

基于样本生成技术的光伏组件故障智能诊断方法研究

郑志文¹ 柳朝阳²

(1. 福建华电福瑞能源发展有限公司 2. 华电(厦门)能源有限公司)

摘要：本文提出基于样本生成技术的光伏组件故障智能诊断方法。以光伏组件故障状态为基础，建立潮流方程。基于此，采用红外成像的方式采集光伏组件温度故障图像，生成光伏组件故障样本，利用高斯滤波和双边滤波对光伏组件的红外图像完成滤波去噪。应用卷积神经网络，智能提取光伏组件故障图像特征。采用特征匹配的方式度量光伏组件故障特征和正常特征的相似度，实现光伏组件故障智能诊断。实验结果表明，研究方法能够对光伏组件红外图像完成去噪和增强，且故障诊断的漏检率和误检率小于1%。

关键词：样本生成；光伏组件；故障智能诊断；红外图像；卷积神经网络

0 引言

光伏组件故障智能诊断的研究背景是源于光伏发电系统在大规模应用中出现故障和损坏的情况，这对发电效率和系统可靠性产生了负面影响。传统的故障诊断方法通常需要人工干预和长时间的维修，效率低下且成本较高。为了解决这一问题，研究者开始关注将智能技术应用于光伏组件故障诊断中。通过采用人工智能、图像处理、机器学习等相关技术，可以对光伏组件进行故障诊断和状态监测。这种智能诊断方法可以从设备上获取大量的数据和图像，利用先进的算法和模型分析这些数据，实时检测和诊断故障，并给出准确的故障类型和定位结果^[1]。

1 光伏组件故障智能诊断

1.1 潮流方程

在生成光伏组件故障样本的过程中，构建潮流方程是必要的。潮流方程是用来描述电力系统中电压、电流以及功率之间的关系的方程式。它通过考虑各个节点之间的电流平衡以及电压相位差等因素，能够准确地揭示光伏组件的运行状态和潜在故障。构建潮流方程的过程可以分为以下几个步骤：首先，需要确定电网的拓扑结构，即各个节点之间的连接关系。接下来，需要列出每个节点的潮流方程，其中包括节点的电压和功率之间的关系。这些方程通过 KCL（基尔霍夫电流定律）原理进行推导。

以光伏组件故障状态为基础，建立潮流方程为：

$$f(x, \lambda) = f(x) - \lambda b_{p, Q} = 0 \quad (1)$$

式中，状态变量和变化参数分别为 x 和 λ ，其中前

者属于节点光伏组件幅值和相角，后者属于负荷和发电；两者之间的连续可微状态用 $f: R^n \times R \rightarrow R^n$ 描述； $b_{P,Q}$ 为单位方向向量，且经过规范化处理，属于负荷和发电变化。

1.2 光伏组件故障样本生成

本文采用红外成像的方式采集光伏组件温度故障图像。采用红外成像的方式来采集光伏组件温度故障图像有以下几个具体原因。首先，红外成像技术可以非接触、远距离地获取光伏组件的温度信息，无需对其进行接触式测量，避免物理接触可能带来的损坏或不便。这种非接触性的特点使得红外成像技术可以在实际运行中进行快速、安全的检测。其次，光伏组件的温度是其工作效率和寿命的关键因素之一。过高的温度会降低光伏组件的发电效率，并可能导致寿命缩短。通过采集光伏组件的温度故障图像，可以直观地展示光伏组件表面温度的分布情况，进而判断是否存在异常热点或温度异常区域。这有助于准确识别潜在的温度故障，及时采取措施进行修复或维护，保证光伏组件的正常运行。此外，红外成像还具有高空间分辨率和高灵敏度的特点，能够捕捉到微小的温度变化。光伏组件表面存在各种类型的缺陷和故障，例如接头损耗、电池裂纹、背面絮凝等。这些问题往往造成整个光伏组件或部分区域的温度升高，通过红外成像技术，可以对这些微弱的温度异常进行有效监测和可视化显示。原理如图 1 所示。

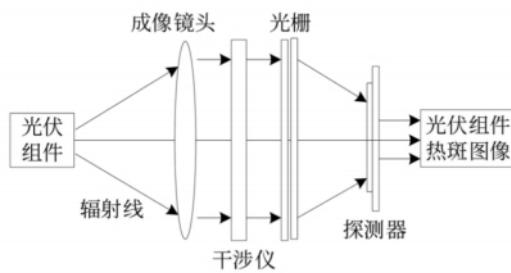


图 1 光伏组件故障图像采集原理图

利用红外成像生成光伏组件故障样本的步骤如下：

- 1) 准备设备：首先准备一台红外热像仪，确保其能够提供高分辨率的红外图像。同时需要确保红外热像仪与计算机或移动设备的连接正常，以便后续进行图像获取和处理。
- 2) 定位拍摄目标：选择想要采集故障样本的光伏组件，并确定要检测的区域。可能的选择包括电池组、接线盒、并联 / 串联组件等。
- 3) 调整设置：根据实际情况调整红外热像仪的设置，包括增益、测温范围、色彩调节等，确保能够得到清晰、准确的红外图像。
- 4) 获取故障样本：使用红外热像仪在选定的目标区域上进行扫描，确保相应故障样本的红外图像能完整覆盖。应尽量保持稳定的环境条件，并注意避免遮挡和光照干扰。
- 5) 图像保存和命名：将获取到的红外图像保存下来，并根据实际情况进行合理的命名和标注，以便后续的分析和处理。
- 6) 故障样本分类和整理：根据故障样本的特征和类型，将其进行分类和整理。例如，可以按照温度异常区域的位置、大小、形状等进行分类，以便后续分析和对比。
- 7) 故障样本分析：利用高斯滤波和双边滤波优化样本质量。使用机器学习算法中的卷积神经网络提取光伏组件故障图像特征，最终实现光伏组件故障的诊断。

1.3 滤波去噪

红外图像在采集过程中可能会受到各种因素的干扰，例如环境光、热噪声、传感器噪声等。这些噪声会影响图像的清晰度和细节，降低图像的质量和可用性。通过对红外图像进行滤波去噪操作，可以有效地减少这些噪声的干扰，使图像更加清晰、真实地

反映光伏组件的温度分布情况。滤波去噪可以提高故障区域的可见性。光伏组件上可能存在各种类型的故障，例如热点、裂缝、污染等。这些故障区域通常与周围区域的温度有所不同，但噪声的存在使得故障信号变得模糊和难以辨别。通过对红外图像进行滤波去噪，可以突出故障区域的温度梯度，使得故障信号更加明显，便于故障的识别和定位。

本节利用高斯滤波和双边滤波完成去噪。高斯滤波和双边滤波都是常用的图像滤波方法，能够有效减少图像中的噪声。高斯滤波使用一个高斯核函数来平滑图像，通过对每个像素点周围区域进行加权平均，去除高频噪声，并且可以保持较好的图像细节。双边滤波则在高斯滤波的基础上考虑像素点的空间距离和像素值之间的相似性，通过加权平均的方式进行滤波，以保留图像边缘和纹理等细节。去噪操作通常会引入一定的信息损失。如果仅仅使用传统的均值滤波或中值滤波等简单滤波方法去除噪声，可能会导致图像细节过度模糊或失真，降低图像质量。而高斯滤波和双边滤波能够在一定程度上平衡去噪和细节保留之间的矛盾。高斯滤波的平滑操作可以有效减少噪声的影响，而双边滤波在去噪的同时，通过对像素点相似性的考虑，保持图像纹理和边缘的细节特征。高斯滤波和双边滤波的处理过程如下：

$$\begin{cases} f_{\text{Gaussian filter}}(x, y) = \frac{1}{2\pi\delta^2} e^{-\frac{x^2+y^2}{2\delta^2}} \\ f_{\text{bilateral filter}} = e^{-\frac{x^2+y^2}{2\varphi_{\text{smooth-d}}^2} - \frac{x^2+y^2}{2\varphi_{\text{smooth-h}}^2}} \end{cases} \quad (2)$$

式中， δ 为进行高斯滤波的尺度大小； $\varphi_{\text{smooth-d}}$ 和 $\varphi_{\text{smooth-h}}$ 分别为调节空间距离和灰度值之间的平滑参数^[2]。根据光伏组件故障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，完成光伏组件故障图像的滤波去噪处理。

1.4 智能提取光伏组件故障图像特征

选择机器学习算法中的卷积神经网络提取光伏组

件故障图像特征。卷积神经网络是一种非常有效的深度学习算法，特别适用于图像处理任务。光伏组件故障图像中的特征通常包括不同的纹理、形状和颜色等信息。卷积神经网络能够通过多层卷积和池化操作，自动提取并学习这些抽象的、高级的图像特征。相比传统的特征提取方法，CNN 在提取多层次、多尺度的特征方面更为强大。卷积神经网络是端到端的学习方法，能够将原始的图像数据直接输入网络进行训练，不需要手工设计和选择特征。对于复杂的故障图像，常规的特征提取算法可能无法充分捕捉故障的表现形式。通过使用 CNN，可以让网络自己在大量的训练数据上学习到最优的特征表示，从而更好地适应光伏组件故障图像的分类、检测和诊断等任务。

设计利用卷积神经网络提取光伏组件故障特征流程，如图 2 所示。

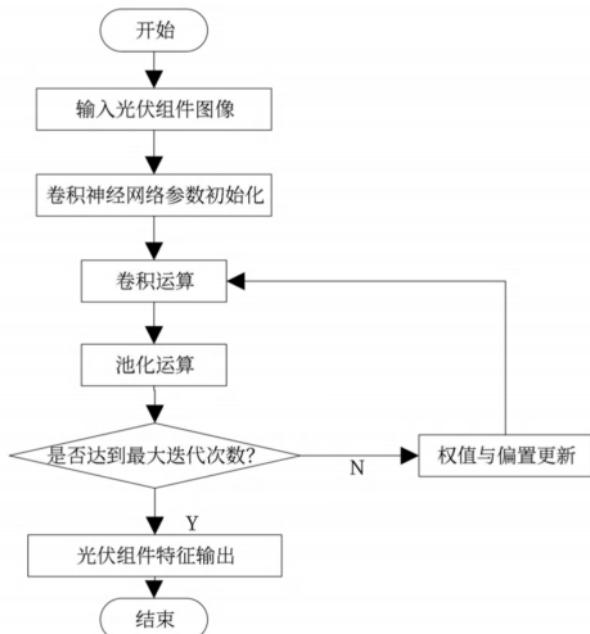


图 2 利用卷积神经网络提取故障图像特征流程图

1.5 实现光伏组件故障图像诊断

以上节提取的光伏组件故障特征为基础，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。通过特征匹配的方式度量当前光伏组件图像故障特征与标准特征之间的相似度，可以实现对故障的检测、分类和定位等任务。通过比较图像特征，可以识别出具有相似故障特征的图像，指导对应的维修或替换措施。此外，特征匹配还可以用于故障预测和监测，通过与历史数据进行对比，及时发现和预警潜在的故障情况。相似度计算如下：

$$s = \frac{\tau \cdot \tau_{\text{colour}}}{\|\tau\| \cdot \|\tau_{\text{colour}}\|} \quad (3)$$

将相关数据代入到式中，若计算得出特征相似度高于阈值，说明当前图像中包含故障，否则认为当前图像不属于故障图像，即光伏组件中不存在故障。

在此基础上，确定图像中的故障的几何参数和位置信息，其中几何参数的诊断结果为：

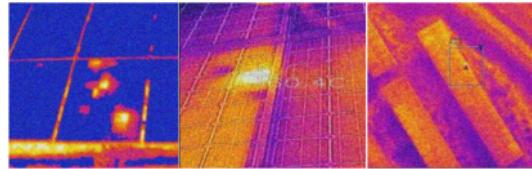
$$A = \pi \left(\frac{D_{\text{edge-max}} - D_{\text{edge-min}}}{2} \right)^2 \quad (4)$$

式中， $D_{\text{edge-max}}$ 和 $D_{\text{edge-min}}$ 分别为最远和最近的边缘节点； $D_{\text{edge-max}} - D_{\text{edge-min}}$ 为光斑半径，确定图像中故障位置的诊断结果，最终以可视化的形式输出光伏组件故障图像的诊断结果。

2 实验设计与结果分析

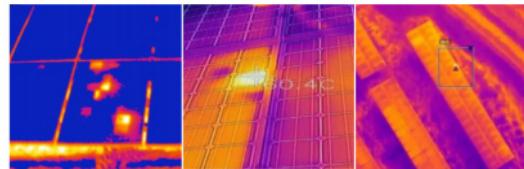
此次实验选择某光伏发电厂的光伏组件作为研究对象，该区域的光伏组件以晶硅电池作为核心设备。选择 FLIR E4 手持式红外热像仪拍摄光伏组件红外热图像。手持式红外热像仪通常较为便携且易于操作，适用于现场使用。对于一般的光伏组件故障诊断，常规型号的手持式热像仪通常已经足够满足需求。

利用不同方法处理采集的光伏组件图像样本，效果如图 3~ 图 6 所示。



(a) 样本 1 (b) 样本 2 (c) 样本 3

图 3 光伏组件红外原图



(a) 样本 1 (b) 样本 2 (c) 样本 3

图 4 研究方法下光伏组件红外图像

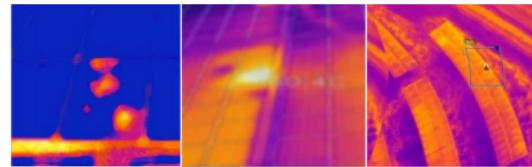


图 5 文献 [3] 方法下光伏组件红外图像

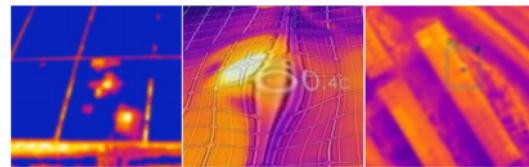


图 6 文献 [4] 方法下光伏组件红外图像

为进一步统计不同方法的应用性能，以漏检率、误检率作为实验测试指标，指标的计算如下：

$$\begin{cases} \eta_{\text{false detection}} = \left(\frac{n_{\text{hot spot}} - n_{\text{out}}}{n_{\text{all}}} \right) \times 100\% \\ \eta_{\text{missed detection}} = \left(\frac{n_{\text{error}}}{n_{\text{all}}} \right) \times 100\% \end{cases} \quad (5)$$

式中， $n_{\text{hot spot}}$ 为光伏组件故障图像样本的数量； n_{out} 为诊断为故障图像的样本数量； n_{error} 为诊断错误的图像样本数量； n_{all} 为总样本数量。

不同方法的漏检率、误检率对比如图7和图8所示。

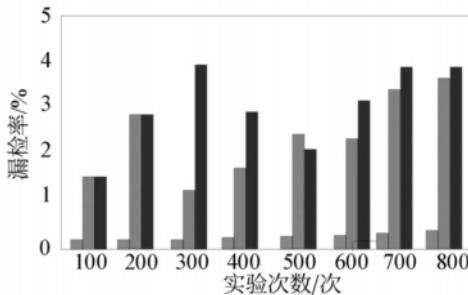


图 7 不同方法的漏检率对比

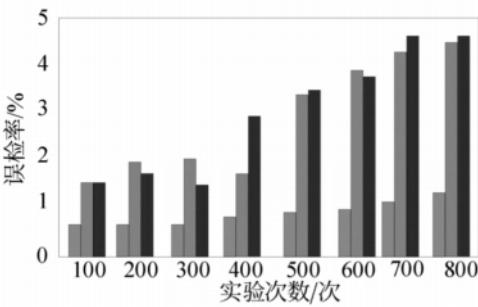


图 8 不同方法的误检率对比

根据图 7 和图 8 的实验数据统计结果可知，研究方法下光伏组件故障诊断的漏检率和误检率均低于 1%，具有更理想的应用效果。

3 结束语

本文提出了一种基于样本生成技术的光伏组件故障智能诊断方法。该方法通过样本生成技术，能够增加光伏组件故障样本的数量和多样性，有效地克服了数据稀

缺和标注困难的问题。通过对红外图像的滤波去噪和卷积神经网络的智能特征提取，可以准确捕捉故障图像中的关键信息，提高故障诊断的准确性。特征匹配的方式则能够度量故障特征与正常特征之间的相似度，进一步判断光伏组件的故障状态。

参考文献

- [1] 孙明正, 李浩. 一种基于 ResPNet 的光伏组件红外成像故障检测方法 [J]. 激光与光电子学进展, 2023, 60 (24) : 201-209.
- [2] 姜萍, 王天亮, 栾艳军. 基于改进 SSD 的光伏组件故障定位检测 [J]. 激光杂志, 2022, 43 (5): 43-48.
- [3] 李莎, 陈泽华, 刘海军. 基于 ST-TCN 的太阳能光伏组件故障诊断方法 [J]. 电子技术应用, 2022, 48 (12) : 79-83, 88.
- [4] 孙建波, 王丽杰, 麻吉辉, 等. 基于改进 YOLO v5s 算法的光伏组件故障检测 [J]. 红外技术, 2023, 45 (2) : 202-208.

(收稿日期：2024-03-22)