

DOI: 10.19650/j.cnki.cjsi.12311969

基于改进 EfficientNet 的红外图像光伏组件故障识别研究*

吕 游¹, 郑 茜², 齐欣宇², 房 方¹, 刘吉臻¹

(1. 华北电力大学新能源电力系统国家重点实验室 北京 102206; 2. 华北电力大学
控制与计算机工程学院 北京 102206)

摘 要:光伏组件的故障会影响光伏阵列的输出性能,从而降低电站的发电效率,严重时甚至会危害电站的安全运行。传统的方法无法满足目前光伏组件故障检测快速性和正确率需求。因此,本文提出了一种基于改进 EfficientNet 的光伏组件故障识别方法。首先,利用采集到的光伏组件红外图像建立故障数据集,并利用图像分割和数据增强对数据集进行预处理;其次,基于 EfficientNet 网络构建故障识别模型,同时在模型中引入双通道注意力模块(CBAM),该模块能够抑制不必要特征的识别,增强模型对空间特征信息的提取能力,进而提高模型的识别准确率;最后,通过对比仿真实验证明模型的有效性和先进性。实验结果表明,该模型的故障识别准确率达到 90.83%,相较于原始的 EfficientNet 模型提高了 2.83%,且模型大小仅为 20.3 M,具有良好的实用性,能够满足光伏电站实际应用的需求。

关键词:光伏组件;红外图像;故障识别;CBAM 注意力机制

中图分类号: TH17 TM315 **文献标识码:** A **国家标准学科分类代码:** 470.40

A study on fault recognition of photovoltaic module with infrared images based on improved efficientnet

Lyu You¹, Zheng Xi², Qi Xinyu², Fang Fang¹, Liu Jizhen¹

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: Failures of the photovoltaic (PV) module can affect the performance of the PV arrays, thus reducing the power generation efficiency. In serious cases, PV module failures may even jeopardize the safe operation of the power plant. Traditional methods cannot meet the current demand for fast and correct PV module fault detection. Therefore, this paper proposes a PV module fault identification method based on the improved EfficientNet algorithm. First, the collected infrared images of PV modules are utilized to establish a fault dataset, which is then preprocessed by using image segmentation and data enhancement technology. Second, a fault recognition model is constructed based on the EfficientNet network. Meanwhile, a dual-channel convolutional block attention module (CBAM) is introduced into the model, which can inhibit the recognition of unnecessary features and enhance the ability to extract spatial feature information, thus improving the recognition accuracy. Finally, comparative simulation experiments are conducted to validate the effectiveness and advancement of the proposed model. The experimental results show that the fault recognition accuracy of the model reaches 90.83%, which is 2.83% higher than that of the original EfficientNet model; in addition, the model size is only 20.3 M, which shows good practicability and can meet the requirements of practical application of PV power plants.

Keywords: photovoltaic (PV) module; infrared image; image recognition; convolutional block attention module (CBAM)

0 引 言

为了加快规划建设新型能源体系,以风电、光伏发电为主的新能源成为电力供应主体。其中,光伏电站主要分布在以沙漠、戈壁、荒漠等太阳辐射资源丰富的地区^[1-3]。光伏组件长时间暴露在恶劣的环境中,易引发热斑、二极管失效故障等,不但影响光伏电站的输出效率,还有可能造成光伏组件过热甚至引发火灾等灾害^[4-5]。因此,如何高效且准确的识别光伏组件的故障情况,对光伏电站的安全高效运行具有重要意义。

目前,国内外学者针对光伏组件的故障识别开展了一系列研究工作,其主流方法是利用光伏组件的电压、电流等电气参数的输出特性来检测故障信息^[6-7]。例如,文献[8-9]基于光伏组件的输出电压及电流特性,通过参数辨识计算故障量化指标实现故障识别,但该方法需要大量的传感器支持,在实际应用中运维成本过于高昂;文献[10]考虑了光伏阵列的输出电压,通过计算故障因子评价电压的波动,以此进行故障的检测,但目前只能针对目标电站建立故障因子,方法的泛用性较差;文献[11]提出利用数学形态学对限电异常数据进行自适应分析来识别故障信息,其识别过程依赖传感器的测量精度,但测量精度受到环境噪声的影响,部分光伏电站所处的环境难以满足要求。从上述研究可知,利用电气参数特性的故障识别方法需要大量数据采集设备的支撑,且存在检测成本高、环境噪声影响大等缺点,难以有效应用在实际光伏电站的生产现场。

光伏组件表面温度信息是发电过程中最重要的参数之一,与电气参数相比,温度的变化更直接的体现了光伏组件的运行状态^[12]。因此,基于红外图像实现故障诊断的方法因其高效、低成本的特点,逐渐在光伏故障诊断领域得到研究^[13]。文献[14]通过提取光伏组件的红外图像温度信息实现故障的识别,该方法利用手持热像仪得到红外图像信息,但检测精度有待提高。随着人工智能技术的发展,有研究利用深度神经网络等方法来提取红外图像信息并实现故障检测。文献[15]利用无人机航拍的红外图像作为故障识别的对象,通过深度卷积网络提取高级特征,实现光伏组件的故障识别;文献[16]通过分析光伏组件图像与发电效率损失率的关系,以深度残差网络(residual network, ResNet)来辨识光伏组件的故障信息;文献[17]采用卷积神经网络作为故障分类模型的框架,引入宽度因子优化网络结构,以实现光伏组件的故障识别。为提高分类准确率,文献[18]提出将神经网络和智能分类器相结合,利用神经网络对光伏组件的红外热成像进行

分割,再采用决策树算法进行故障分类;文献[19-20]提出了一种包含图像采集、分割、故障定位和缺陷预警组成的新框架,利用深度卷积网络进行图像处理,并最终实现光伏组件故障的识别。上述故障识别方法利用的都是传统深度学习网络,网络只是通过改进模型的宽度或者深度实现故障识别模型的优化,且对于光伏故障图像中的空间像素信息重视程度不高,导致光伏故障识别的准确率不高,检测的速度较慢,无法满足光伏电站实际应用的需求。

鉴于此,本文提出一种基于 EfficientNet-CBAM 的光伏故障识别方法。首先利用巡检拍摄到的红外图像建立数据集,采用 EfficientNet 网络作为故障识别模型的框架,从网络的高度、宽度和分辨率 3 个方向优化光伏故障识别模型的结构,同时引入 CBAM 注意力机制,增强模型对像素信息的关注程度,提高模型的训练效果。最后,基于混淆矩阵评价指标,与其他图像分类和检测方法进行了分析对比。结果表明,本文提出的方法具有更高的准确度,同时具有较快的检测速度,能够有效地实现光伏组件的故障识别。

1 光伏组件故障数据集

本研究共收集 14 998 张光伏阵列红外图像,共覆盖 120 m² 光伏阵列,每张图片的分辨率为 640×512,故障类型包含热斑故障、二极管故障、整串故障、阴影遮挡和大面积热斑故障,如图 1 所示。




图 1 光伏组件红外图像

Fig. 1 Photovoltaic module infrared image

在数据预处理阶段,为了消除环境对故障识别模型的影响,基于 U²-Net 语义分割模型对采集到的光伏阵列图像进行深度学习训练^[21],实现快速识别光伏阵列与背景区域,将光伏阵列从红外图像中分割出来。其次,考虑到部分故障现象发生的概率较低,无法采集到充足的图像数据,利用几何变换的方法扩充故障样本^[22],采用的方式主要包括上下翻转、随机旋转、左右平移以及随机缩放。最终,经过处理后的样本集数量共 1 200 张,其中正常样本和每类故障样本均为 200 张。

2 EfficientNet 网络介绍

2.1 网络构建原理

EfficientNet 是一个利用神经网络搜索技术结合模型缩放方法的新型卷积神经网络^[23],可以对光伏组件红外图像实现更高效率的故障识别。相比于传统卷积神经网络,EfficientNet 能够平衡网络的深度、宽度、输入分辨率之间的关系,复合缩放可以提取红外图像中更复杂、更高细粒度的特征,从而利用较少的参数量提高网络的性能。

对于卷积网络的运算,模型可以抽象成:

$$N = F_k \odot \dots \odot F_2 \odot F_1(X) = \bigodot_{j=1,2,\dots,k} F_j(X) \quad (1)$$

式中: $\odot$ 表示连乘运算, k 表示网络的层数, F_j 表示第 j 层的运算操作, X 表示光伏组件红外图像输入的特征。

在建立模型时,考虑到光伏组件信息模糊、图像噪声分布不均匀等特性,卷积层采用堆叠多个相同的网络模块来提高网络对图像的特征提取能力,具体表示为:

$$N_c = \bigodot_{i=1,\dots,s} F_i^{L_i}(X_{[H_i, W_i, C_i]}) \quad (2)$$

式中: s 表示需要重复堆叠的网络层个数, F_i 表示第 i 层的运算操作, L_i 表示第 i 层的运算重复执行的次数, $[H_i, W_i, C_i]$ 表示第 i 层的输入特征矩阵的高度、宽度和通道数。

传统卷积神经网络一般只针对模型的深度或宽度进行优化,忽略了光伏图像的空间像素信息,EfficientNet 能够同时改变网络的宽度、深度和输入分辨率,从而优化卷积层的网络结构,综合考虑寻找最优解,具体优化的数学模型如下所示:

$$\begin{aligned} \max_{d,w,r} \text{Accuracy}(N(d,w,r)) \\ \text{s. t. } N(d,w,r) = \bigodot_{i=1,2,\dots,s} \widehat{F}_i^{d \cdot \widehat{L}_i}(X_{[r \cdot \widehat{H}_i, r \cdot \widehat{W}_i, w \cdot \widehat{C}_i]}) \quad (3) \end{aligned}$$

$$\text{Memory}(N) \leq \text{TM}$$

$$\text{Flops}(N) \leq \text{TF}$$

式中:Accuracy 表示模型的准确率, $\widehat{F}_i$ 、 $\widehat{L}_i$ 、 $\widehat{H}_i$ 、 $\widehat{W}_i$ 、 $\widehat{C}_i$ 表示基线网络中的预定义参数, d, w, r 分别表示网络的深度、宽度和输入分辨率缩放系数,Memory 表示模型计算力,Flops 表示模型参数,TM 表示目标模型计算力,TF 表示目标模型参数。

为了追求更好的准确性和效率,EfficientNet 通过复合缩放系数 ϕ 统一优化网络的 d, w, r ,如下所示:

$$\begin{aligned} \max_{d,w,r} \text{Accuracy}(N(d,w,r)) \\ d = \alpha^\phi \\ w = \beta^\phi \\ r = \gamma^\phi \\ \text{s. t. } \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \\ \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{aligned} \quad (4)$$

式中: α, β, γ 分别决定网络的宽度、深度和图像分辨率的缩放比例。

2.2 模型结构

按照 2.1 节中网络搜索得到的缩放比例,就可以确定网络模型的基本结构。如图 2 所示,网络的结构主要包含 Stage1 ~ Stage9 共 9 层。其中,Stage1 为升维卷积层,该层采用卷积操作对红外图像的输入特征矩阵进行升维。Stage2 ~ Stage8 主要采用一系列重复堆叠的 MBConv 进行特征提取,其中 MBConv 主要包括一个升维卷积层,一个深度可分离卷积层,一个 SE 注意力模块以及一个降维卷积模块。Stage9 为输出层,由一个降维卷积层、平均池化层和全连接层组成。最终,模型将输出通道值表征光伏组件故障的类别。




图2 EfficientNet 网络模型

Fig. 2 EfficientNet network model

Stage 1 升维卷积层运算如下所示:

$$F_1(X) = g_u(X_{[r \cdot H_1, r \cdot W_1, w \cdot C_1]}) \quad (5)$$

$$g_u(x_c) = f(x_c * k_u + b_u) \quad (6)$$

式中: g_u 表示升维卷积操作, x_c 表示第 c 个通道的输入矩阵, $X = [x_1, x_2, \dots, x_c]$, f 表示卷积激活函数,*表示卷积运算, k_u 表示升维卷积核的权重, b_u 表示升维卷积的偏移量。

Stage2~Stage8 中 MBConv 的运算如下所示:

$$F_i(X) = g_d \odot g_{se} \odot g_w \odot g_u(X_{[r \cdot H_i, r \cdot W_i, w \cdot C_i]}) \quad (7)$$

$$g_d(x_c) = f(x_c * k_d + b_d) \quad (8)$$

$$z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (9)$$

$$s = f_1(W_2(f_2(W_1 z))) \quad (10)$$

$$g_{se}(x_c) = s_c \cdot x_c \quad (11)$$

$$g_w(x_c) = f_{dw}(f_{pw}(x_c)) \quad (12)$$

式中: F_i 表示第 i 层的 MBConv 操作, i 的取值范围为 $[2, 3, \dots, 8]$, g_d 表示降维卷积操作, g_{se} 表示注意力机制运算操作, g_w 表示深度可分离卷积操作, k_d 表示降维卷积核的权重, b_d 表示降维卷积的偏移量, $z \in \mathbb{R}^C$ 表示通道平均池化中间向量, $z = [z_1, z_2, \dots, z_c]^T$, $s \in \mathbb{R}^C$ 表示通道平均池化权重向量, $s = [s_1, s_2, \dots, s_c]^T$, W_1 和 W_2 分别

表示注意力模块中第一次和第二次全连接的权重, $\mathbf{W}_1 \in \mathbb{R}^{C/h \times C}$, $\mathbf{W}_2 \in \mathbb{R}^{C \times C/h}$, h 为注意力模块中全连接缩放系数, f_1 和 f_2 分别表示第一次和第二次全连接激活函数, f_{dw} 和 f_{pw} 分别表示逐点卷积和逐通道卷积操作。

Stage9 输出层运算如下所示:

$$F_9(\mathbf{X}) = g_c \odot g_p \odot g_d(\mathbf{X}_{[r, H_9, r, W_9, w, C_9]}) \quad (13)$$

$$g_p(\mathbf{x}_c) = f(\boldsymbol{\eta} * \boldsymbol{\lambda}(\mathbf{x}_c) + \mathbf{b}_p) \quad (14)$$

$$g_c(\mathbf{x}_c) = f(\mathbf{W}^T \mathbf{x}_c + \mathbf{b}_c) \quad (15)$$

式中: g_p 表示池化层操作, $\boldsymbol{\eta}$ 表示池化权重, $\boldsymbol{\lambda}$ 表示池化方式, $\mathbf{b}_p$ 表示池化层的偏移量, g_c 表示全连接层操作, $\mathbf{W}$ 表示输出层全连接权重, $\mathbf{b}_c$ 表示全连接偏移量。

3 CBAM 注意力机制

EfficientNet 网络主要通过 MBConv 模块堆叠而成, 每个 MBConv 模块都含有 SE 注意力模块, 用于提高模型对重要通道的关注能力。然而, 面对光伏组件运行过程中出现的故障情况, SE 模块只考虑到通道上的特征信息, 无法捕捉红外故障图像中的空间信息, 使得模型对光伏组件故障的识别精度受到影响。因此, 为了提高模型对光伏故障红外图像中像素空间特征的提取能力, 本文在 MBConv 中使用 CBAM 模块替代 SE 模块。

CBAM 是一种轻量级注意力模块^[24], 相较于原有的 SE 注意力模块只关注通道信息, CBAM 能够结合通道与空间两个维度增强注意力机制效果。如图 3 所示, CBAM 包含通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)两个子模块, 分别负责通道和空间上的注意力功能, 其计算过程为:

$$g_{cbam}(\mathbf{X}) = g_{sa}(g_{ca}(\mathbf{X})) \quad (16)$$

式中: g_{sa} 表示空间注意力模块运算, g_{ca} 表示通道注意力模块运算。




图3 CBAM 注意力模块

Fig. 3 CBAM Attention Module

通道注意力模块如图 4 所示, 若输入的特征矩阵高度为 H , 宽度为 W , 特征通道数为 C , 通道注意力模块在空间维度上对通道分别进行全局最大池化与平均池化, 两个输出后的向量经过全连接网络 MLP 求和, 最终使用 sigmoid 函数将合并后的向量映射到区间 $[0, 1]$ 内。




图4 通道注意力模块

Fig. 4 Channel Attention Module

通道注意力模块主要关注通道上的重要信息, 通过同时采用平均池化和最大池化聚合特征图的空间信息, 从而针对特征图在空间维度上进行压缩, 其注意力表达机制可以表示为:

$$z'_c = \max_{i=1,2,\dots,H} (x_c(i, j)) \quad (17)$$

$$s' = \sigma(W'_2(W'_1(z')) + W'_2(W'_1(z')) \quad (18)$$

$$g_{ca}(\mathbf{x}_c) = s'_c \cdot \mathbf{x}_c \quad (19)$$

式中: σ 表示 sigmoid 激活函数, W'_1 和 W'_2 表示 CAM 中第一次和第二次多层感知器权重, $W'_1 \in \mathbb{R}^{C/h \times C}$, $W'_2 \in \mathbb{R}^{C \times C/h}$, h 为注意力模块中全连接缩放系数, z' 表示 CAM 通道最大池化中间向量, $z' = [z'_1, z'_2, \dots, z'_C]^T$, s' 表示 CAM 通道特征权重向量, $s' = [s'_1, s'_2, \dots, s'_C]^T$ 表示 CAM 通道注意力权重向量。

空间注意力模块如图 5 所示, 空间注意力模块主要是对空间分别进行平均池化与全局最大池化, 得到两个单通道的池化特征图, 并利用 7×7 、卷积核个数为 1 的卷积降维成一个单通道的特征图, 最终使用 sigmoid 函数将合并后的向量映射到区间 $[0, 1]$ 内。




图5 空间注意力模块

Fig. 5 Spatial Attention Module

空间注意力模块主要关注空间上的重要信息, 在维度通道分别采用平均池化和最大池化聚合信息, 从而针对特征图在维度维度上进行压缩, 其注意力表达机制可以表示为:

$$n_{H,W} = \frac{1}{C} \sum_{i=1}^C x_{H,W,i} \quad (20)$$

$$n'_{H,W} = \max_{i=1,2,\dots,C} (x_{H,W,i}) \quad (21)$$

$$\mathbf{m} = \sigma(f([n; n'] * \mathbf{k}_{7 \times 7} + \mathbf{b}_m)) \quad (22)$$

$$g_{sa}(\mathbf{x}_{H,W}) = \mathbf{m}_{H,W} \cdot \mathbf{x}_{H,W} \quad (23)$$

式中: $\mathbf{x}_{H,W} \in \mathbb{R}^C$ 表示 $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$ 第 H 行第 W 列的输入

特征向量,也即 $\mathbf{x}_{H,W} = [x_{H,W,1}, x_{H,W,2}, \dots, x_{H,W,C}]^T$; $\mathbf{n} \in \mathbb{R}^{H \times W}$ 表示 SAM 中空间平均池化中间向量, $n_{i,j}$ 是 $\mathbf{n}$ 中的元素; $\mathbf{n}' \in \mathbb{R}^{H \times W}$ 表示 SAM 中空间最大池化中间向量, $n'_{i,j}$ 是 $\mathbf{n}'$ 中的元素; $\mathbf{m} \in \mathbb{R}^{H \times W}$ 表示 SAM 中空间特征权重向量, $m_{i,j}$ 是 $\mathbf{m}$ 中的元素, $\mathbf{k}_{7 \times 7}$ 表示卷积核大小为 7×7 的权重, $\mathbf{b}_m$ 表示空间卷积的偏移量。

4 光伏组件故障识别模型构建

本文基于改进的 EfficientNet 网络构建光伏组件故障识别模型,如图 6 所示。模型以 EfficientNet 网络为整体框架,引入注意力机制,将 MBConv 模块中的 SE 注意力模块替换成 CBAM 模块,并在降维卷积后再次添加 CBAM 模块,提高模型对空间特征上的关注度。




图 6 光伏组件故障识别模型

Fig. 6 Fault identification model of photovoltaic module

基于上述提出的光伏故障识别模型,本文对红外图像光伏组件故障识别的流程如图 7 所示,具体步骤如下:

S1:采集光伏组件故障红外图像;

S2:采用 U²-Net 语义分割模型进行图像分割,从红外图像中提取光伏阵列,并采用几何变换方法扩充样本数据集;

S3:将样本集分成训练集与测试集,并对不同故障类

别打上标签,使用数据增强扩充样本数量;

S4:利用式(5)~(23)对 EfficientNet-CBAM 网络进行训练;

S5:建立光伏组件故障识别模型;

S6:输出故障识别结果。




图 7 光伏故障识别流程图

Fig. 7 Photovoltaic fault identification flowchart

5 实验及结果分析

5.1 混淆矩阵评价指标

为了全面合理的评价模型识别精度,本节采取基于混淆矩阵多指标评价体系,主要定义了准确率 (accuracy, Acc)、精确率 (precision, Pre) 和召回率 (recall, Rec) 来定量评价光伏组件故障识别的性能,其计算方式如下:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (24)$$

$$Pre = \frac{TP}{TP + FP} \quad (25)$$

$$Rec = \frac{TP}{TP + FN} \quad (26)$$

式中: TP 为待测图像判定成正类且分类模型预测为正类; FN 为待测图像判定成正类但分类模型预测为负类; FP 为待测图像判定成负类但分类模型预测为正类; TN 为待测图像判定成负类且分类模型预测为负类。

5.2 模型参数确定

EfficientNet 网络采用了模型缩放方法优化网络结构,基于典型的网格法确定缩放系数,对应的将 EfficientNet 网络分成 b0~b7 共 8 个预训练模型,不同的预训练模型有着不同的网络结构,对于光伏组件故障识别网络的训练效果也不一样。考虑到故障识别精度的要求以及模型的参数量,利用采集的数据集对预训练模型进行对比实验,结果如下表 1 所示。综合考虑模型大小与故障分类的准确率,最终采用 EfficientNet-b0 作为基础网络结构,其网络参数为:输入分辨率设置为 $224 \times 224 \times 3$, $\alpha = 1.2$ 、 $\beta = 1.1$ 、 $\gamma = 1.15$ 、 $\phi = 1$,同时模型初始学习率设置为 10^{-3} ,迭代次数设置为 200,每次训练样本输入数量设置为 4。

表 1 预训练模型对比

Table 1 Comparison of pre-training models

模型网络	输入尺寸	模型大小/MB	准确率/%
EfficientNet-b0-CBAM	$224 \times 224 \times 3$	16.4	88.33
EfficientNet-b1-CBAM	$224 \times 224 \times 3$	30.0	87.50
EfficientNet-b2-CBAM	$224 \times 224 \times 3$	35.0	88.33
EfficientNet-b3-CBAM	$224 \times 224 \times 3$	47.1	85.83
EfficientNet-b4-CBAM	$224 \times 224 \times 3$	74.3	87.50
EfficientNet-b5-CBAM	$224 \times 224 \times 3$	116.0	87.50
EfficientNet-b6-CBAM	$224 \times 224 \times 3$	165.0	84.17
EfficientNet-b7-CBAM	$224 \times 224 \times 3$	254.0	85.27

5.3 结果分析及对比

本次实验使用的电脑参数配置为:Window 系统,i5-9300H CPU@ 2.40 GHz,NVIDIA GeForce RTX1660Ti。

为验证 EfficientNet-CBAM 模型的有效性,本文对比了模型与其他传统图像诊断模型在训练集上的准确率和损失值,曲线结果如图 8 和 9 所示。可以看出,VGGNet 模型在第 30 次迭代后达到稳定,准确率达到 85%左右,模型的训练效果表现不佳,得到的准确率最低且损失函数最大。ResNet 和 Inceptionv1 模型相较于 VGGNet 模型,虽然准确率得到提高,最终迭代的损失值也有所降低,但模型整体优势不明显。而 EfficientNet 模型性能优于其他对比模型,且在第 25 次迭代后就达到稳定,但它的性能仍然不是最优的。EfficientNet-CBAM 迭代的最终分类准确率最高,达到了 90%左右,模型迭代最终损失值最小,迭代到 20 次左右就达到稳定,训练效果与其它模型相比更加优秀,且具有更好的稳定性。

为了验证 EfficientNet-CBAM 模型在综合性能方面的提升,本文与其他分类模型——对比了模型大小、运行时间和准确率。如下表 2 所示,与 VGGNet 模型相比,




图 8 模型准确率迭代曲线对比图

Fig. 8 Comparison Chart of Model Accuracy Iteration Curves




图 9 模型损失值迭代曲线对比图

Fig. 9 Comparison Chart of Model Loss Value Iteration Curves

EfficientNet-CBAM 识别准确率提高了 14.72%,模型大小减少了 93.45%,运算时间减少了 55.28%,与 ResNet 相比,准确率提高了 11.21%,模型大小减少了 90.89%,运算时间减少了 45.77%,与 Inceptionv1 相比,准确率提高了 5.01%,模型大小减少了 80.29%,运算时间减少了 10.76%,可以看出,EfficientNet-CBAM 模型无论在识别准确率、模型大小或运行时间上都有着较好的表现。而相比于改进前的 EfficientNet 模型,虽然模型大小提高了,但运行时间却有所下降,准确率也优于 EfficientNet。整体来看,EfficientNet-CBAM 在性能都优于其他模型。

表 2 模型性能对比

Table 2 PV module fault data set

模型	模型大小/MB	运行时间/ms	准确率/%
VGGNet	310	445	84.17
ResNet	223	367	85.83
Inceptionv1	103	223	86.87
EfficientNet	15.6	207	88.33
EfficientNet-CBAM	20.3	199	90.83

为了进一步验证模型对不同情况识别对象的识别效果,将依据本文提出的混淆矩阵评价指标,对各模型在测试样本上的混淆矩阵进行对比,结果如图 10 所示。

可以看出,所有模型在整串故障与大面积热斑故障均能正确判断,对这两类故障情况具有很强的识别能力。而对于其他几类样本中的故障,VGGNet 模型对于正常




图 10 各模型混淆矩阵热力图

Fig. 10 Thermal diagram of each model confusion matrix

样本的检测准确率不高,仅能达到 50% 的准确率;ResNet、Inceptionv1 和 EfficientNet 模型在热斑故障和阴影遮挡两类样本的故障识别中表现不佳,而本文提出的 EfficientNet-CBAM 模型明显优于其他模型。

各模型混淆矩阵指标的具体数值如表 3 所示,可以看出 EfficientNet-CBAM 表现出了优秀的分类性能。对于六类数据样本,模型的识别准确率最高达到 90.83%,精准率可以达到 90.93%,召回率达到 90.83%。相较于改进前的 EfficientNet 模型,改进后的模型准确度提高了 2.83%、精确度提高了 2.23%、召回率提高了 2.83%;相较于其他传统图像诊断模型,准确率提高了 3%~6.6%,精确率提高了 2.6%~5%,召回率提高了 4%~6.6%。

表 3 混淆矩阵指标

Table 3 Confusion matrix indicator

模型	准确率/%	精确率/%	召回率/%
VGGNet	84.17	85.80	84.17
ResNet	85.83	86.59	85.83
Inceptionv1	86.87	88.28	86.87
EfficientNet	88.33	88.94	88.33
EfficientNet-CBAM	90.83	90.93	90.83

模型在训练集中表现的准确率、损失值和运行时间,测试集中表现的准确率、精确率、召回率都优于其他 4 种模型,能够很好地完成故障分类工作。

6 模型实验验证

本文基于某光伏电站建立实验系统来验证模型的有效性。实验系统包括图像采集、图像处理、模型诊断三个模块,结构如图 11 所示。




图 11 实验系统结构

Fig. 11 Experimental system structure

其中,图像采集模块包括大疆 M300 型号无人机和禅思 XT2 双光热成像相机,通过集成高精度热成像传感器和 4K 可见光传感器进行图像的拍摄。实验设定无人机飞行速度 6 m/s、高度 30 m、云台俯仰角为-45°;航点

综合以上 3 项分析,本文提出的 EfficientNet-CBAM

动作根据飞行方案选择开始等距间隔拍照,拍照间隔设为 12 m。采集了光伏组件的 6 种运行状态模式,分类标号分别为二极管故障Ⅰ,热斑故障Ⅱ,正常Ⅲ,整串故障Ⅳ,大面积热斑故障Ⅴ,阴影遮挡Ⅵ。

图像处理模块中,采用 U²-Net 语义分割模型实现对采集图像的分割,将图像分割提取后共得到 568 张有效图像,其中二极管故障图像 65 张,热斑故障图像 122 张,正常图像 70 张,整串故障图像 122 张,大面积热斑故障图像 124 张,阴影遮挡图像 65 张。将上述图像输入至本研究提出的 EfficientNet-CBAM 模型中诊断分析,计算结果分别如表 4 和图 12 所示。对于六类图像样本,模型的识别准确率可以达到 90.49%,精准率可以达到 88.86%,召回率达到 88.71%;其中大面积热斑故障准确率可达 100%,正常和整串故障的准确率都超过 98%,二极管故障、热斑故障和阴影遮挡的准确率都超过 93%。

表 4 电厂光伏组件故障的检测结果

Table 4 The results of PV module faults in power plants				
故障分类	样本数量	准确率/%	精确率/%	召回率/%
I	65	95.77	79.71	84.62
II	122	94.89	89.08	86.89
III	70	98.23	98.39	87.14
IV	122	98.77	97.52	96.72
V	124	100.00	100.00	100.00
VI	65	93.31	68.49	76.92
整体	568	90.49	88.86	88.71



图 12 检测结果混淆矩阵热力图

Fig. 12 Thermal diagram of detection result confusion matrix

相较仿真环境,模型对光伏组件故障识别的准确率稍有下降,主要是因为光伏电站在采集红外图像的过程中,易受地面环境和天气干扰,对检测结果产生影响,但整体结果基本满足实际工业要求。

7 结 论

本文提出了一种基于 EfficientNet-CBAM 的光伏红外图像故障识别方法,通过实验对比分析得到以下结论:

- 1) 本文针对采集到的光伏红外图像数据,采用图像分割提取光伏阵列,有效的解决环境对模型训练的干扰问题。其次,利用数据增强对样本进行预处理,扩充稀缺样本的数量,提高模型的识别准确率。
- 2) 本文采用 EfficientNet 作为光伏红外图像故障识别模型的框架,通过引入 CBAM 注意力机制,优化模型中 MBConv 模块的结构,从通道与空间两个维度提取光伏红外图像上的有效特征信息,抑制其他无效信息,进而改善模型的泛化能力,提高了模型识别的精度。
- 3) 通过仿真对比实验得出,本文提出的方法相比于原始的 EfficientNet 网络,其准确率提高了 2.83%,收敛速度更快。同时与其他传统深度学习模型相比,该改进模型拥有明显的轻量化优势,模型的识别准确率达到 90.83%,模型大小仅为 20.3 M,且识别故障所需要的运行时间较其他常用模型缩短 10%~50%,具有一定的优越性与良好的实用性。本模型有望在光伏电站的故障分类领域得到广泛应用。

参考文献

[1] 王欢,徐小力. 一种新型光伏阵列在线故障检测方法研究[J]. 仪器仪表学报, 2015, 36(12): 2765-2772.
WANG H, XU X L. Research on an online fault detection method for photovoltaic array [J]. Chinese Journal of Scientific Instrument, 2015, 36(12): 2765-2772.

[2] 余荣斌,刘桂雄,徐欢. 基于 β 分布统计法的光伏组件性能退化可靠度估算[J]. 仪器仪表学报, 2015, 36(11): 2586-2593.
YU R, LIU G X, XU H. β -distribution uniform expression based photovoltaic modules reliability evaluation with degradation data distribution [J]. Chinese Journal of Scientific Instrument, 2015, 36(11): 2586-2593.

[3] 隋欣,魏毅,罗小林,等. 面向“双碳”目标的脆弱区域生态光伏模式研究[J]. 太阳能学报, 2022, 43(7): 56-63.
SUI X, WEI Y, LUO X L, et al. Research on ecological photovoltaic model in vulnerable regions for “two-carbon” objective [J]. Acta Energiæ Solaris Sinica, 2022, 43(7): 56-63.

- [4] 钱晓亮, 张鹤庆, 张焕龙, 等. 基于视觉显著性的太阳能电池片表面缺陷检测[J]. 仪器仪表学报, 2017, 38(7): 1570-1578.
- QIAN X L, ZHANG H Q, ZHANG H L, et al. Solar cell surface defect detection based on visual saliency[J]. Chinese Journal of Scientific Instrument, 2017, 38(7): 1570-1578.
- [5] 丁明, 王伟胜, 王秀丽, 等. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 2014, 34(1): 1-14.
- DING M, WANG W SH, WANG X L, et al. Review on the impact of large-scale photovoltaic power generation on power system[J]. Proceedings of the CSEE, 2014, 34(1): 1-14.
- [6] 张英, 麦耀华, 李国斌, 等. 薄膜硅光伏组件的漏电通道模型及绝缘电阻的定量测试[J]. 仪器仪表学报, 2012, 33(11): 2454-2459.
- ZHANG Y, MAI Y H, LI G B, et al. Electric leakage path model and insulation resistance quantitative measurement for thin film silicon solar module[J]. Chinese Journal of Scientific Instrument, 2012, 33(11): 2454-2459.
- [7] 杜博伦, 何赞泽, 杨瑞珍, 等. 电磁感应对硅光伏电池可视化检测技术的改性[J]. 仪器仪表学报, 2018, 39(10): 158-165.
- DU B L, HE Y Z, YANG R ZH, et al. Modification of visual detection for silicon photovoltaic cells based on electromagnetic induction[J]. Chinese Journal of Scientific Instrument, 2018, 39(10): 158-165.
- [8] 李智华, 马浩强, 吴春华, 等. 基于三参数的光伏组件老化程度诊断[J]. 中国电机工程学报, 2022, 42(9): 3327-3338.
- LI ZH H, MA H Q, WU CH H, et al. Aging degree diagnosis of photovoltaic modules based on three parameters[J]. Proceedings of the CSEE, 2022, 42(9): 3327-3338.
- [9] SPATARU S, SERA D, KEREKES T, et al. Diagnostic method for photovoltaic systems based on light I-V measurements[J]. Solar Energy, 2015, 119: 29-44.
- [10] 马铭遥, 王海松, 马文婷, 等. 基于 S-V 特性分析的晶硅光伏组件阴影遮挡故障诊断[J]. 太阳能学报, 2022, 43(9): 64-72.
- MA M Y, WANG H S, MA W T, et al. Shadow shielding fault diagnosis of crystalline silicon photovoltaic modules based on S-V characteristics analysis[J]. Acta Energiae Solaris Sinica, 2022, 43(9): 64-72.
- [11] 郝颖, 冬雷, 王丽婕, 等. 基于数学形态学去噪的光伏发电限电异常数据识别算法[J]. 中国电机工程学报, 2022, 42(21): 7843-7855.
- HAO Y, DONG L, WANG L J, et al. Power limiting anomaly data recognition algorithm for photovoltaic power generation based on mathematical morphology denoising[J]. Proceedings of the CSEE, 2022, 42(21): 7843-7855.
- [12] 郑秀, 赵乙凡, 陈可, 等. 基于能量平衡法的光伏组件瞬态温度场预测[J]. 中国电机工程学报, 2022, 42(13): 4907-4915.
- ZHENG X, ZHAO Y F, CHEN K, et al. Transient temperature field prediction of photovoltaic modules based on energy balance method[J]. Proceedings of the CSEE, 2022, 42(13): 4907-4915.
- [13] MELLIT A, TINA G, KALOHIROU S. Fault detection and diagnosis methods for photovoltaic systems: A review[J]. Renewable and Sustainable Energy Reviews, 2018, 91: 1-17.
- [14] 王培珍, 郑诗程. 基于红外图像的太阳能光伏阵列故障分析[J]. 太阳能学报, 2010, 31(2): 197-202.
- WANG P ZH, ZHENG SH CH. Fault analysis of solar photovoltaic array based on infrared image[J]. Chinese Journal of Solar Energy, 2010, 31(2): 197-202.
- [15] VENKATESH S N, SUGUMARAN V. Fault Detection in aerial images of photovoltaic modules based on Deep learning[C]. IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2021, 1012(1): 012030.
- [16] 赵波, 廖坤, 邓春宇, 等. 基于卷积神经学习的光伏板积灰状态识别与分析[J]. 中国电机工程学报, 2019, 39(23): 6981-6989, 7111.
- ZHAO B, LIAO K, DENG CH Y, et al. Recognition and analysis of photovoltaic panel ash accumulation state based on convolutional neural learning[J]. Proceedings of the CSEE, 2019, 39(23): 6981-6989, 7111.
- [17] 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 for aerial infrared images of photovoltaic modules based on improved InceptionV3 network [J]. Laser Journal, 2022, 43(8): 90-94.
- [18] WANG X, YANG W, QIN B, et al. Intelligent monitoring of photovoltaic panels based on infrared detection[J]. Energy Reports, 2022, 8: 5005-5015.
- [19] HONG F, SONG J, MENG H, et al. A novel framework on intelligent detection for module defects of PV plant combining the visible and infrared images [J]. Solar Energy, 2022, 236: 406-416.
- [20] 夏杰锋, 唐武勤, 杨强. 光伏航拍红外图像的热斑自动检测方法[J]. 浙江大学学报(工学版), 2022, 56(8): 1640-1647.
- XIA J F, TANG W Q, YANG Q. Automatic detection of hot spots in photovoltaic aerial infrared images [J]. Journal of Zhejiang University (Engineering Science), 2022, 56(8): 1640-1647.
- [21] 王盛, 吴浩, 彭宁, 等. 改进 U²-Net 的太阳能电池片缺陷分割方法[J]. 国外电子测量技术, 2023, 42(2): 177-184.
- WANG SH, WU H, PENG N, et al. Improved U2-Net defect segmentation method for solar cells [J]. Foreign Electronic Measurement Technology, 2023, 42(2): 177-184.
- [22] 柳扬, 陈美珍, 徐胜彬, 等. 基于热成像与灰度转换技术的光伏阵列缺陷检测方法[J]. 电子测量技术, 2021, 44(11): 96-102.
- LIU Y, CHEN M ZH, XU SH B, et al. Defect detection method of photovoltaic array based on thermal imaging and gray conversion technology [J]. Electronic Measurement Technology, 2021, 44(11): 96-102.
- [23] 罗洪伟, 刘波, 姚虎, 等. 基于改进 EfficientNet 的轻量化性别与年龄段估计算法[J]. 传感器与微系统, 2023, 42(11): 114-118.
- LUO H W, LIU B, YAO H, et al. Lightweight gender and age estimation algorithm based on improved Efficient Net [J]. Transducer and Microsystem Technologies, 2023, 42(11): 114-118.
- [24] 樊涛, 孙涛, 刘虎. 基于注意力机制的光伏组件热斑检测算法[J]. 北京航空航天大学学报, 2022, 48(7): 1304-1313.
- FAN T, SUN T, LIU H. Hot spot detection algorithm of photovoltaic modules based on attention mechanism [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(7): 1304-1313.

作者简介



吕游 (通信作者), 2009 年于华北电力大学获得学士学位, 2014 年于华北电力大学获得博士学位, 现为华北电力大学副教授, 主要研究方向为能源系统建模、优化及设备状态监测方法。

E-mail: you.lv@ncepu.edu.cn

Lyu You (Corresponding author) received his B.Sc. degree from North China Electric Power University in 2009, and received his Ph.D. degree from North China Electric Power University in 2014. He is currently an associate professor at NCEPU. His main research interests include energy system modeling, optimization, and condition monitoring methods.