

基于深度学习算法的风电机组叶片开裂缺陷分析

董礼, 韩则胤, 王宁, 王恩路, 苏宝定

(中国广核新能源控股有限公司, 北京 100000)

摘要: 为实现对风电机组叶片表面缺陷检测的智能化, 该研究应用无人机技术、图像视觉技术和深度学习算法, 建立风电机组叶片缺陷检测系统, 提高了对叶片上开裂缺陷的检测精度; 系统使用 sobel 算子计算图像横向和纵向的梯度, 并对图像进行阈值分割和去噪处理; 构建深度学习模型提取图像缺陷的特征信息, 加入了 SPP-Net 网络进行卷积操作, 增加了模型的输入数据尺度, 得到特征图后在利用 PRN 网络筛选特征图; 实验结果显示该研究系统能够去除大量无用的背景信息, 开裂缺陷部位的特征信息保留完整, 对验证集中的图像进行测试后, 该研究系统识别出的开裂缺陷数最高可达到 50 个。

关键词: 风电机组叶片; 缺陷检测; 无人机技术; 阈值分割; 去噪处理; 深度学习模型

Crack Defect Analysis of Wind Turbine Blade Based on Deep Learning Algorithm

DONG Li, HAN Zeyin, WANG Ning, WANG Enlu, SU Baoding

(CGN New Energy Holdings Co., Ltd., Beijing 100000, China)

Abstract: In order to realize the intelligent detection of the surface defects of wind turbine blades, the research technologies of unmanned aerial vehicle (UAV), the image vision and deep learning algorithms are applied to establish the wind turbine blade defect detection system, which improves the detection accuracy of cracking defects on the blades. The system uses the sobel operators to calculate the horizontal and vertical gradients of the image, and performs threshold segmentation and denoising processing on the image. This paper constructs a deep learning model to extract the feature information of image defects, joins the SPP-Net network for convolution operation, increases the input data scale of the model, and uses the PRN network to filter the feature map after obtaining the feature map. The experimental results show that the research system can remove a large amount of the useless background information, and the characteristic information of the cracking defects is completely kept. After testing the images in the verification set, the number of cracking defects identified by the research system can reach up to 50.

Keywords: wind turbine blade; defect detection; uav technology; threshold segmentation; denoising; deep learning model

0 引言

我国可供开发的风能资源大约在 10 亿千瓦, 为加强对风能资源的开发利用, 截止到 2020 年底, 全年新增风电装机超过 7 100 万千瓦, 成为目前应用最广泛和发展最快的新能源发电技术^[1]。由于风电设备大多数安装在偏远地区, 风电机组的工作环境恶劣并且气候环境复杂, 经常受到大风、雷电、雨雪等天气的影响, 导致风电机组故障频发, 对机组叶片造成损伤^[2]。

在对风电机组叶片缺陷检测中, 文献 [3] 系统利用声发射技术, 基于能量的等高线图判断风机叶片的损伤程度, 并应用新的源定位方法对缺陷部分定位。文献 [4] 系统通过部署大量传感器组成传感器网络, 实时采集机组叶片的声信号, 对叶片的实时结构健康进行监测。文献 [5] 系统结合有限元法和反卷积分离法, 利用叶片的振动信号检测风机的损伤状态, 确定叶片的损伤位置。文献 [6] 系统通

过应变感应器来检测风机叶片在外界作用下产生的形变, 安装在叶片表面或叶片层, 间接检测风电机组的结构损伤。当前的研究中需要借助大量多种类型的传感器设备, 对叶片状态进行监测, 提高了系统的检测成本和复杂程度, 同时传感器获得的信号容易受到环境噪声的影响, 进一步影响了系统对风机叶片缺陷的分析和识别的精度。

1 基于无人机图像采集的风电机组叶片缺陷检测系统

该研究将无人机技术和图像视觉技术应用在对风机叶片的缺陷检测上, 采用高分辨率的相机和无人机对风电机组叶片图像进行采集, 获取到清晰且完整的叶片信息, 比人工巡检的方式更具安全性和效率。采集到风机叶片的图像越清晰, 包含的叶片缺陷信息更加丰富, 该研究系统使用深度学习模型能够更好地提取出叶片表面开裂的缺陷特征, 更加精确的定位缺陷位置^[7]。该研究系统使用基于

收稿日期: 2021-12-05; 修回日期: 2022-01-06。

作者简介: 董礼 (1981-), 男, 辽宁锦州人, 博士, 高级工程师, 主要从事算法方向的研究。

引用格式: 董礼, 韩则胤, 王宁, 等. 基于深度学习算法的风电机组叶片开裂缺陷分析[J]. 计算机测量与控制, 2022, 30(8): 142-146, 154.

ONESTAGE 的 YOLOv5 目标检测算法, 能够直接产生目标叶片缺陷的类别概率和位置坐标值, 提高了对风机叶片的目标检测速度^[6]。基于无人机图像采集的风电机组叶片缺陷检测系统结构如图 1 所示。




图 1 风电机组叶片缺陷检测系统结构

该研究设计时, 在结构上可分为采集层、数据层、服务层和应用层。通过不同层次结构实现风电机组叶片数据的采集、传递、计算、分析与计算。满足用户从底层风电机组叶片的运行状态开始, 进行远程数据信息监控, 有效地将风电机组叶片的运行状态的宏观数据信息, 转换为直观的数据显示, 提高了风电机组叶片缺陷检测效率。

采集层利用全自主巡检模式的无人机完成风电机组叶片表面的全面覆盖图像的采集, 采用低速、定点航拍的方式, 在巡检过程中通过无线传输网络将采集到的叶片缺陷图像传输到系统的数据层。为防止无人机与叶片距离过近发生碰撞事故, 在无人机上安装有红外激光传感器, 用来探测无人机前方水平 60° , 距离 30 m 之内的所有物体, 通过设定距离阈值保证无人机在图像采集过程中的飞行安全, 当小于阈值距离时发生报警信号自动向相反方向飞行并恢复安全飞行距离^[9]。在具体设计时, 通过无人机携带不同的电子设备信息实现风电机组叶片缺陷的巡检采集, 无人机体积小, 重量轻, 能够实现人力无法企及的高空场合或者高危区域。通常包括飞机平台系统、信息采集系统和地面控制系统等, 能够将高空或者高危区域数据信息带回地面, 实现数据远距离交互, 提高了作业工作效率。

数据层完成叶片缺陷图像的存储和预处理, 并向应用层提供数据访问接口, 数据层使用具有多个计算引擎的分布式数据库 HIVE, 能够兼容多种数据存储格式, 并支持时间复杂程度较高的数据结构^[10]。数据层可以设置外设接

口, 比如远程无线通信接口、USB 数据接口、CAN 数据总线等, 通过这种方式, 能够实现无人机采集数据与外设设备多种数据交互与共享, 必要时, 在数据局层可以设置数据管理软件, 以提高风电机组叶片缺陷检测数据管理效率。

应用层使用支持可视化操作的 LABELIMG 工具来标注图像中的缺陷信息, LABELIMG 工具并且支持源码编译安装, 可以直接下载系统对应打包好的文件, 在 DATA_CLASSES 路径文件下定义训练好的使用类的列表, 使用 OPENDIR 选择叶风电机组叶片图像的目录, 在 CHANGE_SAVEDIR 中自定义生成标注文件的保存位置。对图像中叶片开裂缺陷的位置进行选择, 并标注损伤程度完成后对标注就信息进行保存, 输出 XML 格式的标注文件。标注文件的标注信息包括图像路径、名称、图像分辨率、通道数量、缺陷坐标和损伤程度等信息。

本研究设计中, 可以将服务层与应用层结合起来应用, 或者将应用层划分为不同的数据模块, 比如具有服务功能的多种数据管理模块。比如可视化管理模块、分类管理模块、交互模块、故障处理模块等。

2 叶片开裂缺陷图像的高精度检测方法

在无人机自动巡检过程中, 大规模风机叶片图像和视频的数据传输可能会造成网络拥堵, 并且上传到系统数据层的图像或视频数据并不是完全有用的, 图像过于模糊、叶片图像的有效面积过小影响系统对叶片缺陷的分析效果, 同时增加了系统数据库的存储资源。该研究设计出风机叶片开裂缺陷的检测模型, 对采集到的图像质量进行检测, 过滤掉运动模糊和低质量的不适合作为训练数据的叶片图像^[11]。

2.1 清晰度检测

通常, 从无人机输出的数据信息由于外界噪声的干扰, 数据信息不纯净, 容易使采集到的数据信息在后续计算过程中误差大, 不准确程度高。针对该方法, 该研究使用图像边缘锐度评价无人机采集到的叶片图像, 通过 sobel 算子计算图像梯度, 采用 Tenegrad 梯度函数衡量图像的清晰度, 通过这种方式, 能够将获取的数据信息特征提取出来, 在对提取的数据特征进行分析, 以提高数据分析精度。为了量化采集到的宏观数据量, 该研究采用了数据思维的方式, 以具体化通过无人机技术采集到的叶片开裂缺陷图像数据信息。梯度计算可表示为:

$$G_x = \begin{bmatrix} 1 & 0 & -1 \\ -2 & 0 & -2 \\ -1 & 0 & -1 \end{bmatrix} * I$$

$$G_y = \begin{bmatrix} 1 & -2 & -1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * I \quad (1)$$

式中, G_x 表示图像像素横向梯度, G_y 表示图像像素纵向梯度, I 表示图像的灰度值。

通过该公式, 能够计算出叶片开裂缺陷图像信息的灰度值, 基于灰度值的计算结果, 能够评判采集到叶片开裂

缺陷图像的精度。通过上述计算后，再计算叶片开裂缺陷图像的清晰度。计算图像的清晰度可表示为：

$$F_T = \frac{1}{m \times n} \sum_m \sum_n (G_x^2(x,y) + G_y^2(x,y)) \quad (2)$$

式(2)中， F_T 表示清晰度评价算子， m 表示叶片缺陷图像的长度， n 表示叶片缺陷图像的宽度， (x,y) 表示图像的像素点坐标^[12]。

通过该公式，清晰度评价算子、叶片缺陷图像的长度、叶片缺陷图像的宽度等因素是影响叶片开裂缺陷图像清晰度的关键性因素，当然，在实际应用中，还会存在其他因素，出于篇幅的限制，本研究不再考虑一些非关键因素，将清晰度计算融入上述清晰度评价算子、叶片缺陷图像的长度、叶片缺陷图像的宽度等因素能够从本质上分析影响清晰度评价算子、叶片缺陷图像的长度、叶片缺陷图像精度的能力。系统通过设置合理的阈值，计算出的清晰度算子高于系统阈值时被认定为满足叶片开裂缺陷分析的图像要求，低于阈值的图像不会保存在系统数据库。

2.2 缺陷图像有效面积检测

无人机采集到风电机组叶片图像的有效面积是指叶片上开裂缺陷的面积，叶片像素点在整个图像总像素点的比例大小影响缺陷检测的精度。两种不同叶片面积占比的图像如图 2 所示。



图像1

图像2

图 2 不同叶片面积占比的图像

图像 1 中的叶片占比面积超过 80%，能够清晰地观察到叶片上的开裂缺陷，图像 2 的叶片占比面积不足 20%，包含的缺陷信息较少，需要进行图像分割和去噪处理。图像转换可表示为：

$$F(i,j) = 0.30R(i,j) + 0.59G(i,j) + 0.11B(i,j) \quad (3)$$

其中： $F(i,j)$ 表示转换后的灰色图像， R 表示图像的红色通道， G 表示图像的绿色通道， B 表示图像的蓝色通道^[13]。

通过上述分析，将采集到的图像数据信息切割成小模块结构，将图像信息转换为可以矢量数据信息，提高了计算能力。通过式(3)能够将提取到的叶片开裂缺陷图像数据信息，清晰地展示叶片上的开裂缺陷。

由于图像像素具有不连续的特性，因此根据像素的灰度值进行阈值分割，将叶片图像和背景分隔开，使用最大类间方差法进行阈值分割，计算初始阈值分割两组像素点的灰度值的方差，可表示为：

$$\sigma^2 = \omega_0 \omega_1 (\mu_0 - \mu_1)^2 \quad (4)$$

式中， ω_0 表示叶片像素占比， ω_1 表示背景像素占比， μ_0 表示

叶片像素的平均灰度值， μ_1 表示背景像素的平均灰度值^[14]。

通过式(4)能够将采集到的叶片开裂缺陷图像数据信息中信息与背景信息分离出来，这种方法能够分析雨、雪、雾、雨等恶劣天气下的图像信息，这就提高了该研究技术应用的范围，任意恶劣天气下所采集到的图像信息都能够清楚地将采集到的重要信息分离出来。该研究在分离时，还使用方差最大的阈值进行图像分割，经过阈值分割后的风机叶片图像如图 3 所示。



图 3 阈值分割后的风机叶片图像

再通过形态学图像处理去除图像中的噪点，膨胀计算和腐蚀计算可表示为：

$$\begin{aligned} A \oplus B &= \{x,y | (B)_{xy} \cap A = \phi\} \\ A \otimes B &= \{x,y | (B)_{xy} \subseteq A\} \end{aligned} \quad (5)$$

其中： A 表示进行运算的图像元， B 表示结构元。开运算通过先腐蚀计算再膨胀计算的方式，闭运算通过先膨胀计算再腐蚀计算的方式，去除叶片图像中的黑色噪点，将完整的叶片图像进行分离并去噪^[15]，图像的有效面积可表示为：

$$R = \frac{K}{M \times N} \quad (6)$$

式(6)中， R 为有效面积的比例， $M \times N$ 表示图像大小， K 表示叶片像素点数。当 R 大于 50% 时，无人机采集到的风机叶片图像才能够保存到系统数据库中，上传到深度学习模型中进行计算。

3 基于深度学习算法的叶片缺陷图像检测

在对处理后的风电机组叶片图像的缺陷部分进行识别和检测时，传统的神经网络模型在面对大量数据时无法及时提取图像信息。本研究采用深度学习算法能够获取更深层次的数据信息，在具体计算时，该研究将处理后的风电机组叶片图像建立为原始数据集，利用深度学习模型自动提取图像缺陷的特征信息，对图像中开裂缺陷进行识别和检测。叶片缺陷图像检测过程如图 4 所示。

为了增加深度学习网络模型的输入数据尺度，加入了 SPP-Net，SPP-Net 是一种可以不用考虑图像大小，输出图像固定长度网络结构，并且可以做到在图像变形情况下表现稳定。SPP-net 的效果已经在不同的数据集上面得到验证，速度上比 R-CNN 快 24~102 倍。通过这种方法改进了网络模型能够直接进行卷积操作，对输入特征图的每个通道分别使用一个卷积核，将所有卷积核的输出再进行拼接，最终输出特征图^[16]。正常的深度网络由两部分组成，卷积部分和全连接部分，要求输入图像需要固定 size 的原因并不是卷积部分而是全连接部分。所以 SPP 层就作用在最后

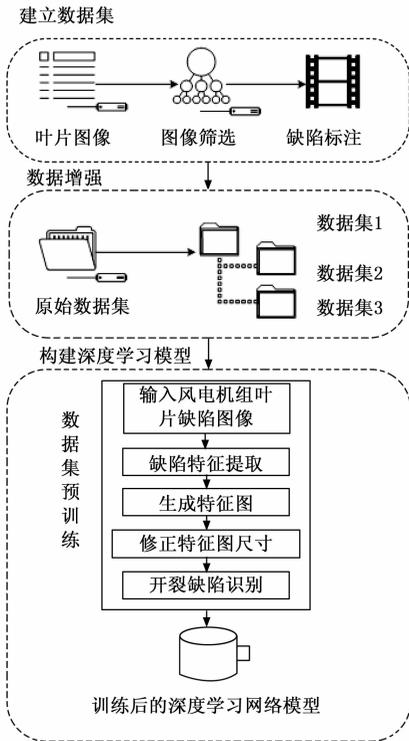


图 4 叶片缺陷图像检测过程

一层卷积之后, SPP 层的输出就是固定大小。

首先将风机叶片图像输出到深度学习网络模型, 通过对图像的五层卷积操作得到特征图后在利用 PRN 网络筛选特征图, 该方法专门用来提取候选框, 在 RCNN 和 Fast RCNN 等物体检测架构中, 用来提取候选框的方法通常是 Selective Search。然后利用特征图进行矩形框回归。网络模型的分割损失具体表示为:

$$L_{\text{mask}} = \sum_y y \log(1 - \hat{y}) + (1 - y) \log(1 - \hat{y}) \quad (7)$$

其中: y 表示叶片图像二值化的结果, 图像的二值化处理就是将图像上的点的灰度值为 0 或 255, 也就是将整个图像呈现出明显的黑白效果。即将 256 个亮度等级的灰度图像通过适当的阈值选取而获得仍然可以反映图像整体和局部特征的二值化图像。 \hat{y} 表示图像预测结果^[17]。 L_{mask} 使深度学习网络能够输出图像的每一个类, 并在每个像素点上应用激活函数计算像素的交叉熵值得到分割损失。在卷积过程中, 每个风电机组叶片图像对应的特征图空间位置中的每个点进行一次卷积操作, 深度可分离卷积可表示为:

$$CC_D = D_k \times D_k \times M \times D_f \times D_f + M \times N \times D_f \times D_f \quad (8)$$

式中, D_k 表示单个卷积核尺寸, M 表示卷积核数量, $M \times D_f \times D_f$ 表示输入特征图的尺寸, $N \times D_f \times D_f$ 表示输出特征图的尺寸。模型中卷积层输入向量为 $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_i\}$, 输入向量 x_i 的高度为 h_i 、宽度为 w_i 、通道数为 n_i , 卷积层由 N 个三维滤波器 ξ_i 组成^[18], 卷积层的运算量高达 $n_i n_{i+1} k^2 h_i w_i$ 。卷积层输入的向量为 $\mathbf{Y} = \{y_1, y_2, y_3, \dots, y_i\}$, 输出向量的的高度为 h_{i+1} 、宽度为 w_{i+1} 、通道数为 n_{i+1} 。经过多层卷积后输出

结果, 图像中的开裂缺陷能够精准被检测到, 优化了的叶片损伤检测错检、相邻损伤遮挡检测效果不佳的问题, 并且取得了较好的检测效果^[19-21]。

4 应用测试

4.1 搭建实验环境

该研究在 Windows 10 操作系统上搭建实验仿真环境, 采用 KERAS 和 TensorFlow 实验框架, 系统客户端使用的处理器为 Intel (R) Core (TM) i7-8750H, 显卡为 NVIDIA GeForce GTX 1080。在实验平台中安装 ANA-CONDA 环境管理器, 集成了常用的 Python、Conda、Numpy 等函数库, 能够更好地管理开发环境, 搭建深度学习网络模型^[21-22]。

4.2 实验数据准备

该研究实验的数据来源为某风力发电厂无人机巡检拍摄到的部分风机叶片图像, 风机叶片表面具有常见的开裂、腐蚀、涂层脱落等缺陷类型, 总共有 31 526 张图像。由于采集到的部分图像的背景信息较为复杂, 有些图像中不包含缺陷部分, 需要对图像进行筛选并删去无关信息, 从大量图像中挑选出 2 000 张缺陷特征明显, 有效面积超过 30% 的图像作为实验的原始数据集。原始数据集参数如表 1 所示。

表 1 原始数据集参数

类型	参数
数量	2 000
图像分辨率	1 280 * 960
数据集大小	2 481 MB
位深	16 bit
颜色数	256

通过 CreatePolygons 对叶片图像绘制标注框, 标注对应的缺陷类型, 将图像和标准信息共同保存为 json 文件, 将所有的样本图像存储在实验文件夹下。叶片图像缺陷标注界面如图 5 所示。

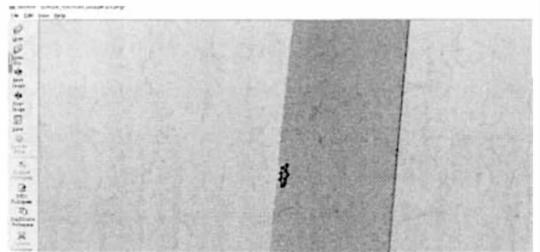


图 5 叶片图像缺陷标注界面

4.3 实验测试

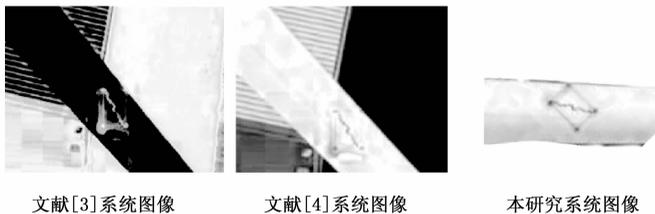
为验证该研究系统的性能, 分别使用文献 [3] 系统、文献 [4] 系统和该研究系统进行实验。从原始数据集中随机选取一张风电机组叶片图像, 经过缺陷标注后作为实验测试图像, 实验测试图像如图 6 所示。

实验测试图像中存在较多的背景信息, 为增强模型对图像的识别精度, 使用 3 种系统对实验测试图像进行处理,



图 6 实验测试图像

得到图像增强后的实验图像如图 7 所示。



文献[3]系统图像

文献[4]系统图像

本研究系统图像

图 7 处理后的实验图像

文献 [3] 系统处理后的实验测试图像去除了大部分背景信息，通过明暗反转的方式增强了风电机组叶片上开裂缺陷的特征，但图像增强后的画面对比度过高，失去了叶片表面其他部分的细节信息，仍可能存在较小的缺陷尚未被发现。文献 [4] 系统处理后的图像保留了叶片的全部信息，叶片画面的对比度明显增加，但黑色背景图像和白色叶片图像中可能存在噪点，图像的亮度过高导致部分缺陷特征细节丢失^[22-23]。

该研究系统去除了叶片图像的全部背景信息，并对图像进行阈值分割和校正，得到了更加明显的开裂缺陷特征，并保证了叶片图像的明暗变化，根据图像的像素灰度值变化获取叶片轮廓，并过滤掉了大部分噪声，对图像的处理效果更好，提高了后续缺陷检测的精度^[24-25]。

对原始数据集中的叶片图像标记完成后，Imagesets 文件夹中有 200 张叶片缺陷图像，其中包含开裂缺陷、磨损缺陷、脱落缺陷、雷击缺陷和多类别损失缺陷，将数据分为训练集、测试集和验证集，使用训练集中的数据对深度学习网络模型进行训练。使用训练好的模型进行开裂缺陷识别测试，文献 [3] 系统和文献 [4] 系统进行对比，将验证集中的图像分为 6 组，识别验证集中的开裂缺陷图像数量如图 8 所示。

对验证集中每一组实验图像进行测试后，该研究系统识别出开裂缺陷图像的数量最多，深度学习网络模型的缺陷检测效果最好，其中识别到第四组的开裂缺陷数量高达 50 个，第六组的开裂缺陷数为 24 个。

文献 [3] 系统检测到第一组的图像的叶片开裂缺陷数最多，最高达到 40 个，第二组和第六组识别到的缺陷数量低至 20 个。文献 [4] 系统检测到开裂缺陷数量最高为 35 个，识别到第六组图像的缺陷数量最少为 18 个。文献 [3] 系统和文献 [4] 系统的对叶片图像中缺陷的识别精度较

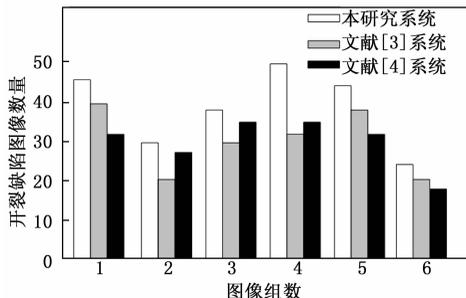


图 8 识别到开裂缺陷图像数量

低，不能较好地提取出图像的缺陷特征，受到图像质量、亮度和对比度的影响较大，图像过亮或过暗导致叶片缺陷处的信息较少，造成系统对叶片缺陷识别效果不好。

5 结束语

该研究设计出风电机组叶片缺陷检测系统，使用无人机完成风电机组叶片图像的采集任务，采用深度学习算法对叶片图像进行缺陷检测分析，并在图像上标注开裂缺陷位置。该研究的创新点在于：

1) 对无人机采集到的叶片缺陷图像进行高精度检测，采用 Tenegrad 梯度函数计算图像的清晰度评价算子，对叶片占比较小的图像进行灰度化处理，使用最大类间差法进行阈值分割再计算有效面积。

2) 建立深度学习网络模型，使系统自动提取图像的缺陷特征，引入了 SPP-Net 网络直接进行卷积再进行特征映射，加快了图像数据处理速度，提高了模型的检测效率。

该研究仍存在一些不足之处还需进一步改进，系统仅对风机叶片的开裂缺陷进行检测，在后续研究中考虑增加系统的风机叶片缺陷数据集，对叶片上的更多类型的缺陷进行检测。

参考文献：

- [1] 张成旭. 风电叶片芯材蒙皮微裂纹产生原因及缺陷的消除 [J]. 天津科技, 2021, 48 (10): 59-60, 63.
- [2] 蒋菲, 赵朝友, 张素慧. 基于 CEEMDAN 能量熵和 SVM 的风电叶片缺陷检测 [J]. 无损检测, 2021, 43 (6): 36-40.
- [3] 董健, 柳亦兵, 滕伟, 等. 基于 BP_Adaboost 算法的风电机组叶片结冰检测 [J]. 可再生能源, 2021, 39 (5): 632-636.
- [4] 海涛, 范恒, 王楷杰, 等. 基于 PSO-SVM 算法的风电机组结冰故障诊断 [J]. 智慧电力, 2021, 49 (4): 1-6, 74.
- [5] 马宝珠, 汤磊, 赵晶, 等. 风电叶片图像直线特征检测与拼接方法 [J]. 哈尔滨理工大学学报, 2020, 25 (5): 83-92.
- [6] 傅天航, 刘松平, 刘菲菲, 等. 复合材料桨叶无损检测技术研究进展 [J]. 工程塑料应用, 2020, 48 (10): 162-166, 171.
- [7] 王雪平, 张建斐, 李万润, 等. 基于机器视觉的风电叶片风沙侵蚀程度检测方法研究 [J]. 太阳能学报, 2020, 41 (5): 166-173.

(下转第 154 页)