

# 基于无人机的风机叶片表面缺陷自动检测方法

闫浩伟

(大唐山西新能源公司, 山西 太原 030000)

**摘要:** 风机叶片是风力发电系统的核心部件, 在受到气候条件、工作负荷等因素的影响后, 容易出现各类缺陷, 如裂纹、磨损、腐蚀等; 如果不能及时发现和解决这些缺陷, 将导致风机性能下降、损坏甚至引发安全事故; 为此, 研究一种基于无人机的风机叶片表面缺陷自动检测方法; 利用无人机搭载摄像机, 拍摄空中运行的叶片图像; 对叶片图像实施灰度化、去噪以及照度均衡化处理, 提升图像质量; 提取叶片图像中的几何特征和纹理特征, 利用差异演化算法改进概率神经网络平滑参数, 以优化后的概率神经网络为基础构建分类识别模型, 将几何特征和纹理特征作为输入, 计算每种类别的输出概率, 将最大值响应原则将概率数值最大的类别作为判定的缺陷类别, 以此实现风机叶片表面缺陷自动检测; 结果表明: 所研究技术应用下, 杰卡德系数可以达到 0.982 3, 说明该方法的检测结果更为准确; 所花费时间低于 15.69 s, 说明该方法的检测效率更高, 可以更快地完成检测任务。

**关键词:** 无人机; 风机叶片; 特征提取; 改进概率神经网络; 缺陷自动检测技术

## Automatic Detection Method for Surface Defects of Fan Blades Based on Drones

YAN Haowei

(Datang Shanxi Renewable Power Company, Taiyuan 030000, China)

**Abstract:** Wind turbine blades are the core components of wind power generation systems, after the influences of climate conditions, working loads, they are prone to various defects such as cracks, wear, corrosion, etc. If these defects can not be detected and resolved in a timely manner, it will lead to a decrease in fan performance, damage, and even safety accidents. To this end, an automatic detection method for surface defects of fan blades based on drones is studied. the drones equipped with cameras are used to capture the images of blades running in the air. The images of blades are implemented grayscale, denoising, and illumination equalization processing to improve image quality and extract geometric and texture features from blade images, differential evolution algorithms are used to improve the smoothing parameters of probabilistic neural networks, present the classification recognition model based on the optimized probabilistic neural network, and calculate the output probability of each category by taking geometric and texture features as inputs. According to the principle of maximum value response principle, the category with the highest probability value is used to determine the defect category, and achieve automatic detection of surface defects on fan blades. The results show that under the application of the studied technology, the Jaccard coefficient can reach up to 0.982 3, indicating that this method has more accurate detection results; The running time is less than 15.69 s, indicating that this method has a higher detection efficiency and can effectively achieve detection tasks.

**Keywords:** drones; fan blades; feature extraction; improved probabilistic neural networks; automatic defect detection technology

## 0 引言

风力发电是目前缓解能源短缺问题的典型措施之一, 发电原理是借助风力发电机将自然界中的风能转换为电能。叶片是风力发电机中的重要组成部件之一<sup>[1-2]</sup>, 风力发电机的叶片巨大, 需要建造在广阔的野外, 当有风吹过, 带动叶片转动, 从而产生电力<sup>[3]</sup>。而风力发电机长期处在野外恶劣环境条件中, 叶片很容易受到侵蚀和损害, 导致出现各种缺陷, 如雷击损伤、表面开裂、局部脱落、凹坑、覆冰、砂眼、腐蚀、脱胶等。这些缺陷若不能及时处理和修复, 长期下去将直接影响风电机组的正常工作, 甚至引

发电力事故。面对上述情况, 对风机叶片定期进行缺陷检测是十分必要的。

为此, 相关学者对风机叶片实施检测。文献 [4] 针对覆冰缺陷进行了检测研究, 该研究中首先采集基础数据并实施预处理, 然后从数据中提取并筛选出合适特征向量作为输入, 利用改进 Adaboost-SVM 模型实现分类检测。这种检测方法的优点是高效率、操作简单、覆盖面积广, 但是查准率方面仍有很大的提升空间。文献 [5] 针对裂纹缺陷进行了检测研究, 该研究首先采集了风机叶片的图像并实施了灰度化, 双边滤波以及 Sobel 边缘检测等预处理, 然

收稿日期: 2024-02-19; 修回日期: 2024-06-17。

作者简介: 闫浩伟(1975-), 男, 大学本科, 高级工程师。

引用格式: 闫浩伟. 基于无人机的风机叶片表面缺陷自动检测方法[J]. 计算机测量与控制, 2024, 32(11): 72-79.

后提取图像中的 LBP 特征和 GLCM 纹理并将二者融合到一起, 最后通过改进萤火虫算法改进后的 SVM 分类模型进行分类识别, 检测出裂纹缺陷。这种方法的优点是查准率和查全率较高, 缺点检测效率相对较低。文献 [6] 采集了 VOC 格式的叶片图像, 然后利用 EfficientDet 算法中的主干特征提取图像中的多尺度特征并进行融合, 最后基于 FReLU 实现了风机叶片缺陷检测。这种方法的优点是对叶片上小尺寸缺陷也能识别出来, 但是适用范围有限, 如针对裂纹、凹坑等缺陷检测效率相对较低。

针对前人研究存在的不足, 为进一步提高风机叶片缺陷自动检测工作质量, 研究一种基于无人机的风机叶片表面缺陷自动检测方法。该方法利用无人机采集全局视野的风机叶片图像, 以获取包含全部叶片信息的高分辨率图像, 采集的图像更全面、更准确。通过灰度化、去噪和照度均衡化等预处理操作, 能够提高图像质量, 增强图像中的目标信息, 并减少图像中的噪声和干扰, 提高后续特征提取和缺陷检测的准确性。几何特征和纹理特征的提取可以全面描述叶片的形态和细节信息, 其中, 几何特征可以帮助区分不同类型的缺陷, 而纹理特征可以揭示缺陷的表面纹理特点。这些特征能够提供更全面、更准确的信息, 对于缺陷的检测和分类具有重要作用。概率神经网络具有强大的自学习能力, 能够根据提供的训练数据自适应调整权重和偏置, 优化网络模型, 可以学习和识别不同类型的叶片缺陷, 提高检测的效果, 为风机运行状态监测和维护提供了重要支持。

## 1 无人机风机叶片图像采集

风机叶片大部分都布设在荒郊野岭, 地理条件恶劣, 再加上叶片的巨大性, 使得人工检测工作难度非常大<sup>[7]</sup>。以往人工检测多采用目测检查方式, 即由检测人员借助高倍望远镜或叶片维修平台, 用肉眼逐个检查叶片。这种方法不仅检测效率低, 且由于人员需要亲自到现场, 因此还存在安全风险, 另外需要更多的人力物力配合, 因此检测成本较高<sup>[8]</sup>。面对这种情况, 随着无人机的出现, 为风机叶片缺陷自动检测工作带来巨大的便利。无人机上搭载摄像机, 飞到高空当中, 拍摄空中运行的叶片图像, 利用无人机拍摄图像, 最大的优点是可以进行跟踪拍摄, 而无需停止风机运行, 避免了停机对电力生产造成的干扰<sup>[9]</sup>。利用无人机采集风机叶片表面图像过程中有一个关键问题需要解决, 即无人机飞行路径规划。无人机的续航能力有限, 为提高图像采集效率, 对飞行路径进行规划是十分必要的<sup>[10]</sup>。在这里通过改进粒子群算法优化求解过程, 实现无人机采集图像过程中飞行路径规划。具体过程如下。

步骤 1: 确定待检测风机叶片所处区域以及各个风机在该区域中所处的位置坐标。

步骤 2: 建立三维飞行环境模型。

步骤 3: 定义航迹规划空间坐标, 即

$$\{(x, y, z) \mid 0 \leq x \leq x_{\max}, 0 \leq y \leq y_{\max}, 0 \leq z \leq z_{\max}\} \quad (1)$$

式中,  $(x, y, z)$  代表三维飞行环境模型中空间节点的坐标;  $x_{\max}$ 、 $y_{\max}$ 、 $z_{\max}$  代表三维坐标的最大值。

步骤 4: 确定最优飞行路径。定义路径由一系列节点序列组成的航迹段。

1) 设置粒子群算法初始参数。

2) 构建航迹代价函数。即:

$$A = w_1 a_1 + w_2 a_2 + w_3 a_3 + w_4 a_4 \quad (2)$$

式中,  $A$  代表航迹代价函数;  $w_1$ 、 $w_2$ 、 $w_3$ 、 $w_4$  代表权重参数;  $a_1$  代表避障行为函数;  $a_2$  代表最大转弯角限制函数;  $a_3$  代表航程代价函数;  $a_4$  代表航迹高程代价函数。

步骤 4: 采用最佳点集初始化的方法初始化种群, 种群中每个粒子都代表一种空间节点序列组合排列方式<sup>[11]</sup>。

步骤 5: 设定避障行为函数的取值范围为  $0 \sim 1$ ; 最大转弯角限制函数、航程代价函数和航迹高程代价函数的取值范围均为  $0.1 \sim 1$ 。根据公式 (2) 计算种群中每个个体的适应度值, 记为  $\hat{A}_\theta (\theta = 1, 2, \dots, n)$ , 代表第  $\theta$  个粒子的适应度。计算公式如下:

$$\hat{A}_\theta = \frac{(x, y, z) A \exp[A(x_\theta^k)]}{\exp\left[\frac{\sum_{\theta=1}^n A(x_\theta^k)}{n}\right]} \quad (3)$$

式中,  $A(x_\theta^k)$  代表第  $k$  次迭代时第  $\theta$  个粒子的航迹代价函数值;  $\hat{A}_i$  代表第  $\theta$  个粒子的适应度函数值。

步骤 6: 将  $\hat{A}_\theta (\theta = 1, 2, \dots, n)$  值与个体极值比较大小。当前者大于后者,  $\hat{A}_\theta$  替换并更新个体极值; 否则保持不变。

步骤 7: 将更新后种群中所有个体极值与全局极值比较大小。当前者大于后者, 个体极值替换并更新全局极值; 否则保持不变。

步骤 8: 更新粒子速度和位置, 记为  $v^{k+1}$ 、 $x^{k+1}$ 。

步骤 9: 回到步骤 5, 重复步骤 5~步骤 8 的过程, 直至  $k = k_{\max}$ ,  $k_{\max}$  为最大迭代次数。

步骤 10: 输出最优解, 也就是空间节点序列的最佳组合, 将这些空间节点连接到一起形成一条无人机飞行路径。

步骤 11: 采用 B 样条函数法消除无人机飞行路径的尖角, 实现平滑处理。

无人机一边按照飞行路径飞行, 一边利用搭载的摄像机拍摄风机叶片图像<sup>[12]</sup>。当遇到障碍物时, 进行避障, 然后回到飞行路径上, 继续执行飞行拍摄任务, 直至采集完成所有风机叶片图像。

## 2 风机叶片图像预处理

由于无人机采集的图像可能会受到光照、噪声等因素的影响, 需要进行预处理来提高图像质量。为此, 针对无人机采集到的风机叶片图像进行预处理, 使图像中包含的信息内容更加清晰的反映出来, 便于特征提取。通过图像灰度化处理将彩色图像转换为灰度图像, 增强图像的视觉对比度。为了进一步提高图像的清晰度和可读性, 采用改进均值滤波方法去除图像中的干扰信号, 利用光照滤波器

调整图像照度,使图像在视觉上更加舒适和自然,进而对叶片表面缺陷进行准确的检测和识别。

## 2.1 叶片图像灰度化

摄像机拍摄下来的原始叶片图像都是彩色的,彩色图像相较于灰度图像占内存更高,运算速度更慢,因此需要灰度化处理。此外不仅如此,灰度化后的图像可以增加视觉上的对比度,突出目标区域。彩色图像中每个像素颜色由  $R$ 、 $G$ 、 $B$  三个分量来决定,因此将彩色图像转换为灰色图像,也需要从这 3 个分量上进行操作,即取  $R$ 、 $G$ 、 $B$  三个分量均值代替原有值,将彩色图像变为单通道图像,灰度化后的图像灰度范围一般从 0 到 255<sup>[13]</sup>。表达式如下:

$$A(i, j) = \frac{1}{3} \hat{A}_0 [R(i, j) + G(i, j) + B(i, j)] \quad (4)$$

式中,  $A(i, j)$  代表灰度化后的图像像素;  $R(i, j)$ 、 $G(i, j)$ 、 $B(i, j)$  分别代表原始图像红、绿、蓝三色彩分量;  $(i, j)$  代表叶片图像像素位置坐标。

## 2.2 叶片图像去噪

噪声是图像采集过程中难以避免的一种问题,大部分采集到的原始图像都或多或少存在一定的噪声。噪声会造成图像中部分细节信息被掩盖,使得信息丢失<sup>[14]</sup>。为此对叶片图像机械能去噪同样必不可少。去噪方法选择为改进均值滤波方法。去噪过程如下:首先从待去噪的图像中随机选取一个像素点,记为  $p_i$ ,然后根据搜寻窗口搜寻  $p_i$  的相似集合  $Q_{(p_i)}$ ,集合中包含的邻域相似像素点记为  $p_j$ 。重复上述过程,得到了图像中每一个像素点的相似集合。定义两个相似集合之间的高斯加权欧氏距离。

$$d_{ij} = A(i, j) E \| Q_{(p_i)} - Q_{(p_j)} \|_{2\alpha}^2 \quad (5)$$

式中,  $d_{ij}$  代表高斯加权欧氏距离;  $Q_{(p_i)}$  代表邻域像素点  $p_j$  的相似集合;  $E$  代表灰度值向量;  $\alpha$  代表高斯核函数的标准差。根据  $d_{ij}$  计算相似集合内所有相似像素点的权重,即:

$$w_{ij} = \frac{\exp\left(-\frac{d_{ij}}{\beta}\right)}{\beta} \quad (6)$$

式中,  $w_{ij}$  代表像素点  $p_i$  与像素点  $p_j$  之间的权值;  $e$  代表指数函数衰减速度;  $\beta$  代表归一化常数。对  $Q_{(p_i)}$  内所有邻域像素点的灰度值进行加权平均:

$$\hat{p}_i = \frac{\sum_{p_j \in Q_{(p_i)}} w_{ij} \hat{p}_j}{N_{Q_{(p_i)}}} \quad (7)$$

式中,  $\hat{p}_i$  代表第  $i$  个像素点的灰度加权平均值;  $N_{Q_{(p_i)}}$  代表邻域相似像素点  $p_j$  的相似集合  $Q_{(p_i)}$  中相似像素点数量;  $\hat{p}_j$  代表邻域相似像素点  $p_j$  的灰度值。利用  $\hat{p}_i$  代替原始图像中像素点  $p_i$  的灰度值完成去噪。按照上述过程,遍历叶片图像中所有像素点,完成叶片图像去噪<sup>[15]</sup>。

## 2.3 图像照度均衡化

受到采集天气、采集时间以及光照强度等因素的影响,采集到叶片图像很容易出现照度不均衡化的问题,存在部分图像过暗或过亮情况。无论是过暗还是过亮,都会导致

图像中的内容信息辨识度较差<sup>[16]</sup>。为此,需要对图像非均匀光照图像进行亮度调节,提升图像信息辨识度。具体过程如下。

步骤 1: 将去噪后的单通道灰度叶片图像恢复到  $R$ 、 $G$ 、 $B$  三通道彩色图像。

步骤 2: 将 RGB 图像转换到 HSV 空间,其中  $V$  代表亮度部分。

步骤 3: 利用光照滤波器对  $V$  部分进行滤波,即:

$$\bar{V}_{(i, j)} = \hat{p}_i f(V_{(i, j)}) \quad (8)$$

式中,  $\bar{V}_{(i, j)}$  代表光照滤波器滤波结果;  $f(\cdot)$  代表光照滤波器。

步骤 4: 将  $\bar{V}_{(i, j)}$  作为照度分量,结合 Retinex 理论,得到反射分量  $R_{i, j}$ 。

步骤 5: 计算图像的平均光照值,记为  $\bar{V}_{(i, j)}$ 。

步骤 6: 以  $\bar{V}_{(i, j)}$  为阈值,构建暗区  $V_{(i, j)}^d$ 、亮区  $V_{(i, j)}^b$  图像。

步骤 7: 对暗区图像  $V_{(i, j)}^d$  进行光照补偿,即:

$$V_{(i, j)}^e = \left[ \left( \frac{U - \bar{V}_{(i, j)}}{U} + 1 \right) V_{(i, j)}^d + V_{(i, j)}^b \right] \bar{V}_{(i, j)} \quad (9)$$

式中,  $V_{(i, j)}^e$  代表光照补偿后的暗区图像像素。

步骤 8: 对亮区图像  $V_{(i, j)}^b$  进行光照抑制,即:

$$V_{(i, j)}^f = \left[ \left( \frac{U + \bar{V}_{(i, j)}}{U} + 1 \right) V_{(i, j)}^b - V_{(i, j)}^d \right] \bar{V}_{(i, j)} \quad (10)$$

式中,  $V_{(i, j)}^f$  代表光照抑制后的暗区图像像素。

步骤 9: 整体调整。现实中存在一幅图像完全是暗光照图像或者都是亮光照图像的情况,针对这种情况,可以按照下述公式进行整体调整。

$$\bar{V}_{(i, j)} = (L - 1) \left( \frac{V_{(i, j)}^e + V_{(i, j)}^f}{L - 1} \right)^{1/\delta(x)} \quad (11)$$

式中,  $\bar{V}_{(i, j)}$  代表整体调整后的图像照度分量;  $L$  代表图像灰度级;  $\chi$  代表取值  $[1, 2]$  范围内的常数;  $\delta(x)$  代表光照整体调整函数。随着  $\delta(x)$  下调,图像整体亮度值增加,  $\delta(x)$  上调,图像整体亮度值下降。

步骤 10: 结合 Retinex 理论,将调整后的照度分量  $\bar{V}_{(i, j)}$  或  $(V_{(i, j)}^e + V_{(i, j)}^f)$  与反射分量  $R_{i, j}$  结合,还原为图像亮度值,再由 HSV 空间转换回 RGB 空间,完成图像照度调节,使得过亮部分亮度降低,使得过暗部分亮度提高<sup>[17]</sup>。经过上述 3 个步骤的预处理工作,有效提高了图像质量,为图像特征的提取奠定了良好的基础。

## 3 叶片图像特征提取

无人机风机图像采集是获取原始图像数据的过程,而图像预处理是对采集到的图像进行灰度化、去噪、照度均衡化等操作以改善图像质量的过程。通过图像预处理,为图像特征提取提供了更好的输入条件,以便后续对风机图像进行分析,从而实现对风机叶片缺陷的检测。结合图像采集和图像预处理方法,共同为无人机风机图像分析提供了基础。

图像特征提取是整个识别中的关键步骤, 其提取到的特征向量是否准确和全面, 将直接关系到缺陷检测的准确性。为此, 本研究中基于第 2 小节预处理后的图像, 提取两类特征作为后期检测的基础, 分别为几何特征和 LBP 纹理特征。几何特征和纹理特征在图像分析中具有互补性, 它们共同提供了对图像的多方面描述, 可以获得较为全面和丰富的特征信息, 从而有效提高图像分析和缺陷检测的性能。下面进行具体分析。

### 3.1 几何特征提取

每一种缺陷类型所呈现出来的形态是不同的, 这就使得每一种缺陷都有一定的几何特征, 因此透过几何特征可以看出风机叶片上发生缺陷<sup>[18]</sup>。提取分为两个阶段工作, 前一阶段工作为分割缺陷区域。具体过程如下: 首先输入预处理好的风机叶片图像, 图像中每个像素点像素值记为  $\varphi(i, j)$ 。其次, 从风机叶片图像中寻找外轮廓起始点。寻找原则如下: 当风机叶片图像中第  $i$  行, 第  $j$  列的像素点像素值  $\varphi(i, j)$  等于 1, 且第  $i$  行, 第  $j-1$  列的像素点像素值  $\varphi(i, j-1)$  等于 0 时, 认为该像素点为外轮廓起始点, 否则就不是外轮廓起始点。将寻找到的外轮廓起始点记为  $J_1$ 。以寻找到的外轮廓起始点  $J_1$  为核心, 顺时针方向提取到邻域范围内非零像素点, 记为  $J_2, J_3, \dots, J_n$ , 直至回到外轮廓起始点为止。然后利用 findcontours 算子将这些非零像素点  $J_2, J_3, \dots, J_n$  连接起来, 形成一个闭环, 该闭环线就是缺陷的轮廓线, 闭环内的区域就是分割出来的缺陷区域。最后为方便查看缺陷区域, 将缺陷区域的轮廓嵌入叠加到原始风机叶片上, 完成缺陷区域分割。

在缺陷区域分割完成的基础上, 接下来提取缺陷的几何特征, 如表 1 所示。

表 1 几何特征表

| 特征  | 定义              | 符号    | 公式     |
|-----|-----------------|-------|--------|
| 周长  | 缺陷区域周长          | $Z_1$ | 公式(12) |
| 面积  | 缺陷区域面积          | $Z_2$ | 公式(13) |
| 矩形度 | 缺陷区域对其外接矩形的充满程度 | $Z_3$ | 公式(14) |
| 圆形度 | 缺陷区域对其外接圆形的充满程度 | $Z_4$ | 公式(15) |

$$Z_1 = \bar{V}_{(i,j)} \sum_{(i,j) \in \kappa} \{L(i, j) = 0\} \quad (12)$$

$$Z_2 = Z_1 \sum_{(i,j) \in u} \{L(i, j) = 0\} \quad (13)$$

$$Z_3 \begin{cases} Z_{31} = \frac{Z_2}{\min Z_2} \\ Z_{32} = \frac{y}{y} \end{cases} \quad (14)$$

$$Z_4 = \frac{4\pi Z_2}{Z_3} \quad (15)$$

式中,  $Z_{31}$ 、 $Z_{32}$  分别代表矩形拟合因子和宽长比, 二者统称矩形度  $Z_3$ ;  $L(i, j)$  代表叶片图像  $(i, j)$  处灰度值;  $\kappa$  代表叶片缺陷边缘上的像素点集合;  $u$  代表叶片缺陷边缘包含区域内的像素点集合;  $\min Z_2$  代表叶片缺陷区域最小外接矩形面

积;  $y$ 、 $\hat{y}$  代表叶片缺陷区域最小外接矩形面积、宽度、长度。

### 3.2 纹理特征提取

几何特征仅反映图像中叶片缺陷的形态, 这种特征对于识别一些大尺寸缺陷, 而一些尺寸较小的缺陷的几何特征差异表现不明显, 因此单纯依靠几何特征进行后期的缺陷类型识别很容易造成误识别的问题。面对这种情况, 本章节增加一个纹理特征, 以弥补单一几何特征的不足, 使得获取到的特征信息更为全面<sup>[19]</sup>。纹理特征的提取目前主要有两种方法, 一是通过 LBP 算子来提取, 二是通过灰度共生矩阵来提取。本研究中通过第二种方法, 该方法的定义是随机从风机叶片选取一个像素点, 像素点灰度级为  $\alpha$ , 该像素点离开某个固定位置另一个灰度级为  $\beta$  的像素点概率, 遍历图中所有像素点, 将这些像素的概率组成一个矩阵, 即灰度共生矩阵。基于灰度共生矩阵计算标量, 对纹理特征进行描述, 具体分析结果如表 2 所示。

表 2 纹理特征表

| 特征  | 定义                         | 符号    | 公式     |
|-----|----------------------------|-------|--------|
| 能量  | 描述了纹理粗细程度以及灰度在图像中的整体分布的均匀性 | $S_1$ | 公式(16) |
| 对比度 | 反映了纹理凹槽的深度                 | $S_2$ | 公式(17) |
| 熵   | 反映了纹理的复杂度                  | $S_3$ | 公式(18) |
| 均匀性 | 描述了纹理的局部灰度分布的平滑性           | $S_4$ | 公式(19) |

$$S_1 = Z_4 \sum_{\alpha=0}^{N-1} \sum_{\beta=0}^{N-1} p^2[\alpha(i, j), \beta(i, j)] \quad (16)$$

$$S_2 = \sum_{\alpha=0}^{N-1} \sum_{\beta=0}^{N-1} [\alpha(i, j) - \beta(i, j)]^2 \cdot p S_1 \quad (17)$$

$$S_3 = - \sum_{\alpha=0}^{N-1} \sum_{\beta=0}^{N-1} p[\alpha(i, j), \beta(i, j)] \cdot \lg p S_2 \quad (18)$$

$$S_4 = \sum_{\alpha=0}^{N-1} \sum_{\beta=0}^{N-1} \frac{1}{1 + [\alpha(i, j), \beta(i, j)]^2} p S_3 \quad (19)$$

式中,  $p[\alpha(i, j), \beta(i, j)]$  代表像素的频数;  $\alpha(i, j), \beta(i, j)$  表示像素点的灰度;  $N$  代表图像的灰度级;  $\alpha(i, j) - \beta(i, j)$  代表像素点之间的灰度差。

章节 3.1 和 3.2 提取到两类特征的量纲是不同的, 无法统一应用于后期识别模型当中, 因此需要统一量纲。以纹理特征中能量指标为例, 统一处理公式如下:

$$\hat{S}_1 = \frac{S_1 - \min S_1}{\max S_1 - \min S_1} \quad (20)$$

式中,  $\hat{S}_1$  代表统一量纲后的能量指标;  $\max S_1$ 、 $\min S_1$  代表能量值最大值和最小值。经过上述处理后, 最后得到的风机叶片图像特征集合为  $Q = \{Z_1, Z_2, Z_3, Z_4, \hat{S}_1, \hat{S}_2, \hat{S}_3, \hat{S}_4\}$ 。

## 4 叶片缺陷自动检测

图像特征提取是从叶片图像中获取与叶片缺陷相关的特定信息或属性的过程, 这些特征可以包括形状、颜色、纹理、边缘等。特征提取为叶片图像的缺陷自动检测提供

了关键的输入，通过提取与叶片缺陷相关的特征，可以更准确地描述和分析叶片图像中的异常之处，从而实现叶片的自动检测。

基于第 3 小节的几何特征提取和纹理特征提取结果，进入最后一个环节——叶片缺陷类型检测，确定是否发生缺陷问题以及发生了何种缺陷问题。在这里引入神经网络下的一个分支——概率神经网络，以此为核心，构建叶片缺陷类型检测模型，如图 1 所示。

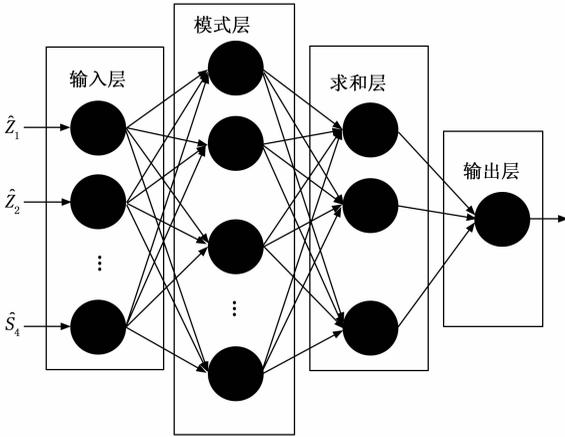


图 1 基于概率神经网络叶片缺陷类型检测模型

与传统神经网络一样，在使用之前，概率神经网络也同样需要进行训练，建立特征与缺陷类别之间的映射关系，使其模型具有较强的自学习和泛化能力<sup>[20]</sup>。训练过程如下。

1) 输入层：

输入层是训练样本的输入窗口，用于接收来自训练样本的值。本研究中，其输入的样本为  $Q = \{\hat{Z}_1, \hat{Z}_2, \hat{Z}_3, \hat{Z}_4, \hat{S}_1, \hat{S}_2, \hat{S}_3, \hat{S}_4\}^T$ 。

2) 模式层：

模式层的作用是计算训练样本属于各个叶片缺陷类型的概率，计算过程如下：首先需要计算样本  $Q$  与设置的权值之间的距离，输入特征提取结果，获取第  $i$  类样本的第  $j$  个神经元的权值向量  $\lambda_{ij}$ ，按照下述公式计算神经元的输出概率  $R_{ij}(Q)$ ，即：

$$R_{ij}(Q) = \frac{Q \exp\left(\frac{\lambda_{ij}}{2\epsilon^2}\right)}{(2\pi\epsilon^2)^{n/2}} \quad (21)$$

式中， $\epsilon$  代表平滑参数； $n$  代表样本维数，也就是一个样本的类别数量。

3) 求和层：

求和层，顾名思义，就是对计算出来的同类神经元概率进行累计求和再求平均值，计算公式：

$$\xi_\nu(Q) = \frac{\sum_{\nu=1}^N R_\nu(Q)}{N_\nu} \quad (22)$$

式中， $\xi_\nu(Q)$  代表第  $\nu$  类神经元输出概率的平均值； $N_\nu$  代表模式层第  $\nu$  类神经元数目。

4) 输出层：

输出层的作用是按照最大值响应原则输出训练样本对应的缺陷类别，也就是将概率数值最大的那个类别作为判定的缺陷类别。输出层表达式如下：

$$\xi(Q) = \arg \max_{1 \leq \nu \leq n} \xi_\nu(Q) \quad (23)$$

式中， $\xi(Q)$  代表样本  $Q$  的对应的缺陷类型。

最后判断是否满足训练结束条件。若满足，完成训练，否则迭代次数+1，重复上述过程，继续训练。

在上述过程中，平滑参数  $\epsilon$  若是设定为一个固定值，会降低检测的精度，因此为了能够实现自适应调节，利用差异演化算法改进概率神经网络平滑参数  $\epsilon$ ，构成自适应概率神经网络。具体过程如下。

1) 设置差异演化算法的初始参数。

2) 对风机叶片缺陷检测样本  $Q$  以及权值向量  $\lambda_{ij}$  进行归一化处理。

3) 基于平滑参数  $\epsilon$  的取值范围  $[0,1]$  之间随机生成初始种群  $X$ 。种群中每个个体都代表一种平滑参数  $\epsilon$  取值方案。

4) 计算种群中每个个体的目标函数  $\bar{w}(x)$ 。

5) 从个体的目标函数中选出最小值对应的个体，该个体为当前最优值。

6) 对当前最优个体进行变异、交叉、选择操作，生成新一代种群。

7) 判断是否进化次数是否达到最大？若是，输出目标函数值最小值对应的个体，该个体为平滑参数  $\epsilon$  取值最优解；否则进化次数+1并回到 4)，重复上述过程。

将求得的最优  $\hat{\epsilon}$  取代原始  $\epsilon$ ，实现概率神经网络优化。利用优化后的概率神经网络完成叶片缺陷类型检测。整体的检测流程图如图 2 所示。

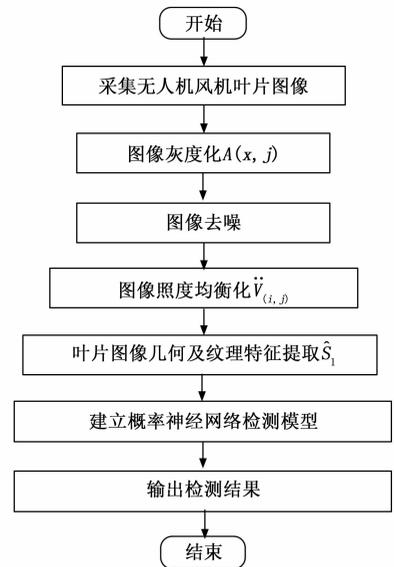


图 2 风机叶片表面缺陷检测流程图

由图 2 可知，本次研究通过无人机对风机叶片进行拍摄，获取全面、高分辨率的图像数据，对图像实施灰度化、

去噪和照度均衡化处理，减少图像中的干扰和噪声。根据预处理后的图像，提取叶片的几何特征和纹理特征，获取叶片缺陷的细节信息。将提取的特征作为输入数据，构建概率神经网络模型，并进行训练，提高检测效果。利用训练好的概率神经网络模型，对新的风机叶片图像进行缺陷类型检测，判断叶片是否存在缺陷，并确定缺陷的具体类型，以此实现基于无人机的风机叶片表面缺陷自动检测。

### 5 测试与分析

在完成检测技术的理论分析后，还需要进行应用测试，以验证该技术是否能够正常发挥检测作用。该研究以文献 [4-6] 中提到的检测技术作为对比，进一步验证技术的检测能力。

#### 5.1 无人机飞行环境

以某 100 km×100 km 的风力发电区域为例，该区域位于山区地带，如图 3 所示。



图 3 风力发电现场

该区域内不规则分布风电机组共计 26 个，风电机组坐标分布图如图 4 所示。

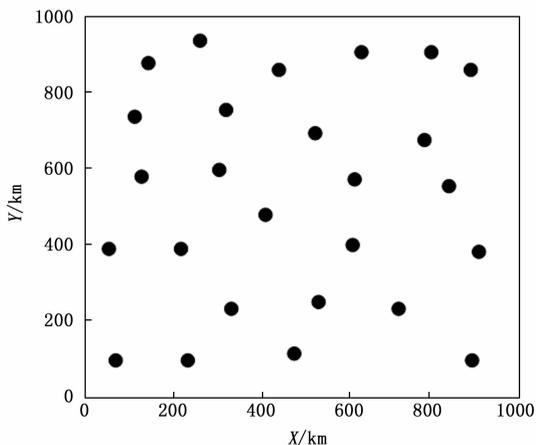


图 4 风电机组坐标分布图

如图 4 所示，各个风电机组坐标均为已知。

#### 5.2 无人机飞行路径规划与图像采集

基于章节 1 研究，利用粒子群算法求取满足航迹代价函数的最优解，求解结果如图 5 所示。

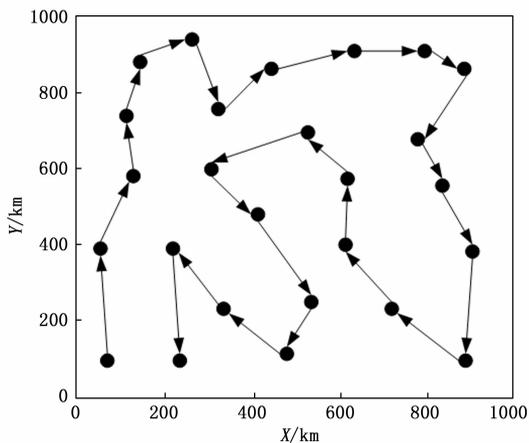


图 5 无人机最佳飞行路径规划方案

控制无人机按照图 5 规划的路径进行飞行，飞行现场如图 6 所示，飞行参数如表 3 所示。



图 6 无人机飞行现场

表 3 无人机参数

| 名称    | 参数                               |
|-------|----------------------------------|
| 无人机类型 | 四旋翼无人机                           |
| 飞行载重  | 2 700 g                          |
| 悬停精度  | 0.1~0.5 m                        |
| 俯仰轴   | 300°/s                           |
| 航向轴   | 100°/s                           |
| 升降速度  | 最大上升速度:S 模式:6 m/s,P 模式:5 m/s     |
|       | 最大下降速度(垂直):S 模式:5 m/s,P 模式:3 m/s |
| 飞行速度  | S 模式:23 m/s,P 模式:17 m/s          |
| 飞行高度  | 5 000 m(2 110 桨叶,起飞重量≤7 kg)      |
| 飞行时间  | 55 分钟                            |
| 抗风等级  | 7 级                              |

图 6 中的无人机每飞行到一个风电机组节点附近，无人机就会悬停在空中，然后启动携带的摄像机拍摄风机叶片图像，每个风机拍摄 18 张图像，共计 468 张图像，以此作为测试样本。样本示例如图 7 所示。

这 468 张图像中，实际划分为两大类，即存在缺陷的图像样本和不存在缺陷的图像样本。其中存在缺陷的图像样本中雷击损伤 12 张、表面开裂 36 张、局部脱落 40 张、

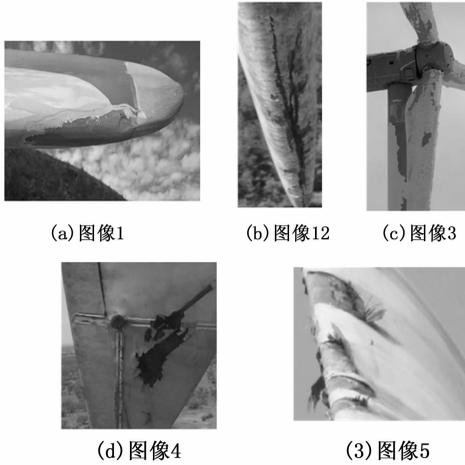


图 7 风机叶片图像样本示例

凹坑 8 张、覆冰 1 张、砂眼 17 张、腐蚀 20 张、脱胶 34 张，剩余图像均为无缺陷样本。

### 5.3 图像预处理结果

在检测识别前，需要对采集到的每一张图像进行预处理，具体参照章节 2 研究的 3 个步骤。以图 7 中 (a) 凹坑缺陷为例，预处理后叶片图像的示例如图 8 所示。

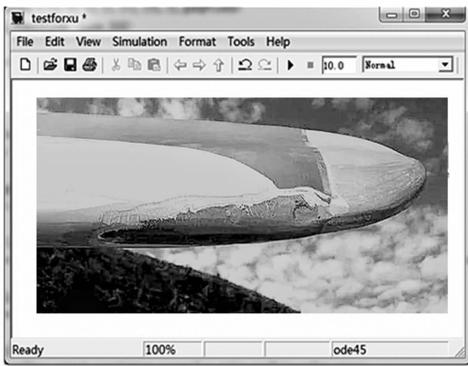


图 8 叶片图像预处理结果示例

### 5.4 图像特征提取结果

参照章节 3 研究，从采集并预处理好的叶片图像中提取两类特征，即几何特征和纹理特征，然后进行量纲统一处理。从测试样本中选取 5 个图像样本，提取到的两类特征示例如表 4 所示。

表 4 图像特征提取结果示例

| 类别   | 特征  | 样本示例    |         |         |         |         |
|------|-----|---------|---------|---------|---------|---------|
|      |     | 图像 1    | 图像 2    | 图像 3    | 图像 4    | 图像 5    |
| 几何特征 | 周长  | 0.125 6 | 0.326 2 | 0.864 5 | 0.048 5 | 0.278 4 |
|      | 面积  | 0.325 9 | 0.126 2 | 0.283 2 | 0.218 5 | 0.135 5 |
|      | 矩形度 | 0.463 3 | 0.243 6 | 0.029 5 | 0.356 2 | 0.485 1 |
|      | 圆形度 | 0.865 4 | 0.356 5 | 0.196 5 | 0.412 6 | 0.155 5 |
| 纹理特征 | 能量  | 0.621 1 | 0.198 7 | 0.625 8 | 0.202 0 | 0.284 8 |
|      | 对比度 | 0.784 2 | 0.874 5 | 0.478 1 | 0.174 8 | 0.184 8 |
|      | 熵   | 0.246 3 | 0.546 2 | 0.215 5 | 0.386 5 | 0.385 2 |
|      | 均匀性 | 0.452 5 | 0.185 7 | 0.784 8 | 0.187 4 | 0.424 5 |

### 5.5 缺陷类型检测结果

以提取到的特征为输入，利用章节 5 中研究的概率神经网络对同类神经元概率总和再求平均值，然后将概率数值最大的那个类别作为判定的缺陷类别，完成各个图像样本的缺陷类型检测，检测结果示例如表 5 所示。

表 5 风机叶片缺陷类型检测结果示例

| 类别   | 图像 1    | 图像 2    | 图像 3    | 图像 4    | 图像 5    |
|------|---------|---------|---------|---------|---------|
| 雷击损伤 | 0.548 2 | 0.242 5 | 0.631 2 | 0.632 2 | 0.547 2 |
| 表面开裂 | 0.627 4 | 0.124 5 | 0.354 4 | 0.275 9 | 0.911 4 |
| 局部脱落 | 0.428 6 | 0.096 2 | 0.244 5 | 0.962 2 | 0.357 4 |
| 凹坑   | 0.726 2 | 0.248 4 | 0.275 8 | 0.524 5 | 0.284 5 |
| 覆冰   | 0.294 6 | 0.321 0 | 0.421 8 | 0.024 2 | 0.128 5 |
| 砂眼   | 0.925 4 | 0.186 5 | 0.377 8 | 0.384 5 | 0.275 8 |
| 腐蚀   | 0.328 4 | 0.521 5 | 0.249 8 | 0.202 8 | 0.421 4 |
| 脱胶   | 0.425 8 | 0.348 4 | 0.425 5 | 0.274 1 | 0.525 2 |
| 无缺陷  | 0.525 2 | 0.922 7 | 0.951 4 | 0.274 4 | 0.262 1 |

按照最大值响应原则，从表 5 中可以看出，图像 1 存在砂眼缺陷；图像 2、图像 3 不存在缺陷；图像 4 存在局部脱落缺陷；图像 5 存在表面开裂缺陷。

### 5.6 对比分析

将文献 [4-6] 中提到的检测技术作为对比方法，以杰卡德系数以及所花费时间为评估指标。其中，杰卡德系数是一个用于比较两个样本集合相似度和多样性的统计量，该系数越高，说明检测算法识别出的缺陷区域与实际缺陷区域越接近，即检测结果的准确性越高；在风机叶片缺陷检测中，检测速度的快慢直接影响到整个检测过程的效率。因此，选择所花费时间作为评估指标之一，能够反映出检测算法的运行速度和效率。所花费时间越短，说明检测算法的运行速度越快，能够在更短的时间内完成检测任务，提高整个检测过程的效率。进一步验证所研究技术的检测能力，结果如表 6 所示。

表 6 对比结果表

| 技术    | 样本    | 杰卡德系数   | 时间/s  |
|-------|-------|---------|-------|
| 所研究技术 | 缺陷样本  | 0.941 2 | 15.69 |
|       | 无缺陷样本 | 0.982 3 | 8.62  |
| 文献[4] | 缺陷样本  | 0.856 2 | 24.62 |
|       | 无缺陷样本 | 0.902 3 | 14.78 |
| 文献[5] | 缺陷样本  | 0.755 2 | 22.32 |
|       | 无缺陷样本 | 0.856 6 | 12.63 |
| 文献[6] | 缺陷样本  | 0.862 1 | 26.85 |
|       | 无缺陷样本 | 0.821 5 | 20.48 |

从表 6 中可以看出，与文献 [4-6] 中提到的检测技术相比，所研究技术应用下，杰卡德系数最高达到 0.982 3，说明检测结果与实际结果更为接近，检测结果更为准确；所花费时间低于 15.69 s，由此说明检测效率更高，更快的完成检测任务，技术运行速度快。总而言之，所研究技术

的检测能力更强, 达到了研究目标。

以图 7 中的凹坑缺陷为检测对象, 进一步测试 3 种方法的自动检测效果, 结果如图 9 所示。

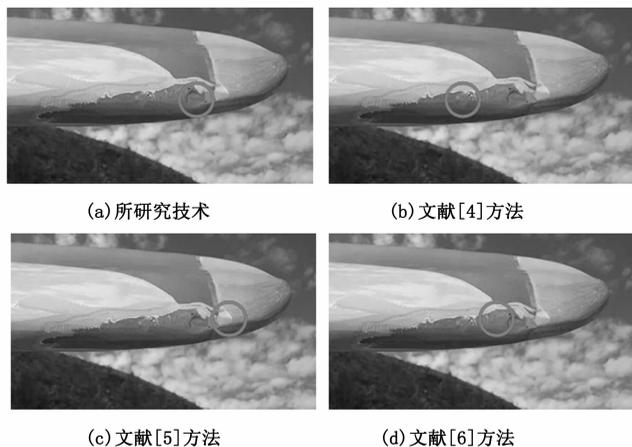


图 9 风机叶片表面缺陷检测结果

由图 9 可以看出, 所研究技术可以准确检测出风机叶片表面凹坑缺陷, 而文献 [4-6] 方法的检测均存在一定程度的偏差, 检测效果还需进一步的提升。

## 6 结束语

风力发电机是新能源的主要生产方式之一, 接入大电网后很大程度上缓解了供电压力。风力发电机是利用风带动叶片旋转从而产生电能的, 因此保证叶片能够正常运行是十分必要的。风机叶片都布设在野外空旷的地方或者海上, 长期很容易出现雷击损伤、表面开裂、局部脱落、凹坑、覆冰、砂眼、腐蚀、脱胶等缺陷。为此, 研究一种基于无人机的风机叶片表面缺陷自动检测方法。该方法主要取得了以下成就:

1) 提取了几何和纹理两类特征, 弥补了单一特征面对小尺寸缺陷信息量不足和不准确的问题, 为后期检测与识别提供了更为可靠的基础数据。

2) 差异演化算法改进概率神经网络平滑参数, 提升了概率神经网络的分类识别能力, 由此构建了更为有效的风机叶片缺陷自动检测模型。

最后对所研究技术进行了测试, 通过杰卡德系数以及所花费时间的对比, 证明该技术的检测能力更强。

### 参考文献:

[1] 刘毅, 储银贺, 李波. 基于持续热激励红外检测的风机叶片腐蚀检测 [J]. 激光与红外, 2023, 53 (5): 716-722.

[2] 朱新宇, 郭志平, 杨燕昭, 等. 双叶片直线翼垂直轴风力发电机流场特性分析 [J]. 计算机仿真, 2021, 38 (8): 108-112.

[3] 何赞泽, 李响, 王洪金, 等. 基于可见光和热成像的风机叶片全周期无损检测综述 [J]. 机械工程学报, 2023, 59 (6):

32-45.

[4] 冉浦东, 范磊, 张军, 等. 基于改进 Adaboost-SVM 的风机叶片覆冰检测 [J]. 计算机应用与软件, 2023, 40 (5): 110-114.

[5] 汤占军, 孙栋钦, 李英娜, 等. 改进 FA 优化 SVM 的风机叶片裂纹检测模型 [J]. 可再生能源, 2022, 40 (9): 1189-1194.

[6] 辛彦, 吴国新, 左云波. 基于 EfficientDet 的风机叶片缺陷检测方法 [J]. 电子测量技术, 2022, 45 (5): 124-131.

[7] 刘曦檬, 汤占军, 李英娜, 等. 基于时序卷积对抗域适应的风机叶片结冰诊断 [J]. 石河子大学学报 (自然科学版), 2022, 40 (5): 648-654.

[8] 张玉彦, 张永奇, 孙春亚, 等. 不平衡样本下基于生成式对抗网络的风机叶片开裂状态识别 [J]. 计算机集成制造系统, 2023, 29 (2): 532-543.

[9] 刘书山, 刘兰兰, 肖乔莎, 等. 无人机巡检 500 kV 典型铁塔的抗干扰路径规划 [J]. 无线电工程, 2023, 53 (5): 1171-1179.

[10] 单光瑞, 赵金, 徐婷, 等. 贝叶斯框架下基于灰狼优化策略的多无人机巡检航迹规划 [J]. 计算机应用与软件, 2023, 40 (2): 82-88.

[11] 陶新民, 郭文杰, 李向可, 等. 基于密度峰值的依维度重置多种群粒子群算法 [J]. 软件学报, 2023, 34 (4): 1850-1869.

[12] 徐其春, 郭晨晨, 刘志明, 等. 无人机线路自主巡检的动态轨迹规划方法 [J]. 电力系统及其自动化学报, 2022, 34 (10): 24-31.

[13] 沈学利, 杨莹, 秦鑫宇, 等. 基于残差神经网络的风机叶片结冰故障诊断 [J]. 噪声与振动控制, 2022, 42 (1): 79-87.

[14] 汤占军, 孙栋钦, 李英娜, 等. 基于特征融合的风机叶片表面缺陷检测模型 [J]. 电子测量技术, 2022, 45 (11): 161-166.

[15] 黄子恒, 许钊源, 伍剑波, 等. 基于优化模态分解和 Xgblr 的风机叶片故障诊断方法 [J]. 机械设计, 2022, 39 (7): 56-62.

[16] 韩涛, 姚维. 基于 K 近邻与支持向量机协同训练的风机叶片结冰早期检测 [J]. 实验室研究与探索, 2021, 40 (9): 52-56.

[17] 张雁忠, 吴寒, 董超, 等. 风机叶片引下线断裂故障检测与定位方法 [J]. 科学技术与工程, 2021, 21 (18): 7564-7569.

[18] 张则荣, 韩桐桐, 李影. 基于应变模态的风机叶片损伤诊断研究 [J]. 可再生能源, 2021, 39 (3): 359-364.

[19] 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.

[20] 解明辉, 孙亚剑, 汤思杰, 等. 基于群体优化一概率神经网络的配电网设备状态研判模型 [J]. 电工电能新技术, 2023, 42 (6): 79-87.