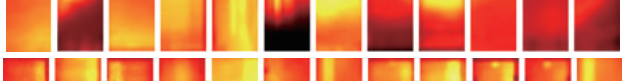
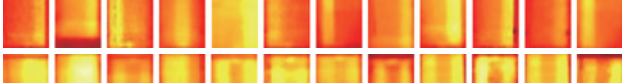
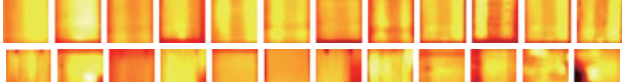






图 5 多模型级联光伏组件检测架构  
Fig. 5 Ensemble neural network framework for prediction of photovoltaic modules

表 1 光伏组件红外影像类别划分依据及数据集划分表  
Table 1 Description of photovoltaic module and dataset partitioning

Fault name	Fault description	Number of images	Number of images in train and validation dataset	Number of images in test dataset
Cell	There is a single square hot spot in the photovoltaic module	1877	1689	188
Cell-multi	There are multiple square hot spots in the photovoltaic module	1288	1160	128
Cracking	Cracks exist on the surface of the photovoltaic module	940	845	95
Hot-spot	A single hot spot exists on the surface of the photovoltaic module	249	224	25
Hot-spot-multi	There are multiple hot spots on the surface of the photovoltaic module	246	222	24
Shadowing	Shadows created by plants, artifacts between adjacent rows	1056	950	106
Diode	Bypass diode short circuit causes that 1/3 photovoltaic module cannot operate normally	1499	1349	150
Diode-multi	The short circuit of the bypass diode causes that 2/3 of the photovoltaic module cannot operate normally	175	158	17
Vegetation	The plants shade the photovoltaic module	1639	1476	163
Soiling	Dust and garbage may block the surface of the photovoltaic module	204	183	21
Offline-module	The entire photovoltaic module fails to operate properly	827	744	83
No-anomaly	Trouble-free	10000	9000	1000

表 2 光伏组件红外影像数据集样本示例  
Table 2 Type of photovoltaic module images

Fault name	Image data
Cell	
Cell-multi	
Cracking	
Hot-spot	
Hot-spot-multi	
Shadowing	
Diode	
Diode-multi	
Vegetation	
Soiling	
Offline-module	
No-anomaly	

Note: the photovoltaic module infrared image data in the table are falsely coloured based on the COLORMAP\_HOT module in Open-CV for better visualisation, where the brighter parts have higher grey values and the darker parts have lower grey values.

### 3.3 实验设计及评价指标

为验证所提 ResPNet 模型中底层特征信息增强模块、Resblock、Gblock 对网络模型整体性能的影响,设置消融实验进行分析。基于 ResNet-50 模型加入底层特征信息增强模块记为 ResPNet[D],基于 ResPNet[D] 模型加入 Resblock 记为 ResPNet[P],基于 ResPNet[P] 模型加入 Gblock 记为 ResPNet[G]。

为量化光伏组件故障检测结果,以准确率  $A_c$ 、平均精确率  $A_p$ 、平均召回率  $A_r$  以及  $F_{F1-Score}$  作为光伏组件分类检测评价指标。计算公式为

$$A_c = \frac{T_p + T_n}{T_p + T_n + F_p + F_n}, \quad (1)$$

$$A_p = \frac{1}{N} \sum_1^N \frac{T_p}{T_p + F_p}, \quad (2)$$

$$A_r = \frac{1}{N} \sum_1^N \frac{T_p}{T_p + F_n}, \quad (3)$$

$$F_{F1-Score} = \frac{2A_p \times A_r}{A_p + A_r}, \quad (4)$$

式中: $N$ 为光伏组件红外影像类别数; $T_p$ 为正样本预测为正; $T_n$ 为负样本预测为负; $F_p$ 为负样本预测为正; $F_n$ 为正样本预测为负。

### 3.4 实验结果

图 6、图 7 分别为 ResNet-50、ResPNet[D]、

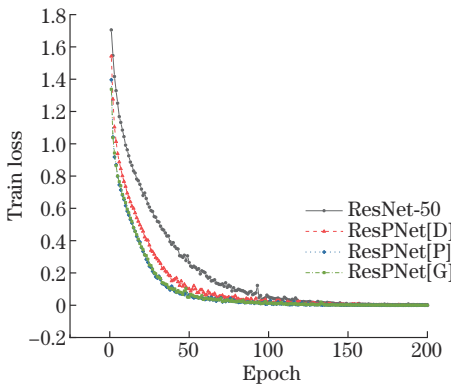


图 6 各模型训练损失图

Fig. 6 Training loss of each model

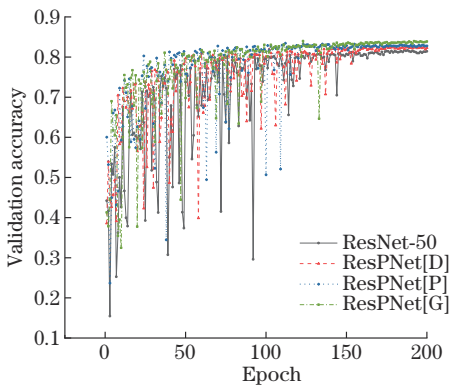


图 7 各模型验证精度图

Fig. 7 Validation accuracy of each model

ResPNet[P]、ResPNet[G] 模型训练损失图和验证精度图。分析图 6、图 7 可知 150 次迭代后,所有模型的训练损失与验证精度均趋于平稳,表明训练完成。

由图 6 所示:相比于 ResNet-50 模型,ResPNet[D] 模型的训练损失下降更快,表明保留底层特征信息可以增强模型的特征提取能力;相比于 ResPNet[D] 模型,ResPNet[P]、ResPNet[G] 模型损失下降更快,表明加入 Resblock、Gblock 后模型的特征提取能力得到了进一步的提升。

由图 7 所示,最终模型验证精度 ResNet-50 < ResPNet[D] < ResPNet[P] < ResPNet[G],表明依次加入底层特征信息增强模块、Resblock 以及 Gblock,有利于 ResPNet 模型检测精度的提升。

为验证底层特征信息增强模块能够得到更丰富的底层空间特征信息,取表 2 中的第一张热斑影像数据,对 ResNet-50 和 ResPNet[D] 模型 Conv1 卷积后的特征层进行可视化,可视化结果如图 8 所示。观察图 8 可以看到 ResPNet[D] 模型获取的特征图尺寸为 ResNet-50 模型获取特征图尺寸的 16 倍。较大尺寸的特征图有利于模型提取更详细的红外影像底层特征信息,进一步提升光伏组件红外影像分类精度。




图 8 底层特征信息增强模块特征层可视化图。(a) ResNet-50 的特征层信息;(b) ResPNet[D] 的特征层信息

Fig. 8 Feature layer visualization information of underlying feature information enhancement module. (a) Feature maps information of ResNet-50; (b) feature maps information of ResPNet[D]

为验证 Resblock 相比于 Residual block 能够获取更丰富的灰度变化信息以及多尺度特征信息,取表 2 中的第一张热斑影像数据,对 ResPNet[D] 和 ResPNet[P] 模型 Conv2\_x 后的特征层进行可视化,可视化结果如图 9 所示。观察图 9 可以看到 ResPNet[P] 模型得到的特征图相比 ResPNet[D] 模型得到的特征图纹理细节信息更加丰富,表明加入 Resblock 后,模型能够获取更丰富的多尺度特征信息。模型浅层获取更多特征信息,深层转换得到更多语义信息,可以实现更高精度的






图9 ResPblock特征层可视化图。(a) ResPNet[D]的特征层信息；(b) ResPNet[P]的特征层信息

Fig. 9 Feature layer visualization information of ResPblock module. (a) Feature maps information of ResPNet[D]; (b) feature maps information of ResPNet[P]

光伏组件故障检测。

为验证Gblock能够保留更多的全局信息,取表2中的第一张热斑影像数据,对ResPNet[P]和ResPNet[G]模型Conv3\_x后的特征层进行可视化,观察特征图(图10),可以发现ResPNet[G]模型加入全局特征信息后,相当于在较高的特征层中融入了浅层空间特征信息,所以模型较高特征层依然保有一定的全局空间信息,实现了浅层空间信息与深层语义信息的融合。多信息融合有利于模型对光伏组件红外影像类别进行判断。




图10 Gblock特征层可视化图。(a) ResPNet[P]的特征层信息；(b) ResPNet[G]的特征层信息

Fig. 10 Feature layer visualization information of Gblock module. (a) Feature maps information of ResPNet[P]; (b) feature maps information of ResPNet[G]

ResNet-50、ResPNet[D]、ResPNet[P]、ResPNet[G]模型测试结果如表3所示。分析表3可以得出,所提ResPNet模型相比于ResNet-50能够实现更高精度的

表3 光伏组件红外影像分类精度消融实验结果

Table 3 Ablation experiment results of infrared image classification accuracy of photovoltaic modules

Dataset	Model	$A_c$ / %
Infrared Solar Modules	ResNet-50	83.2
	ResPNet[D]	83.8
	ResPNet[P]	84.4
	ResPNet[G]	84.6

光伏组件故障检测,检测精度提升1.4个百分点。保留ResNet-50模型底层特征信息得到的ResPNet[D]模型,与Resnet-50相比检测精度提升0.6个百分点;在ResPNet[D]模型基础上将残差连接模块替换为ResPblock得到ResPNet[P]模型,相较于ResPNet[D]模型,检测精度进一步提升0.6个百分点;在ResPNet[P]模型基础上加入Gblock,检测精度提升0.2个百分点。

ResPNet模型在Resnet-50模型基础上加入底层特征信息增强模块、ResPblock、Gblock,提升了模型特征提取能力,减少了模型特征提取过程中的信息流失,取得了更高的光伏组件分类检测精度。

表4对比了不同分类模型在Infrared Solar Modules数据集上的光伏组件红外影像分类精度。分析表4可以得出,相比已有的ShuffleNetV2<sup>[19]</sup>、MobileNetV2<sup>[20]</sup>、ResNet-101<sup>[14]</sup>、EfficientNetV7<sup>[21]</sup>等分类检测模型,ResPNet模型的12类光伏组件红外影像分类结果中, $A_c$ 、 $A_p$ 、 $F_{F1-Score}$ 值均最高, $A_r$ 略低于Resnet-50模型。相比于上述模型,ResPNet模型分类速度较慢,但仍可以保持较快速度的光伏检测。相比于王艳等<sup>[12]</sup>、Le等<sup>[13]</sup>提出的分类检测模型,ResPNet模型的12类光伏组件红外影像分类精度最高。

表4 不同模型光伏组件红外影像分类精度

Table 4 Model accuracy of infrared image classification in photovoltaic modules

Model	$A_c$ / %	$A_p$ / %	$A_r$ / %	$F_{F1-Score}$ / %	Speed / ms
ShuffleNetV2 <sup>[19]</sup>	76.8	59.8	54.1	56.8	4.9
MobileNetV2 <sup>[20]</sup>	78.3	63.0	57.2	59.9	4.0
ResNet-50 <sup>[14]</sup>	83.2	74.2	67.9	70.9	5.1
ResNet-101 <sup>[14]</sup>	83.5	74.3	67.0	70.4	12.3
EfficientNetV7 <sup>[21]</sup>	81.4	68.7	63.6	66.1	26.9
Alves et al. 模型 <sup>[11]</sup>	78.8	—	—	—	—
CNN-SVM <sup>[12]</sup>	82.9	—	—	—	—
Le et al. 模型 <sup>[13]</sup>	84.1	—	—	—	—
ResPNet[G]	84.6	75.8	67.6	71.5	30.8

图11列出了ResNet-50和ResPNet[G]模型的光伏组件故障检测测试结果。分析该结果可以得出ResPNet模型相比于ResNet-50模型,光伏组件故障类型数据的检测精度和无故障类型数据的检测精度均有所提升。其中:故障类型数据测试样本数为1000,

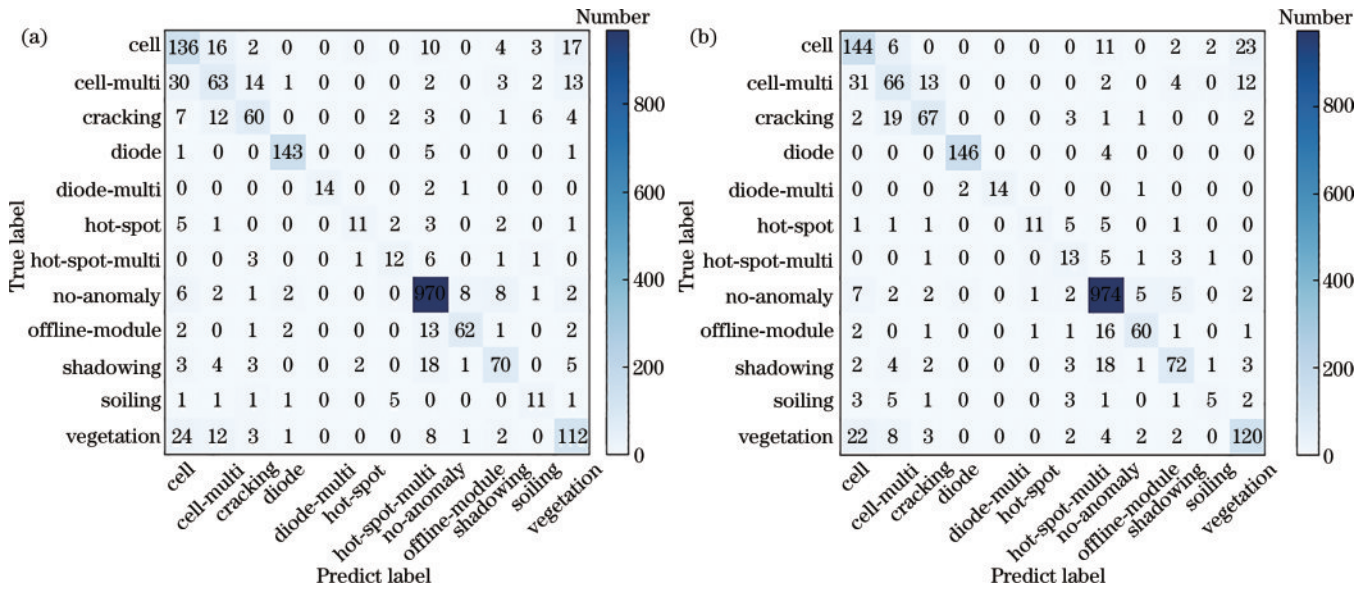


图 11 不同光伏组件故障检测模型的测试结果。(a)ResNet;(b)ResPNet

Fig. 11 Test results of different photovoltaic module fault detection models. (a) ResNet; (b) ResPNet

ResPNet 模型检测正确的样本数为  $144+66+67+146+14+11+13+60+72+5+120=718$ , ResNet 模型检测正确的样本数为  $136+63+60+143+14+11+12+62+70+11+112=694$ , ResPNet 模型相比于 ResNet 模型,故障类型数据检测精度提升 2.4 个百分点;无故障类型数据(no-anomaly)测试样本数为 1000, ResPNet 模型检测正确的样本数为 974, ResNet 模型检测正确的样本数为 970, ResPNet 模型相比于 ResNet 模型,无故障类型数据检测精度提升 0.4 个百分点。

表 5 对比了 Le 等<sup>[13]</sup>集成 15 个改进的 ResNet-50 模型的光伏组件分类精度以及集成 3 个 ResPNet 模型的光伏组件分类精度。通过表 5 可以得出,集成更少数量的 ResPNet 模型可以取得与集成 15 个改进 ResNet-50 模型相同的 12 类光伏组件红外影像分类精度,表明所提 ResPNet 模型光伏组件红外影像数据特征提取能力更强。相比于单个模型,级联多个模型能够取得更高的光伏组件红外影像分类精度。

表 5 集成模型的光伏组件红外影像分类精度

Table 5 Integrated models for infrared image classification accuracy of photovoltaic module

Model	No. of model	$A_c / \%$
Proposed by Le et al. <sup>[13]</sup>	15	85.9
ResPNet[G]	3	85.9

图 12 列出了级联 3 个 ResPNet[G] 模型的光伏组件故障检测测试结果。级联模型故障样本检测正确的数量为 732,相较于单个模型检测精度提升 1.4 个百分点;无故障样本检测正确的数量为 985,相较于单个模型检测精度提升 1.1 个百分点。上述结果表明,级联模型的光伏组件故障影像数据与无故障影像数据的检测精度均有提升。




图 12 级联模型的光伏组件故障检测测试结果

Fig. 12 Test results of cascaded photovoltaic module fault detection

## 4 结 论

为解决光伏组件红外影像多故障类型检测精度偏低的问题,在 ResNet 模型基础上构建了适用于光伏组件红外影像故障检测的 ResPNet 模型。通过消融实验证明了所提 ResPNet 模型中的底层特征信息增强模块、ResPblock、Gblock 均有利于提取光伏组件红外影像数据特征信息,实现更高精度的光伏组件故障检测。

利用所提 ResPNet 模型在公开的光伏组件红外影像数据集上进行实验,12 类光伏组件红外影像数据分类精度为 84.6%。相比于原模型分类精度有明显提升,证明了改进方法的有效性。级联 3 个 ResPNet 模型取得了该数据集目前最高的分类检测精度



(85.9%),证明了级联模型在光伏组件红外影像故障检测中的有效性。实验过程中发现,光伏组件红外影像数据所包含的光伏组件故障特征信息相对较少,导致多故障类型光伏组件红外数据分类精度偏低。考虑结合可见光影像与红外影像,进一步提升光伏组件分类检测精度。

### 参 考 文 献

- [1] Yahya Z, Imane S, Hicham H, et al. Applied imagery pattern recognition for photovoltaic modules' inspection: a review on methods, challenges and future development [J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102071.
- [2] 段中兴, 张雨明, 马佳豪. 基于改进 YOLOv4 的电力设备红外图像识别[J]. 激光与光电子学进展, 2022, 59(24): 2410002.  
Duan Z X, Zhang Y M, Ma J H. Infrared image recognition of power equipment based on improved YOLOv4[J]. Laser & Optoelectronics Progress, 2022, 59(24): 2410002.
- [3] 顾燕, 李臻, 杨锋, 等. 基于改进 Faster R-CNN 的复杂背景红外车辆检测算法[J]. 激光与红外, 2022, 52(4): 614-619.  
Gu Y, Li Z, Yang F, et al. Infrared vehicle detection algorithm with complex background based on improved Faster R-CNN[J]. Laser & Infrared, 2022, 52(4): 614-619.
- [4] 梅建华, 云利军, 朱小鹏. 基于长短期记忆网络的红外人体步态识别方法研究[J]. 激光与光电子学进展, 2022, 59(8): 0811005.  
Mei J H, Yun L J, Zhu X P. Infrared human gait recognition method based on long and short term memory network[J]. Laser & Optoelectronics Progress, 2022, 59(8): 0811005.
- [5] 何自芬, 陈光晨, 陈俊松, 等. 多尺度特征融合轻量化夜间红外行人实时检测[J]. 中国激光, 2022, 49(17): 1709002.  
He Z F, Chen G C, Chen J S, et al. Multi-scale feature fusion lightweight real-time infrared pedestrian detection at night[J]. Chinese Journal of Lasers, 2022, 49(17): 1709002.
- [6] Haidari P, Hajiahmad A, Jafari A, et al. Deep learning-based model for fault classification in solar modules using infrared images[J]. Sustainable Energy Technologies and Assessments, 2022, 52: 102110.
- [7] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2023-01-06]. <https://arxiv.org/abs/1409.1556>.
- [8] Hwang H P C, Ku C C Y, Chan J C C. Detection of malfunctioning photovoltaic modules based on machine learning algorithms[J]. IEEE Access, 2021, 9: 37210-37219.
- [9] 姜萍, 李梦瑶, 栾艳军. 基于改进 InceptionV3 网络的光伏组件航拍红外图像故障分类方法[J]. 激光杂志, 2022, 43(8): 90-94.  
Jiang P, Li M Y, Luan Y J. Fault classification method of photovoltaic module aerial infrared image based on improved Inceptionv3 network[J]. Laser Journal, 2022, 43(8): 90-94.
- [10] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [11] Alves R H F, de Deus G A, Jr, Marra E G, et al. Automatic fault classification in photovoltaic modules using Convolutional Neural Networks[J]. Renewable Energy, 2021, 179: 502-516.
- [12] 王艳, 申宗旺, 赵洪山, 等. 基于改进 CNN-SVM 的光伏组件红外图像故障诊断方法[J/OL]. 华北电力大学学报(自然科学版): 1-8[2023-03-07]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20220801.1622.004.html>.  
Wang Y, Shen Z W, Zhao H S, et al. Infrared image fault diagnosis method of photovoltaic module based on improved CNN-SVM[J/OL]. Journal of North China Electric Power University (Natural Science Edition): 1-8 [2023-03-07]. <http://kns.cnki.net/kcms/detail/13.1212.TM.20220801.1622.004.html>.
- [13] Le M, Luong V S, Nguyen D K, et al. Remote anomaly detection and classification of solar photovoltaic modules based on deep neural network[J]. Sustainable Energy Technologies and Assessments, 2021, 48: 101545.
- [14] He K M, Zhang X Y, Ren S Q, et al. Identity mappings in deep residual networks[EB/OL]. (2016-03-16)[202301-06]. <https://arxiv.org/abs/1603.05027>.
- [15] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015.
- [16] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 9992-10002.
- [17] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st Annual Conference on Neural Information Processing Systems (NIPS), December 4-9, 2017, Long Beach, CA, USA. Cambridge: JMLR, 2017.
- [18] Millendorf M, Obropta E, Vadhavkar N. Infrared solar module dataset for anomaly detection[EB/OL]. [2023-02-03]. <https://ai4earthscience.github.io/iclr-2020-workshop/papers/ai4earth22.pdf>.
- [19] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [EB/OL]. (2018-07-30)[2023-01-03]. <https://arxiv.org/abs/1807.11164>.
- [20] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [21] Tan M, Le Q V. EfficientNet: rethinking model scaling for convolutional neural networks[EB/OL]. (2019-05-28)[2023-01-02]. <https://arxiv.org/abs/1905.11946>.