

大型海上风电机组叶片故障图像识别方法

张森¹, 杨苹¹, 刘泽健², 李文胜³, 吴昊³

(1.华南理工大学 电力学院 广东省绿色能源技术重点实验室, 广东 广州 510641; 2.深圳华工能源技术有限公司, 广东 深圳 518129; 3.南方电网电力科技股份有限公司, 广东 广州 510180)

摘要: 针对海上风电机组叶片故障诊断建模时缺乏大量实际故障图像训练样本的问题, 文章提出了一种基于小数据集的海上风电机组叶片故障图像识别方法。该方法针对风机叶片图像的叶片及其故障的颜色与形状特征, 改进 K 均值聚类算法以实现叶片分割, 设计自适应算法调整 Canny 算子参数以实现叶片表面早期故障区域的分割, 使用 K 均值聚类算法提取故障的颜色和形状特征并设计相应的分类器以实现故障分类。仿真算例表明, 该方法对于叶片表面早期故障的识别是有效的, 可以在少量故障样本的基础上为海上风电机组叶片故障识别提供准确的诊断模型, 提高了海上风电场的运维效率。

关键词: 海上风电机组; 叶片故障; 图像识别; 小数据集

中图分类号: TK81 **文献标志码:** A **文章编号:** 1671-5292(2024)06-0767-07

0 引言

海上风电机组叶片故障频发, 直接影响风电机组的正常运行。海上风电机组叶片的传统人工巡检工作量大、效率低且成本高, 亟需智能化的巡检手段提高效率, 确保风电场的可靠运行。而海上风电机组叶片表面早期故障的智能化巡检, 高度依赖叶片故障的图像识别精度^[1-5]。

国内外对叶片故障的图像识别研究取得了较多成果, 文献[6]针对深度学习训练时间过长的问題, 基于迁移学习方法设计了基于反向传播神经网络和超限学习机的全连接层, 实现了叶片状态的分类和叶片裂缝的识别, 相较于反向传播神经网络, 训练速度可提高上千倍且准确率性能指标相似。文献[7]通过叶片振动信号采集与分析进行叶片裂纹损伤的在线监测, 将叶片振动信号、模态参数和机组运行数据融合为多源数据集, 结合 LightGBM 算法进行了叶片裂纹损伤故障诊断。文献[8]针对风电机组叶片的裂纹检测, 使用扩展后的 Haar-like 特征提取算法提取叶片裂纹特征, 并使用 LogitBoost、决策树和 SVM 分类器构造级联分类器进行分类, 检测一张图像仅需 0.09 s。文献[9]对叶片图像进行灰度变换、空间滤波和图像增强等操作后, 使用 Robert 算子将叶片图像分割出来, 通过设计分类器识别斑点、砂眼、擦痕、裂纹等

4类故障。文献[10]提出了限制对比度自适应直方图均衡化算法增强图像, 通过阈值分割先后将叶片和故障分割出来, 最后设计分类器识别砂眼、划痕等故障, 准确率达到 90%以上。

现有的叶片故障图像识别模型, 大多需要利用大量叶片故障图像样本进行训练, 而叶片故障图像样本的收集与积累十分困难。因此, 本文提出了一种基于小数据集的海上风电机组叶片故障图像识别方法, 期望能够在少量故障样本的基础上为海上风电机组的叶片故障识别提供准确的诊断模型。

1 大型海上风电机组叶片故障图像分割

为实现基于小数据集的海上风电机组叶片故障图像识别, 需要有效的海上风电机组叶片故障图像特征提取方法。因此, 在图像识别前分割叶片和故障区域, 可以有效地消除背景对识别结果的影响, 保障识别结果的准确率。

1.1 基于 K 均值聚类算法的叶片分割

海上风机图像的背景比较简单且叶片的颜色通常只有一种, 因此, 海上风机叶片分割可以归类为颜色分类问题, 处理这类问题的有效方法有 K-means 聚类、模糊 C 均值聚类和基于密度的聚类算法等, 其中 K-means 聚类算法的运行速度最快。

收稿日期: 2023-02-20。

基金项目: 广东省自然资源厅 2022 年省级促进经济高质量发展(海洋经济发展)海洋六大产业专项(GDNRC[2022]26)。

通信作者: 杨苹(1967-), 女, 博士, 教授, 博士生导师, 研究方向为电力市场、大规模风电并网控制与运维、微能源网优化调度运行。

E-mail: eppyang@scut.edu.cn

但 K-means 聚类算法存在需要指定聚类个数且较难处理图像阴影的问题, 而利用叶片的颜色和形状特征处理上述问题, 能够更精准地分割叶片, 改进后的算法步骤如图 1 所示。

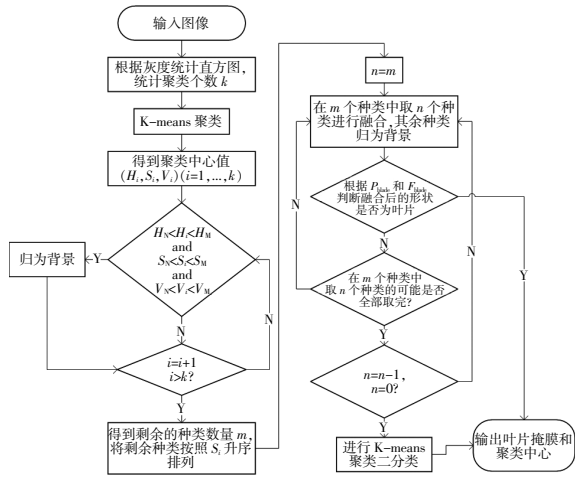


图 1 改进 K-means 聚类算法流程

Fig.1 Flow chart of improved K-means clustering algorithm

首先, 统计聚类个数 k : 将图像转换为灰度图, 并统计图像的 16 柱灰度直方图; 令 $a=0.08$, 统计灰度值大于 a 的值的个数 k ; 若 $k \leq 9$, 令 $a=a-0.01$, 继续统计大于 a 的值的个数 k , 直至 $k > 9$ 或 $a=0.03$ 时, 输出上一次统计的 k 值。

其次, 根据颜色进行 K-means 聚类, 得到 k 个聚类中心的 HSV 颜色 $(H_i, S_i, V_i) (i=1, \dots, k)$ (H 为色度, S 为对比度, V 为亮度), 将 $H_N < H_i < H_M$, $S_N < S_i < S_M$ 和 $V_N < V_i < V_M$ 的颜色认为是属于背景的

颜色, 并归类为背景。

然后, 根据形状判断融合部分是否为叶片: 将剩余的 m 个种类按照对比度 S_i 的大小从小到大排序, 并从中依次取出 n 个种类进行融合, 其余部分认为是图像的背景, 计算融合部分中面积最大部分的形状因子 P_{blade} 和其周长与最小外接矩形周长之比 F_{blade} , 若 $P_{blade} < P_{blade} < P_{blade} & F_{blade} < F_{blade} < F_{blade}$, 则认为该部分是叶片, 否则继续取其它种类进行融合和判断。

$$P_{blade} = \frac{C_{blade}^2}{4\pi S_{blade}} \quad (1)$$

式中: C_{blade} 为叶片的周长; S_{blade} 为叶片的面积, 单位为像素点。

最后, 若仍未寻找到符合的分割结果, 则输出 K-means 二分类的结果和聚类中心; 若寻找到符合的区域, 则直接输出叶片掩膜和聚类中心。

1.2 基于 Canny 算子的故障区域分割

故障区域分割首先要定位故障所在区域, 而故障与其周围的区域存在明显的色差, 边缘检测算法能够检测出这些色差并识别为边缘, 边缘所在区域即为故障所在区域。

Canny 算子是目前理论上相对完善的边缘检测算法, Canny 算子须要设置低阈值 L_{Canny} 和高阈值 T_{Canny} 两个参数, 本文令 $T_{Canny} = 2L_{Canny}$, 减少所需调节的参数。

图 2 为不同阈值时叶片区域内的边缘检测结果。

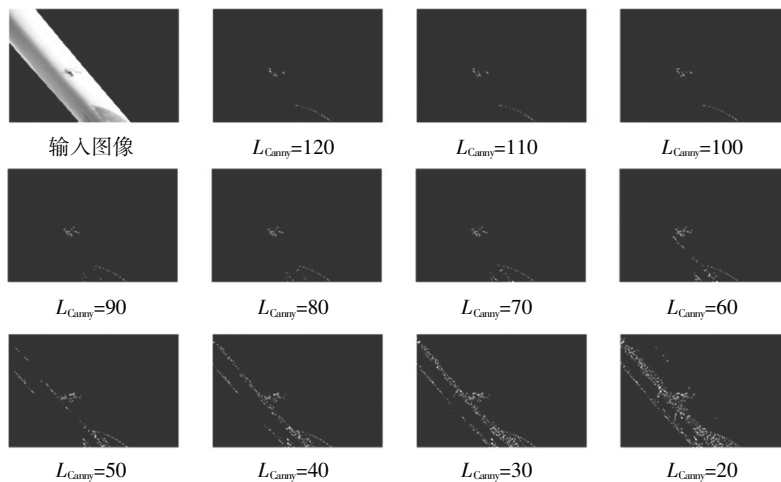


图 2 不同阈值的 Canny 算子边缘检测结果

Fig.2 Canny operator edge detection results with different thresholds

由图 2 可知, L_{Canny} 越小, 检测到的边缘越多, 但同时噪声也越多, 而 $L_{Canny}=60$ 是噪声增多的临

界点。

因此,针对 Canny 算子须要预先设定参数的问题,以边缘外轮廓的数量变化量 num_{con} 和边缘像素的数量变化量 num_p 为判断依据,设计自适应算法改进 Canny 算子,使其能够找到合适的 L_{Canny} 。自适应 Canny 算子步骤如图 3 所示。

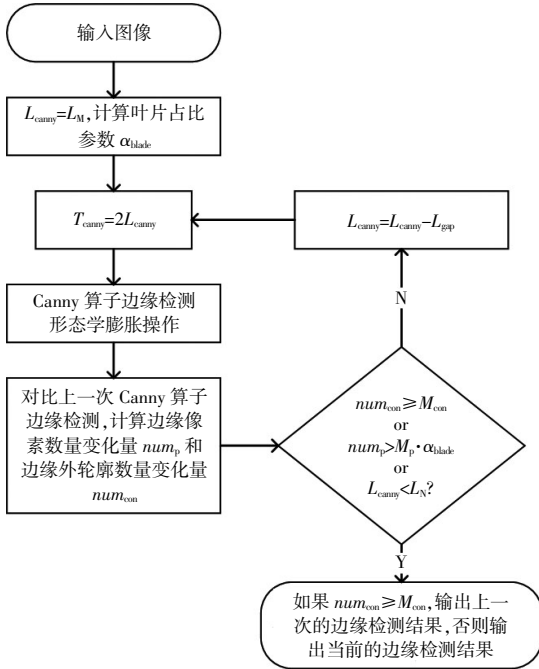


图 3 自适应 Canny 算子流程

Fig.3 Flow chart of adaptive Canny operator

图中: L_M 为 L_{Canny} 的起始值; L_{gap} 为步进值; L_N 为终止值; M_p 为 num_p 的阈值; M_{con} 为 num_{con} 的阈值。叶片的占比参数 α_{blade} 与叶片占整张图像面积的大小成正相关。

$$\alpha_{blade} = e^{S_{blade}/S_{picture}} \quad (2)$$

式中: $S_{picture}$ 为图片的面积,单位为像素点。

最后,得到边缘检测结果后,通过形态学膨胀和轮廓检测及填充操作,生成每个故障的掩膜。

1.3 故障特征提取

故障区域图像中通常只存在故障及其背景,即叶片两种类别,使用 K-means 聚类算法进行二分类可以很好地把这两种类别区分开来,从而提取故障的颜色和形状特征(图 4)。

图 4(c)中:0 代表故障的 HSV 颜色;1 代表背景的 HSV 颜色; S_{max} 为背景的对比值; V_{max} 为叶片的亮度。

2 大型海上风电机组叶片故障分类

为了提高分类结果的准确率,针对故障的颜




图 4 故障特征提取

Fig.4 Fault feature extraction

色和形状特征,分别设计颜色和形状特征分类器对故障进行分类,从而实现故障识别。

2.1 颜色特征分类器

海上风机叶片故障颜色大多较深,且越严重的故障颜色会越深,因此,可以将颜色相对鲜艳明亮的故障归类为非故障,并根据颜色的亮度判断故障的受损程度。根据上述特点设计的颜色特征分类器工作流程如图 5 所示。

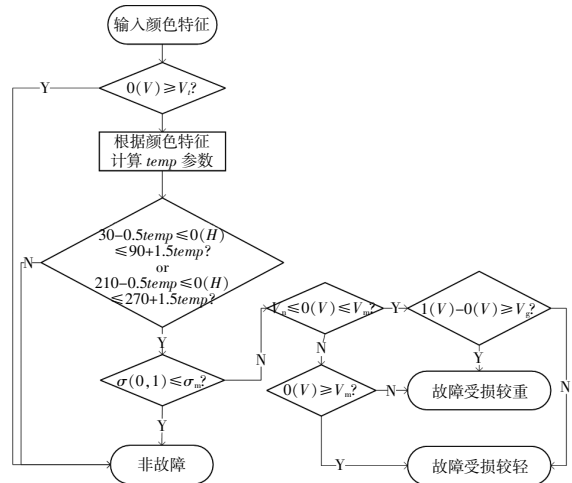


图 5 颜色分类器工作流程

Fig.5 Color sorter workflow

图 5 中: $0(H), 0(S), 0(V)$ 为故障颜色的 HSV 三分量; $1(H), 1(S), 1(V)$ 为背景颜色的 HSV 三分量; $\sigma(0,1)$ 为故障与背景的颜色方差。

$$\sigma(0,1) = [0(H)-1(H)]^2 + [0(S)-1(S)]^2 + [0(V)-1(V)]^2 \quad (3)$$

参数 $temp$ 的计算式为

$$temp = \sqrt{\frac{V_{max}-0(V)+10}{V_{max}} \cdot \frac{S_{max}-0(V)+10}{S_{max}}} \cdot 60 \quad (4)$$

颜色特征分类器的工作原理如下:

首先,判断故障的亮度 $0(V)$ 是否过高,亮度过高的属于非故障;

其次,根据故障的色度 $0(H)$ 进行判断,对于人眼的感受而言,蓝色区域颜色较深,黄色区域较

符合海上风机被腐蚀时的颜色,因此,以这两个区域为中心设计判断公式: $30-0.5temp \leq 0(H) \leq 90+1.5temp$ 或 $210-0.5temp \leq 0(H) \leq 270+1.5temp$ 。其中 $temp$ 与 S_{max} 和 V_{max} 相关,可以动态调整判断公式,降低拍摄时的光照影响;

再次,计算故障与背景的颜色方差 $\sigma(0,1)$,若 $\sigma(0,1) < \sigma_m$,则该故障属于非故障;

最后,根据 $0(V)$ 对故障进行分类,若 $0(V) < V_n$,代表亮度低,故障受损较重;若 $0(V) > V_m$,代表亮度高,故障受损较轻;若 $V_n \leq 0(V) \leq V_m$,则进一步判断故障与背景的亮度差。

2.2 形状特征分类器

叶片故障主要有类圆型和长条型两种形状,通过故障形状特征的形状因子 P_{fault} 和最小外接矩形的长短边之比 R_{fault} 能够有效地区分二者^[1]。因此,设计形状特征分类器的工作步骤:选择形状特征中周长最大的部分用于分类;若 $P_{fault} < N_{fault}$,则属于类圆型故障,若 $P_{fault} > M_{fault}$,则属于长条型故障,若 $N_{fault} < P_{fault} < M_{fault}$,则进一步计算 R_{fault} ;若 $R_{fault} > T_{fault}$,则属于长条型故障,否则属于类圆型故障^[9];最后结合颜色分类器的结果实现故障分类。

若为长条型故障,还需进一步判断故障是否为阴影。由于故障区域分割是在边缘两侧均匀地分割,若为阴影,阴影应仅存在边缘的一侧,另一侧为背景,且二者的面积大小近似相等。因此,判

断方式如下:首先使用故障掩膜减去故障形状得到故障轮廓图;然后判断故障轮廓图中的轮廓个数是否为 1,若为 1,则计算故障形状面积和故障掩膜面积之比 Q_{area} ,若 $Q_{area} \approx 0.5$,则该故障属于阴影。

3 算例分析

为了验证所提方法的有效性,对图像识别的全过程进行算例分析,并使用增广的数据集验证算法的适应性。

3.1 叶片分割结果分析

海上风机的背景通常为简单的天空和海水。叶片的颜色为灰白色,叶片上的标记为红色,海水和天空的颜色为蓝白色, H, S, V 的取值如表 1 所示。

表 1 HSV 颜色取值范围

Table 1 HSV color range

HSV 颜色	叶片	叶片标记	海水和天空
H	[0, 360]	[0, 30]U[330, 360]	[180, 270]
S	[0, 30]	[10, 100]	[10, 100]
V	[0, 100]	[10, 100]	[10, 100]

根据表 1,将 $30 < H < 330, S > 30, V > 10$ 的颜色认为是不属于叶片的颜色,并归类为背景。根据叶片的形状结合多次实验,将叶片分割时 P_{blade} 和 F_{blade} 的取值设定为 $1 \leq P_{blade} \leq 4$ 和 $0.8 \leq F_{blade} \leq 1.2$,若图像最长边的像素大于 640,则把图像最长边等比例地缩放至 640,叶片分割的掩膜见图 6。




图 6 改进前后的 K-means 聚类算法对比

Fig.6 Comparison of K-means clustering algorithm before and after improvement

由图 6 可知,K-means 聚类算法对图 6(c)这类叶片中存在阴影的图像的分割结果较差,而改进后的 K-means 聚类算法能够准确地分割出所有图像中的叶片,且细节处理得更好,验证了该算法的有效性。

3.2 故障区域分割结果分析

根据 Canny 算子原理,将自适应 Canny 算子相关的参数设定为 $L_M=120, L_N=20, L_{gap}=10$,使其能够遍历所有边缘检测的结果。根据仿真经验,设定 $M_p=200, M_{con}=5$ 。

以图 6(c)为例,故障区域分割的结果如图 7 所示。




图 7 故障区域分割结果

Fig.7 Fault area segmentation results

在图 7 中,根据自适应 Canny 算子得到 $L_{Canny}=60$,并分割出 6 个故障区域。其中,mask0,mask3 和 mask4 是叶片背光侧交接处的阴影,mask2 是叶片上红色标记的边缘,mask1 是叶片标记掉色形成的划痕,mask5 是真实的故障区域。结果表明,自适应 Canny 算子能够检测到许多细节,在将其识别为故障区域的同时能够避免被过多的噪声影响。

3.3 故障分类结果分析

砂眼、划痕、斑点和裂纹均属于风电机组叶片表面的早期故障,这些故障如果没有及时发现和处理,最终会演变成较为严重的故障,从而影响风机运行。本文主要识别砂眼、划痕、斑点、裂纹这 4 类叶片表面早期故障。根据分类器的设计原理,相关参数设定如下:根据人眼识别故障的经验,令 $V_r=80$,即认为亮度高于 80 的区域不存在故障;令 $\sigma_m=40$,即认为颜色方差 $\sigma(0,1) \leq 40$ 的区域不存在故障;令 $V_n=10, V_g=30, V_m=50$,即认为亮度小于 10 或亮度差大于 30 的故障受损较重,亮度大于 50 或亮度差小于 30 的故障受损较轻。根据文献

[11]中关于形状分类的参数,令 $M_{fault}=2.5, N_{fault}=1.5, T_{fault}=2$ 。故障的特征如表 2 所示。

表 2 故障特征

Table 2 Fault characteristics

受损程度	类圆型	长条型
较轻	砂眼	划痕
较重	斑点	裂纹

以图 7 的故障区域分割结果为例,对 6 个故障区域中的故障进行分类,最终只剩下 2 个故障,分类结果如表 3 所示。

表 3 故障分类结果

Table 3 Fault classification results

故障区域编号	颜色分类器结果	形状分类器结果	分类结果
mask0	非故障		非故障
mask1	受损较轻	长条型	划痕
mask2	非故障		非故障
mask3	受损较轻	阴影	非故障
mask4	受损较轻	阴影	非故障
mask5	受损较轻	长条型	划痕

3.4 故障识别结果分析

故障识别结果如图 8 所示。




图 8 图像识别结果

Fig.8 Results of image recognition

由图 8 可知,叶片表面的早期故障基本均被识别到了,验证了所提方法的有效性。其中:图 8 (c)误识别了一个叶片标记掉色形成的划痕,这类的误识别在实际运行中可以适当存在;由于裂纹和划痕定义过于相近,图 8(d)将裂纹误分类成划痕。

最后,通过旋转翻转和改变光照等数据增广方式得到近百张图像进行验证,使用漏识率 p_l 、误识率 p_f 、准确率 p_r 3 个指标评价识别结果。

$$p_l = 1 - p_f - p_r \quad (5)$$

$$p_f = \frac{\text{错误识别的故障数量}}{\text{故障总数}} \quad (6)$$

$$p_r = \frac{\text{正确识别的故障数量}}{\text{故障总数}} \quad (7)$$

故障识别结果如表 4 所示。

表 4 故障识别结果
Table 4 Results of fault identification

故障类型	故障总数	$p_l/\%$	$p_f/\%$	$p_r/\%$
砂眼	24	0	0	100
斑点	28	0	0	100
划痕	74	-13.5	32.4	81.1
裂纹	68	0	20.6	79.4

由表 4 可知:故障的漏识率均不大于 0,表明所提方法能够检测到叶片表面的所有故障,验证了所提方法的有效性;所提方法对类圆型的故障识别准确率高,对长条型的故障识别准确率略低,但也达到了 80%左右,能够满足一定的工程实际应用需求。由于验证图像来源过于分散,导致各个步骤的参数设置的范围较广,在实际应用中仅针对同一类型的风机时,可以通过调整参数的范围降低误识率,并进一步定义裂纹和划痕之间的区别,提高准确率。

4 结论

本文针对海上风机叶片故障数据集稀少的问题,提出了一种大型海上风电机组叶片故障的图像识别方法,能够基于小数据集实现海上风电机组叶片图像故障识别。

①对比不同分割算法对两张图片的分割结果,改进的 K-means 聚类算法在针对海上风机叶片这种简单背景的图像时可以完整地将叶片分割出来。对比不同参数的 Canny 算子边缘检测结果,自适应 Canny 算子能够减少噪声的影响并将故障

区域分割出来。

②基于图像处理方法设计的分类器中,颜色特征分类器能够判断颜色的深浅并筛选出不属于故障的颜色,形状特征分类器能够判断故障的形状并筛选出阴影。通过算例分析可以看出,所提方法能够准确地找到叶片表面的所有早期故障并完成分类,准确率较高。

③本文所提方法适用于多种类型的图像和叶片,若只针对特定类型的图像和叶片进行参数调整,准确率可以进一步提高。

参考文献:

- [1] 王道累,肖佳威,刘易腾,等.风电机组叶片损伤检测技术研究进展[J].中国电机工程学报,2023,43(12):4614-4630.
- [2] 王冰佳,韩毅,童博,等.海上风力机叶片状态监测技术应用现状与展望[J].船舶工程,2022,44(S1):1-5.
- [3] 葛畅,阎洁,刘永前,等.海上风电场运行控制维护关键技术综述[J].中国电机工程学报,2022,42(12):4278-4292.
- [4] 贾辉,张磊安,王景华,等.基于声发射技术的风电叶片复合材料损伤模式识别[J].可再生能源,2022,40(1):67-72.
- [5] Awadallah M, El-Sinawi A. Effect and detection of cracks on small wind turbine blade vibration using special Kriging analysis of spectral shifts [J]. Measurement, 2020, 151: 107076.
- [6] 刘艳霞,丁小燕,方建军.基于迁移学习的风力发电机叶片裂缝识别[J].传感器与微系统,2019,38(8):107-110.
- [7] 吴宇辉,张扬帆,高峰,等.基于工作模态分析的风电机组叶片裂纹损伤在线监测研究[J].中国电力,2023,56(10):106-114.
- [8] L Wang, Z Zhang. Automatic detection of wind turbine blade surface cracks based on UAV-Taken images [J]. IEEE Transactions on Industrial Electronics, 2017, 64(9): 7293-7303.
- [9] 徐灵鑫.风力发电机叶片表面缺陷检测的研究[D].杭州:中国计量学院,2015.
- [10] 谭兴国,张高明,张飞翔,等.基于无人机图像的风机叶片表面缺陷检测方法及其系统 [P]. 中国专利:CN202211185960.0, 2022-09-27.
- [11] 云赛.基于图像处理的风力发电机叶片表面缺陷检测技术研究[D].天津:天津理工大学,2019.

Image recognition method for blade fault of large offshore wind turbine

Zhang Miao¹, Yang Ping¹, Liu Zejian², Li Wensheng³, Wu Hao³

(1.Guangdong Key Laboratory of Clean Energy Technology, School of Electric Power, South China University of Technology, Guangzhou 510641, China; 2.Shenzhen Huagong Energy Technology Co.,Ltd., Shenzhen 518129, China; 3.China Southern Power Grid Technology Co.,Ltd., Guangzhou 510180, China)

Abstract: Aiming at the problem of lack of a large number of actual fault image training samples during the fault diagnosis and modeling of offshore wind turbine blades, an image recognition method for offshore wind turbine blade faults based on small data sets is proposed. In this method, the K-means clustering algorithm is improved to identify blade segmentation according to the color and shape characteristics of blades and their faults in wind turbine blade images, an adaptive algorithm is designed to adjust the Canny operator parameters to identify the segmentation of early fault areas on the blade surface, and the K-means clustering algorithm is used to extract the color and shape features of faults and design corresponding classifiers to achieve fault classification. Simulation examples show that this method is effective for the identification of early faults on the blade surface, and can provide an accurate diagnostic model for the blade fault identification of offshore wind turbines on the basis of a small number of fault samples, which can improve the operation and maintenance efficiency of offshore wind farms.

Keywords: offshore wind turbine; blade fault; image recognition; small data set