

基于卷积神经网络算法的光伏组件热斑图像检测方法研究

张绘敏¹, 赵扬², 康会峰³

(1. 河南应用技术职业学院 机电工程学院, 郑州 450042;

2. 河南应用技术职业学院 化学工程学院, 郑州 450042;

3. 北华航天工业学院 航空宇航学院, 河北 廊坊 065000)

摘要: 热斑效应是造成光伏组件损坏的主要原因之一, 为提早发现光伏组件热斑效应, 利用卷积神经网络算法优化设计光伏组件热斑图像检测方法; 根据光伏组件的工作原理以及热斑的产生机理, 设置光伏组件热斑图像检测标准; 通过红外热像仪和探测器采集光伏组件热斑图像, 并对采集得到的图像展开预处理; 利用卷积神经网络算法从轮廓和颜色两个方面提取预处理后热斑图像的特征, 根据特征匹配结果得出光伏组件热斑图像的检测结果; 实验结果表明: 与传统检测方法相比, 优化设计方法的漏检率和误检率明显更低, 且光伏组件热斑面积检测误差较低, 说明其检测效果较好。

关键词: 机器学习; 光伏组件; 热斑图像; 图像检测

Research on Thermal Spot Image Detection Method for Photovoltaic Modules Based on Convolutional Neural Network Algorithms

ZHANG Huimin¹, ZHAO Yang², KANG Huifeng³

(1. College of Mechanical and Electrical Engineering, Henan Technical Institute, Zhengzhou 450042, China;

2. College of Chemical Engineering, Henan Technical Institute, Zhengzhou 450042, China;

3. College of Aeronautics and Astronautics, North China Institute of Aerospace Engineering, Langfang 065000, China)

Abstract: The hot spot effect is one of the main causes of damage to photovoltaic modules, in order to detect the hot spot effect of photovoltaic modules early, convolutional neural network algorithms are used to optimize the design of photovoltaic module hot spot image detection methods. According to the working principle of photovoltaic modules and the mechanism of hot spot generation, the detection standards for hot spot images of photovoltaic modules is set. The collected thermal spot images of photovoltaic modules are preprocessed through the infrared thermal imagers and detectors. Convolutional neural network algorithms are used to extract the features of preprocessed hot spot images from both contour and color aspects, the detection results of photovoltaic module hot spot images are obtained based on the feature matching results. The experimental results show that compared with traditional detection methods, the optimized design method has significantly lower missed detection and false detection rates, and the detection error of photovoltaic module hot spot area is lower, indicating that it has better detection effect.

Keywords: machine learning; photovoltaic modules; hot spot images; image detection

0 引言

太阳能光伏发电技术作为一种可再生能源的重要手段, 广泛应用于家庭、商业和工业领域。然而, 由于诸多因素的影响 (例如材料缺陷、安装错误、污垢等), 光伏组件可能出现局部温度异常区域, 即热斑。热斑不仅导致光伏组

件的发电效率下降, 还可能引发热失控、性能损害甚至火灾等安全隐患。因此, 针对热斑问题, 研究者们开始关注和研究相应的图像处理与分析技术, 旨在实时监测和识别光伏组件表面的热斑, 准确评估光伏组件的健康状况和发电性能, 指导及时采取维修和维护措施, 保障光伏系统的可靠性和效益。

收稿日期: 2023-10-20; 修回日期: 2024-01-17。

基金项目: 河南省科技攻关项目(242102220027); 2023年河南省职业教育教学改革研究与实践项目(豫教[2024]05740); 2021年度河南省高等教育教学改革研究与实践项目(2021SJGLX881); 2023年河南省教育科学规划课题(2023YB0447); 河南应用技术职业学院2022年度校级科研课题(2022-KJ-44); 2024河南省高校人文社会科学研究一般项目(2024-ZDJH-201)

作者简介: 张绘敏(1984-), 女, 硕士, 讲师。

赵扬(1979-), 男, 硕士, 教授。

康会峰(1982-), 男, 硕士, 副教授。

引用格式: 张绘敏, 赵扬, 康会峰. 基于卷积神经网络算法的光伏组件热斑图像检测方法研究[J]. 计算机测量与控制, 2024, 32(7): 57-63.

目前光伏组件热斑图像检测方法的研究已经取得了一些重要成果,其中,文献[1]提出了一种基于红外热图像处理的光伏阵列热斑检测方法,该方法利用灰度直方图的B样条最小二乘拟合处理方法,抑制红外图像噪声,实现图像热斑检测。由于该方法无需直接接触光伏阵列,在实际操作中不会对光伏阵列造成损害,但是在图像处理过程中可能受到成像设备自身因素和光伏电站复杂环境等因素的影响,导致误检率较高。文献[2]提出了一种基于改进自私羊群算法的光伏红外热图像热斑识别方法,通过模仿深度学习分类训练过程获取数据集,基于高斯分布提出一种热斑识别函数,基于获取的数据集采用自私羊群算法对热斑识别函数中的位置参数进行寻优,在寻优的基础上展开阈值分割,得到最终的图像检测结果。实验结果表明,该方法可以快速处理大量图像数据,提高图像检测效率,但是其在图像检测的精确度上存在一定局限性,热斑面积检测误差较大。文献[3]提出了一种基于CSwin的航拍光伏组件红外图像热斑检测方法,以CSwin为基础模块,建立多尺度特征路径聚合网络,通过该聚合网络获取图像的全局位置和空间信息,实现图像检测。实验结果表明,该方法可以提高小目标检测能力,但是漏检率较高,检测结果不够全面,需要进一步通过算法调优和参数优化提升检测效果。文献[4]提出了一种基于深度卷积神经网络的光伏组件热斑检测方法,设计了SpotFPN多尺度特征学习模块,并将该模块应用于二阶段目标检测网络中,以避免数据过拟合问题。实验结果表明,该方法不需要人工设计和选择特征,减少了人为主观因素对检测结果的干扰,但是漏检率较高,需要进一步提升检测效果。文献[5]提出了一种光伏航拍红外图像的热斑自动检测方法,针对航拍红外图像前,背景灰度值的差异性,通过组件分割方法提取光伏组件轮廓,基于获取的轮廓实现热斑检测。实验结果表明,其在检测效率方面具有明显优势,但是其存在一定的准确性限制,无法准确检测图像热斑。

由上述分析可知,现有检测方法普遍存在检测结果漏检率和误检率较高,光伏组件热斑面积检测误差较大的问题,为此引入机器学习算法中的卷积神经网络算法,利用卷积神经网络算法对光伏组件热斑图像检测方法进行优化设计,以期提升热斑图像的检测精度。本文研究的主要内容如下:

1) 依据光伏组件热斑图像检测标准,采用Flir One Pro热感红外线热成像仪和探测器采集光伏组件热斑图像。

2) 针对采集得到的图像,展开颜色空间转换,将处于YCrCb颜色空间下的热斑图像转换至RGB颜色空间,以提升图像色彩的准确性和可视性;将高斯滤波和双边滤波结合,展开图像滤波去噪,在去除图像噪声的同时,保留图像细节和边缘信息;在去除图像背景干扰的基础上,通过空间域与频率域图像增强,提升图像的清晰度和视觉效果,强化边缘和孤立区域,提升图像的细节和清晰度。

3) 基于图像预处理结果,通过卷积神经网络实现光伏

组件热斑图像检测,卷积神经网络能够更好地适应复杂和多样化的图像特征,具备更高的检测精度和鲁棒性。

1 光伏组件热斑图像检测方法设计

1.1 设置光伏组件热斑图像检测标准

光伏系统的核心模块结构是进行能量转换的光伏电池片,其随着阳光照射强度的增强,利用光能产生电能,该转换过程是由光电效应来实现的。当所转换的电能达到某种程度时,外部电路上就会产生电流。光伏组件的等效电路如图1所示。

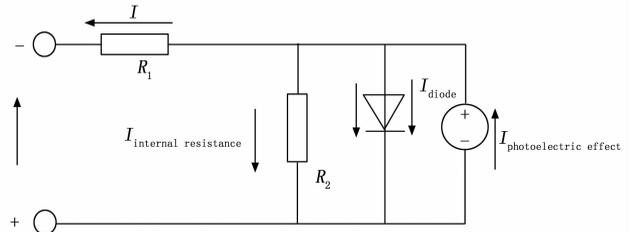


图1 光伏组件等效电路图

在正常运行状态下,光伏电阻的运行满足如下关系:

$$I_{\text{photoelectric effect}} = I + I_{\text{internal resistance}} + I_{\text{diode}} \quad (1)$$

其中: I 、 $I_{\text{internal resistance}}$ 和 I_{diode} 分别对应的是流经外电阻、流经内电阻以及流经二极管的电流, $I_{\text{internal resistance}}$ 容易受到光照强度和温度的影响,当光照强度稳定时,该变量可以被看作一个恒流源。但当光伏电池片被遮挡时,由光电效应转换生成的 $I_{\text{internal resistance}}$ 电流随之减少,导致 $I + I_{\text{internal resistance}}$ 的值大于光生电流,这是因为太阳能电池板本身的半导体属性,会造成光伏板的反向偏压,引起光伏模块的局部温度突然上升,形成热斑。

根据上述光伏组件光斑的产生原理可知,在光伏热斑出现时,其功率、电压、电流与温度等特征量变化敏感程度不同,引发该区域的红外辐射效果增强。用红外热像仪来检测和捕捉红外辐射效果的变化,不同的辐射强度会以不同的颜色来显示,最后呈现为红外图像,物体的红外辐射能力与自身的温度成正相关。由此可以得出光伏组件热斑的标准特征为:

$$\begin{cases} \tau_{\text{colour}} = T \times \kappa_{\text{colour}} \\ T = \lambda(I_{\text{photoelectric effect}} - I_0) \end{cases} \quad (2)$$

其中: κ_{colour} 为光伏组件的颜色转换系数, λ 表示温度与电流之间的线性关系系数, I_0 表示正常运行状态下光伏组件的电流值^[6]。由此得出光伏组件中热斑区域标准特征的设置结果,由此来判定光伏组件图像中是否存在热斑。

1.2 采集光伏组件热斑图像

采用Flir One Pro热感红外线热成像仪采集光伏组件区域图像,具体采集步骤如下。

1) 准备工作:确定要检测的光伏组件,确保其正常运行并暴露在外部环境中。

2) Flir One Pro热感红外线热成像仪设置:设置红外

热像仪参数,如温度范围、色彩调整等。

3) 拍摄光伏组件热斑图像:使用红外线热成像仪对光伏组件进行扫描或拍摄,以获取光伏组件表面的红外热斑图像。

4) 图像保存:将采集到的光伏组件热斑图像保存到计算机或其他存储设备中,供后续处理和分析使用。

然后利用探测器对光伏阵列的红外辐射进行收集,将收集的光信号转化成电信号,并利用温度转换装置将电信号转换成相应的温度值,形成温度分布图,根据温度曲线对灰度图像或伪彩色图像进行映射,获取最终的红外图像^[7]。采集得出的光伏组件图像可以表示为:

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} F\tau_{\text{colour}} \cdot x_{\text{pv module}} \cdot \cos\theta \\ F\tau_{\text{colour}} \cdot y_{\text{pv module}} \cdot \sin\theta \end{pmatrix} \quad (3)$$

其中: F 为成像设备发射出的辐射热量, $(x_{\text{pv module}}, y_{\text{pv module}})$ 表示的是光伏组件的实际位置坐标, θ 为光伏组件热斑图像的成像角度。公式(3)中变量 F 的计算公式为:

$$F = \mu \cdot \kappa_{\text{Stefan Boltzmann}} \cdot T_{\text{pv module}} \quad (4)$$

其中: μ 为光伏组件表面的辐射强度, $T_{\text{pv module}}$ 为光伏组件的绝对温度, $\kappa_{\text{Stefan Boltzmann}}$ 表示的是斯特凡·玻尔兹曼常数^[8]。将公式(4)的计算结果代入得到公式(3)中,即可得出光伏组件热斑图像任意像素点的采集结果,根据光伏组件的几何结构特征,对生成的像素点进行连接,完成光伏组件热斑图像的采集工作。

1.3 光伏组件热斑图像预处理

1.3.1 颜色空间转换

初始生成的光伏组件热斑图像以YCrCb作为颜色空间,该空间下的颜色占用存储空间更小,但反应的颜色存在一定色差,为此需要将处于YCrCb颜色空间下的热斑图像转换至RGB颜色空间中^[9]。由于RGB颜色空间跟人眼的色彩感知关系紧密,转换后的图像能够更准确、真实地呈现原始热斑图像中不同颜色的热斑信息,提供更直观的视觉效果和可视化表达。因此,将热斑图像从YCrCb颜色空间转换至RGB颜色空间可以提升其色彩准确性和可视性,便于更好地分析和理解光伏组件的热特性。转换过程可以表示为:

$$\begin{cases} R = xy + 1.402(C_R - 128) \\ G = xy - 0.344(C_B - 128) - 0.714(C_G - 128) \\ B = xy + 1.772(C_B - 128) \end{cases} \quad (5)$$

其中: C_R 和 C_B 分别对应的是色调和饱和度。将初始采集的光伏组件热斑图像代入到公式(5)中,完成初始图像颜色空间的转换。

1.3.2 滤波去噪

图像滤波的目的就是在保留图像细节的前提下,过滤掉图像中的噪声干扰^[10]。为保证光伏组件热斑图像的滤波去噪处理结果,采用高斯滤波和双边滤波相结合的方式,高斯滤波使用高斯核函数对图像进行卷积运算,核子尺寸可以自行设定,而双边滤波器则包含两个尺度参量,一个用来控制局部空间距离的大小,另一个用来调节局部像素

点之间的区别。高斯滤波和双边滤波的处理过程如下:

$$\begin{cases} f_{\text{Gaussian filter}} = \frac{RGB}{2\pi\delta^2} e^{-x^2+y^2/2} \\ f_{\text{bilateral filter}} = e^{-x^2+y^2/2\omega_{\text{smooth-d}}^2} \times e^{-x^2+y^2/2\omega_{\text{smooth-h}}^2} \end{cases} \quad (6)$$

其中: δ 代表高斯滤波尺度大小, $\varphi_{\text{smooth-d}}$ 和 $\varphi_{\text{smooth-h}}$ 分别对应的是调节空间距离和灰度值之间的平滑参数^[11]。根据光伏组件热斑图像中噪声和细节特征的分布情况,确定 δ 、 $\varphi_{\text{smooth-d}}$ 和 $\varphi_{\text{smooth-h}}$ 的具体取值,完成光伏组件热斑图像的滤波去噪处理。

高斯滤波可以有效平滑图像,减少噪声干扰,而双边滤波在保持边缘信息的同时能够对纹理细节进行保护。这种结合的方式能够在去除图像噪声的同时,保留并增强光伏组件热斑图像中重要的细节和边缘信息,使得滤波结果更加自然、真实,并且更好地适应人眼对图像的感知。

1.3.3 去除图像背景干扰

通过动态设定门限,消除背景干扰,减少阴影对检测结果的影响。对光伏模块初始探测框架的红外图像进行自适应阈值分割,并与初始探测框架的红外图像进行求积,结果记为 J ,在此基础上,定义一个空集合,将其存储在空集中,并将空集按照数值降序排序^[12]。计算集合中前90%数值的平均值,以平均值的0.9倍作为判定阴影区域的参考值,将 J 中各像素点对应的值与参考值进行比较,如果超过这个值,则像素点的值设置为1,如果未超过这个值,则像素点的值设置为0,以此实现对阴影区域的判断,并去除判定为阴影的图像区域。

1.3.4 图像增强

利用空域和频域两种方法,实现对太阳能电池板热斑图像的增强。空间域图像增强处理过程可以量化表示为:

$$f_{\text{Enhancement-Space}} = h_{\text{Enhancement-Space}}(f(x,y)) \times (f_{\text{Gaussian filter}} + f_{\text{bilateral filter}}) \quad (7)$$

其中: $h_{\text{Enhancement-Space}}(\cdot)$ 为空间域增强函数,按照上述方式对光伏组件热斑图像中的所有像素点进行处理,得出结果即为图像的空间域增强处理结果^[13]。通过将图像从空域转换到频域,经过变换操作后再将其逆变换回空域,具体可以通过傅里叶变换将图像转换为频域:

$$f_{\text{Enhancement-Frequency}} = f_{\text{Enhancement-Space}} - \kappa_{\text{Fourier}} f(x,y)^{-1} \quad (8)$$

其中: κ_{Fourier} 为傅里叶变换系数。通过傅里叶变换实现频率域操作后,再将图像逆变换回空间域,就可以得到增强后的图像。

空域方法通过对图像进行直接的像素操作,可以调整图像的对比度、亮度和锐度等属性,以增强图像的清晰度和视觉效果。频域方法则利用傅里叶变换将图像从空域转换到频域,去除噪声、强化边缘和孤立区域,提升图像的细节和清晰度。两种方法结合使用可以互补彼此的优势,既保留了空域方法灵活直观的特点,又利用频域方法在频率域上的处理能力,获得更好的图像增强效果。

按照上述流程对初始采集图像中的所有像素点进行变

换、滤波以及增强处理，并将最终的处理结果赋值给初始图像，完成光伏组件热斑图像的预处理操作。

1.4 光伏组件热斑图像检测实现

机器学习算法具体包括：朴素贝叶斯算法、支持向量机算法、随机森林算法以及卷积神经网络算法等^[14]，其中，朴素贝叶斯算法对特征的分布形式有要求，对于复杂的特征分布表现较差；支持向量机算法计算量较大，训练时间较长；随机森林算法对数据质量要求较高，对缺失数据敏感，且需要较多的内存资源，对于处理大规模数据的效率较低。相比于上述几种算法，卷积神经网络通过深层次特征学习和自动学习能力，在光伏组件热斑图像检测中具有更强的表征能力和准确性，能够更好地适应复杂和多样化的图像特征，具备更高的检测精度和鲁棒性。此外，卷积神经网络还能够处理大规模数据和非线性可分问题，对于图像领域的任务有着广泛的应用和卓越的性能。因此，为满足光伏组件热斑图像检测工作对特征提取精度的要求，选择卷积神经网络作为机器学习算法。在光伏组件热斑图像空间内构建一个卷积神经网络，该网络结构如图 2 所示。

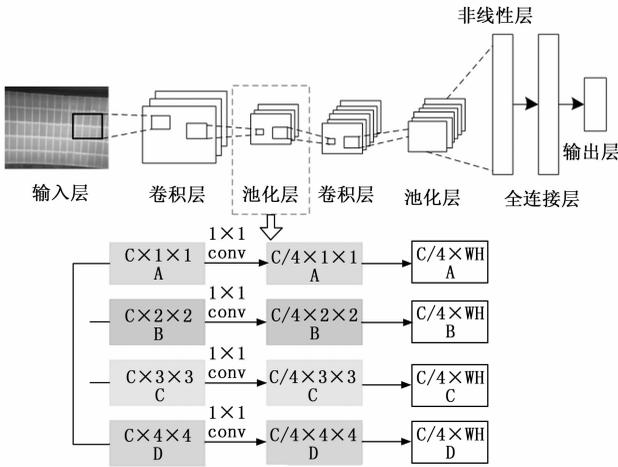


图 2 卷积神经网络结构图

从图 2 中可以看出，构建的卷积神经网络由卷积层、池化层、非线性层以及全连接层等部分组成，将光伏组件热斑图像作为网络的输入，通过多种卷积运算获得局部特征，再通过池化运算对所获得的特征进行融合，最终通过全连通实现对图像综合特征的提取^[15]。其中，采用多尺度池化层可以融合所有通道图的相关特征，压缩空间维度的特征，具有全局感受野，有利于提高了特征的表示能力。

卷积神经网络的特征提取流程如图 3 所示。

按照图 3 表示流程对网络的不同层次进行组合，并对各种特征参数如卷积核的个数、尺寸、步长等进行设定，形成不同的网络结构。卷积神经网络中的卷积运算可以量化表示为：

$$u^{i,j}_{convolution} = H_{convolution} \times f_{\text{Enhancement-Frequency}}(\omega_{convolution} f(x,y) + B_{convolution}) \quad (9)$$

其中： $H_{convolution}$ 为卷积核函数， $\omega_{convolution}$ 和 $B_{convolution}$ 分别

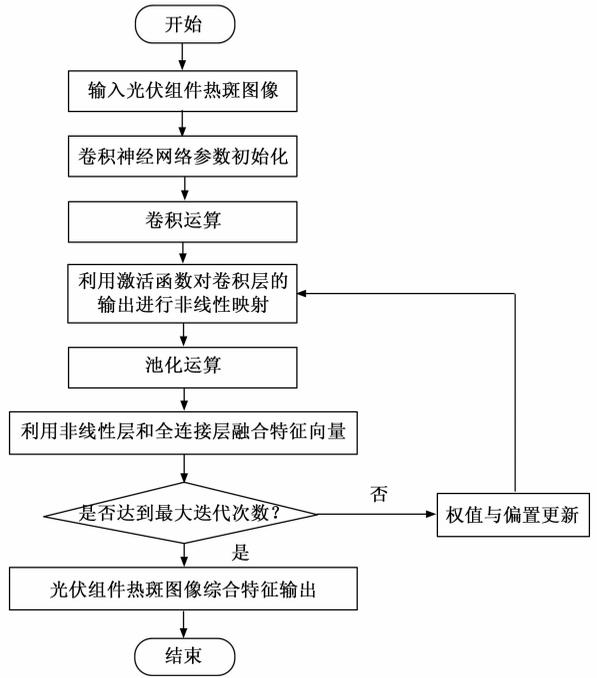


图 3 利用卷积神经网络提取热斑图像特征流程图

为卷积层的权重值和偏置值。公式 (9) 的输出结果 $u^{i,j}_{convolution}$ 表示提取特征矩阵中第 i 行第 j 列对应的向量值^[16]。利用卷积层将图像的空间特征映射到隐层的特征空间，在网络的浅层卷积核中，可以提取输入目标较为突出的纹理、拓扑结构等特征，而网络深层的卷积核可以以之前所提取的特征信息为基础，提取图像更深层次的特征，实现对图像特征多角度提取的目的。池化操作过程如下：

$$u_{pooling}^{i,j} = u_{convolution}^{i,j} \times [\omega_{pooling} \cdot q_{pooling}(u_{convolution}^{i,j}) + B_{pooling}] \quad (10)$$

其中： $q_{pooling}$ 为池化处理函数， $\omega_{pooling}$ 和 $B_{pooling}$ 分别表示池化层的权重和偏置。根据光伏组件热斑图像的特征提取要求，选择最大池化的方式进行操作，即通过卷积核的大小选取热斑图像区域内的最大元素，保留热斑图像的纹理信息。

非线性层主要是通过选择特定的激活函数，将其作用到每个输入，让输入和输出之间形成非线性映射，提高网络的学习表达能力，激活函数可以使网络用较少的神经元来完成大量的参数计算，其实质是利用网络中各个神经元的输入与整个网络模型的预测关联，来决定是否激活该神经元。而全连接层用来调整卷积层和池化层输出的特征向量，每一层的节点都与上一层的节点相连接，它的功能是对之前的特征进行融合学习，并将学习到的“分布式特征”进行映射。为保证热斑图像特征的提取效果，在卷积神经网络运行过程中还需要通过反向迭代对各层的权重和偏置值进行补偿与更新，补偿量由网络的损失函数决定，卷积神经网络的损失函数可以表示为：

$$q_{loss} = L_{\text{logarithm}} u_{pooling}^{i,j} + q_{\text{Robust}} L_{\text{regression}} \quad (11)$$

其中: $L_{\text{logarithm}}$ 和 $L_{\text{regression}}$ 分别表示特征提取结果对数损失和回归损失, q_{Robust} 为鲁棒损失函数。那么在卷积神经网络的第 t 次迭代中更新权值和偏置可以表示为:

$$\begin{cases} \omega(t) = \omega(t-1) + q_{\text{loss}}(\omega) \\ B(t) = B(t-1) + q_{\text{loss}}(B) \end{cases} \quad (12)$$

其中: $\omega(t-1)$ 和 $B(t-1)$ 分别为前一次迭代的权值和偏置, $q_{\text{loss}}(\omega)$ 和 $q_{\text{loss}}(B)$ 对应的是权值和偏置的损失补偿量。将公式 (12) 得出的更新结果代入到卷积神经网络中, 通过多次迭代得出最终的输出结果, 即光伏组件热斑图像的特征提取结果。光伏组件热斑图像轮廓特征如图 4 所示。

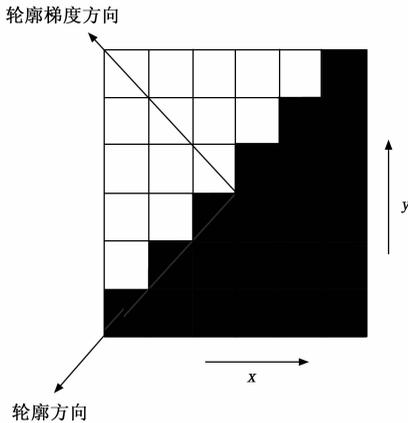


图 4 光伏组件热斑图像轮廓特征示意图

图 4 中的热斑图像轮廓特征向量可以量化表示为:

$$\begin{cases} \tau_{\text{Contour Gradient}} = \omega(t) \sqrt{u_{\text{convolution}}^2(x) + u_{\text{convolution}}^2(y)} \\ \tau_{\text{Outline phase angle}} = B(t) \times \arctan\left(\frac{u_{\text{convolution}}(y)}{u_{\text{convolution}}(x)}\right) \end{cases} \quad (13)$$

其中: $u_{\text{convolution}}(x)$ 和 $u_{\text{convolution}}(y)$ 分别表示卷积层输出的水平和垂直方向上的梯度算子。同理可以得出颜色特征向量的输出结果, 最终利用全连接层对提取的特征向量进行融合处理, 处理结果为:

$$\tau = \omega_{\text{Fully connected}} (\tau_{\text{Contour Gradient}} + \tau_{\text{Outline phase angle}}) + B_{\text{Fully connected}} \quad (14)$$

其中: $\omega_{\text{Fully connected}}$ 和 $B_{\text{Fully connected}}$ 分别表示全连接层的权重和偏置, 将公式 (13) 的计算结果代入到公式 (14) 中, 即可得出光伏组件热斑图像的特征提取结果。

以机器学习算法提取的光伏组件热斑图像特征为研究对象, 采用特征匹配的方式度量当前图像特征与标准特征之间的相似度, 相似度计算公式如下:

$$s = \frac{\tau \cdot \tau_{\text{colour}}}{\|\tau\| \cdot \|\tau_{\text{colour}}\|} \quad (15)$$

将相关数据代入到公式 (15) 中, 若计算得出特征相似度 s 高于阈值 s' , 说明当前图像中包含热斑, 否则认为当前图像不属于热斑图像, 即光伏组件中不存在热斑。在此基础上, 确定图像中的热斑的几何参数和位置信息, 其中, 几何参数的检测结果为:

$$A = s \left(\frac{D_{\text{edge-max}} - D_{\text{edge-min}}}{2} \right)^2 \quad (16)$$

其中: $D_{\text{edge-max}}$ 和 $D_{\text{edge-min}}$ 分别表示最远和最近的边缘节点, $D_{\text{edge-max}} - D_{\text{edge-min}}$ 为光斑半径, 由此得出光伏组件热斑图像面积的计算结果, 同理可以确定图像中热斑位置的检测结果, 最终以可视化的形式输出光伏组件热斑图像的检测结果。

2 实验分析

为了测试设计基于卷积神经网络算法的光伏组件热斑图像检测方法的检测效果, 采用白盒测试与对比测试相结合的方式, 设计检测性能测试实验。

实验的基本测试思路为: 准备光伏组件对象, 并在光伏组件上手动设置遮挡, 实现光伏组件热斑的设置, 根据遮挡的设置情况, 确定热斑图像检测的预期值。利用硬件设备生成光伏组件的图像样本, 利用优化设计方法得出热斑图像的检测结果, 并与设置的预期值进行比对, 得出热斑图像的检测结果。设置传统方法作为实验的对比方法, 在相同的实验环境下对同一组图像进行检测, 得出对比方法输出的检测结果, 通过比对判断优化设计方法在检测性能方面的优势。

2.1 光伏组件对象

此次实验选择某光伏发电厂的光伏组件作为研究对象, 该区域的光伏组件以晶硅电池作为核心设备, 因为其容易破碎、受污染、无法直接与空气接触, 所以通常都进行了包装处理。准备的光伏组件分布情况如图 5 所示。



图 5 光伏组件对象分布实景

准备的光伏组件由组件串联而成的, 它的组成方式能够根据不同的地形需求而进行灵活的变化, 准备光伏组件为 4×5 阵列, 长度可达到 50, 即 $n \times 50$ 阵列。在实际安装时, 应依据屋面的情况确定安装倾斜角度。在选择的光伏组件对象表面放置不同大小的圆形遮挡物, 保证光伏组件中能够产生热斑, 为保证实验的操作安全, 遮挡物选择夜晚进行放置, 避免操作人员烫伤。

2.2 收集光伏组件图像样本

采用 Flir One Pro 热感红外线热成像仪拍摄光伏组件红外热成像图片, 使用的成像仪是一款手持式的红外热像仪, 具有测温精准的特点, 能够满足实验需求。为降低反射对

成像结果产生的影响,设置图像样本的成像角度为 28° 。利用 MatlabR2014a 软件对收集的光伏组件图像样本进行进一步处理。初始收集的光伏组件图像样本如图 6 所示。

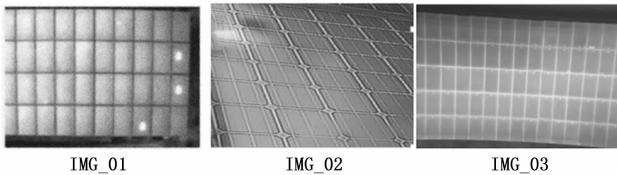


图 6 光伏组件图像样本

通过对初始组件图像预处理,将图像样本调整为相同尺寸。在光照最强时刻收集光伏组件图像,保证热斑图像样本收集的有效性。除热斑图像外,利用相同设备生成多个缺陷图像作为实验干扰,并保证干扰图像尺寸与热斑图像样本一致。准备的光伏组件热斑图像数量共 500 张,干扰图像数量为 100。

2.3 机器学习算法运行参数

设计的光伏组件热斑图像检测方法采用机器学习作为技术支持,为保证机器学习算法在图像检测工作中的正常运行,需要对相关参数进行设置。输入图像大小设置为 640×640 ,由于训练时间较长,且迭代次数较多,可能会造成模型的过拟合,因此,此次实验将迭代次数固定在 4 000 步,将学习率大小设定为 0.000 1,动量设定为 0.9,权重衰减设定为 0.000 5。

2.4 光伏组件热斑图像检测性能测试实验过程

设计的基于卷积神经网络算法的光伏组件热斑图像检测方法以 Windows7 操作系统为基础,使用 MATLABR2014a 为系统开发的平台。MATLAB 对矩阵、阵列进行图形化的显示,具有非常强大的功能,可以对图形添加注解,并提供图形标注、图形打印等功能。将设定的机器学习算法运行参数输入到光伏组件热斑图像检测方法对应的运行程序中,并将收集的光伏组件热斑图像样本逐一输入到图像检测方法中,得出相应的检测结果。图 7 表示的是 1 号光伏组件热斑图像样本的检测结果。

按照上述操作流程,更换输入到图像检测程序中的图像样本,得出实验中收集所有图像的检测结果,并将输出的检测结果与设定的预期值进行比对,判定当前方法输出的图像检测结果是否正确。为了体现出设计方法在图像检测性能方面的优势,设置传统的基于改进自私羊群算法的光伏红外热图像热斑识别方法(文献[2]方法)和基于 CSwin 的航拍光伏组件红外图像热斑检测方法(文献[3]方法)作为实验的对比方法,利用相同的实验环境和开发工具完成两种对比方法的开发,即操作系统为 Windows 10,编程语言为 Python 3.7,开发工具为 Jupyter Notebook,图像处理库为 OpenCV,NumPy,羊群数量为 100,迭代次数为 1 000,窗口大小为 7×7 。通过图像样本的数据、检测方法运行等步骤,得出对比方法输出的光伏组件

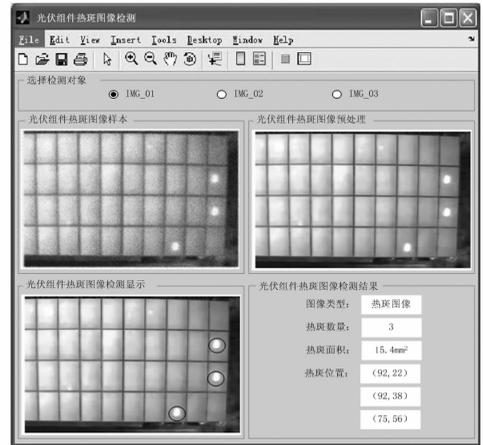


图 7 光伏组件热斑图像检测结果

热斑图像的检测结果,并判断对比方法输出结果的正确性。

2.5 设置图像检测性能测试指标

为实现对光伏组件热斑图像检测性能的量化测试,分别设置漏检率、误检率和热斑面积检测误差作为实验的量化测试指标,漏检率是衡量热斑图像检测可靠性的一项指标,表示未检测到的热斑图像样本总数占全部图像样本的比例,而误检率表示误检为热斑样本的总数量占全部热斑样本总数的比例,上述指标的数值结果为:

$$\begin{cases} \eta_{\text{false detection}} = \left(\frac{n_{\text{hot spot}} - n_{\text{out}}}{n_{\text{all}}} \right) \times 100\% \\ \eta_{\text{missed detection}} = \left(\frac{n_{\text{error}}}{n_{\text{all}}} \right) \times 100\% \end{cases} \quad (17)$$

其中: $n_{\text{hot spot}}$ 、 n_{out} 和 n_{error} 分别表示准备的热斑图像样本、检测为热斑图像的样本数量以及检测错误的图像样本, n_{all} 为设置的图像总样本数量。另外光伏组件热斑面积检测误差指标的测试结果如下:

$$\epsilon_A = |A_{\text{detection}} - A_{\text{set}}| \quad (18)$$

其中: $A_{\text{detection}}$ 和 A_{set} 分别为热斑面积的检测值和设置值,在实际计算中若检测出图像中的热斑数量不唯一,则通过计算求和的方式得出面积检测误差指标的具体取值。最终计算得出漏检率和误检率越低、热斑面积检测误差取值越小,说明对应检测方法的检测性能越优。

2.6 热斑图像检测性能测试结果与分析

通过相关数据的统计,得出反映热斑图像漏检率和误检率的测试结果,为保证实验结果的可信度,采用多次实验取平均值的方式,得出的测试结果如表 1 所示。

将表 1 中的数据代入到公式(17)中,可以得出基于 CSwin 的航拍光伏组件红外图像热斑检测方法的平均漏检率和平均误检率分别为 1.63% 和 1.23%,基于改进自私羊群算法的热斑图像检测方法漏检率和误检率的平均值分别为 0.63% 和 0.94%,而设计方法得出热斑图像漏检率和误检率的平均值分别为 0.08% 和 0.19%。

另外光伏组件热斑面积检测误差的测试结果如表 2 所示。

表 1 热斑图像漏检率和误检率测试结果

实验组别	基于 CSwin 的航拍光伏组件红外图像热斑检测方法		基于改进自私羊群算法的光伏红外热图像热斑识别方法		基于卷积神经网络算法的光伏组件热斑图像检测方法	
	输出为热斑图像的样本数量/张	检测错误图像样本数量/张	输出为热斑图像的样本数量/张	检测错误图像样本数量/张	输出为热斑图像的样本数量/张	检测错误图像样本数量/张
1	491	6	495	5	500	2
2	495	7	500	6	500	1
3	490	9	496	5	498	0
4	492	6	494	4	500	2
5	483	8	498	5	500	2
6	490	6	495	8	499	1
7	489	7	496	5	499	0
8	492	10	496	7	500	1

表 2 光伏组件热斑面积检测误差测试结果

图像样本编号	光伏组件热斑面积设置值/mm ²	基于 CSwin 的航拍光伏组件红外图像热斑检测方法输出光伏组件热斑面积/mm ²	基于改进自私羊群算法的热斑图像检测方法输出光伏组件热斑面积/mm ²	基于卷积神经网络算法的光伏组件热斑图像检测方法输出光伏组件热斑面积/mm ²
IMG_01	15.5	14.6	15.9	15.4
IMG_02	18.7	17.2	18.1	18.5
IMG_03	21.3	22.6	21.7	21.3
IMG_04	16.2	17.1	16.6	16.1
IMG_05	14.2	15.5	14.8	14.0
IMG_06	20.7	20.0	20.4	20.8
IMG_07	19.8	18.7	19.1	19.8
IMG_08	17.0	16.2	17.6	17.2

将表 2 中的数据代入到公式 (18) 中, 计算得出 3 种检测方法的平均热斑面积检测误差分别为 1.06 mm²、0.50 mm² 和 0.11 mm²。综合分析上述实验结果可知, 设计方法能够实现光伏组件热斑的准确检测, 检测结果可靠度较高。

3 结束语

光伏模组中的一些单体自身存在的缺陷, 也会造成模组的局部温度升高, 这就是所谓的“热斑效应”。热斑是造成太阳能电池板故障和功耗损失的最重要原因, 直接降低电池板的使用寿命。为及时发现光伏组件中的热斑现象, 并第一时间对光伏组件中的遮挡物进行清理, 在此次研究中设计并开发了基于卷积神经网络算法的光伏组件热斑图像检测方法, 通过机器学习算法的应用, 实现热斑图像特

征的深度、精准提取, 提升图像的检测效果。通过实验测试发现设计方法具有良好的检测性能, 具有较高的现实意义。

参考文献:

- [1] 蒋琳, 苏建徽, 施永, 等. 基于红外热图像处理的光伏阵列热斑检测方法 [J]. 太阳能学报, 2020, 41 (8): 180-184.
- [2] 孙海蓉, 周映杰, 张镇韬, 等. 基于改进自私羊群算法的光伏红外热图像热斑识别方法 [J]. 中国电机工程学报, 2022, 42 (24): 8942-8951.
- [3] 王巍, 赵宽, 杨耀权, 等. 基于 CSwin 的航拍光伏组件红外图像热斑检测方法 [J]. 太阳能学报, 2023, 44 (10): 142-147.
- [4] 王道累, 李超, 李明山, 等. 基于深度卷积神经网络的光伏组件热斑检测 [J]. 太阳能学报, 2022, 43 (1): 412-417.
- [5] 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.
- [6] 苏树智, 谢玉麒. 基于距离约束的改进 FCOS 遥感图像检测方法 [J]. 计算机工程与应用, 2023, 59 (10): 227-235.
- [7] 钟建波, 李茂忠, 夏青松, 等. 基于图像的红外镜头焦距快速检测方法研究 [J]. 红外技术, 2021, 43 (6): 583-586.
- [8] 廖育荣, 王海宁, 林存宝, 等. 基于深度学习的光学遥感图像目标检测研究进展 [J]. 通信学报, 2022, 43 (5): 190-203.
- [9] 付涵, 范湘涛, 严珍珍, 等. 基于深度学习的遥感图像目标检测技术研究进展 [J]. 遥感技术与应用, 2022, 37 (2): 290-305.
- [10] 邓堡元, 何赞泽, 王洪金, 等. 光伏电池图像序列的深度学习检测方法 [J]. 机械工程学报, 2021, 57 (8): 98-106.
- [11] 吴添权, 郭竞, 苟先太, 等. 基于改进高斯卷积核的变电站设备红外图像检测方法 [J]. 红外技术, 2021, 43 (3): 230-236.
- [12] 谢昕, 王伟如, 万天成, 等. 基于果蝇优化算法的零件图像边缘检测算法研究及应用 [J]. 科学技术与工程, 2021, 21 (5): 1948-1956.
- [13] 张廓, 陈章进, 张岩. 改进 YOLOv4-Tiny 的 SAR 图像目标快速检测方法 [J]. 计算机工程与应用, 2023, 59 (14): 209-216.
- [14] 吴君, 范鹏辉, 王满利. 多尺度融合的 CRC-RetinaNet 光伏板阴影检测方法 [J]. 激光与光电子学进展, 2022, 59 (16): 372-379.
- [15] 刘行谋, 田浩, 杨永明, 等. 复杂环境背景下绝缘子缺陷图像检测方法研究 [J]. 电子测量与仪器学报, 2022, 36 (2): 57-67.
- [16] 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.