

基于红外图像边缘检测算法的 风电机组叶片裂纹视觉检测技术

杨德海[†]

(水发能源集团有限公司, 山东 济南 250100)

摘 要:风电机组叶片损伤无损检测过程容易受到外界环境干扰, 细节处理效果较差, F1 值较低。因此, 提出了基于红外图像边缘检测算法的风电机组叶片裂纹视觉检测技术。将实时采集的风电机组叶片红外图像变换为灰度图像, 再利用引导滤波器进行线性移变滤波, 得到边缘细节增强的图像。应用最大类间方差法选取最优图像分割阈值, 从原始图像中分割出待检测的叶片目标。引入熵分块算法和最优阈值选取算法, 设计改进基于改进 Canny 算法的边缘检测算法, 通过图像自动分块、子图像高低阈值计算等操作, 获取红外图像边缘信息, 基于此提取叶片裂纹图像的周长、长轴、短轴等特征。运用改进萤火虫算法优化后的支持向量机模型, 对特征向量进一步分析, 得出叶片裂纹视觉检测结果。实验结果表明: 新研究技术应用后得出的裂纹检测结果 F1 值超过了 0.9, 满足了风电机组巡检要求。

关键词:红外图像; 风电机组; 叶片; 边缘检测; 裂纹检测; 支持向量机

中图分类号: TM315

文献标识码: A

Visual Detection Technology for Wind Turbine Blade Cracks Based on Infrared Image Edge Detection Algorithm

YANG Dehai[†]

(Shuifa Energy Group Co., Ltd., Jinan, Shandong 250100, China)

Abstract: The non-destructive testing process of wind turbine blade damage is prone to external environmental interference, with poor detail processing effect and low F1 value. Therefore, a visual detection technology for wind turbine blade cracks based on infrared image edge detection algorithm is proposed. Transform the real-time collected infrared images of wind turbine blades into grayscale images, and then use a guided filter for linear shift filtering to obtain images with enhanced edge details. Apply the maximum inter class variance method to select the optimal image segmentation threshold and segment the leaf target to be detected from the original image. Introducing the entropy partitioning algorithm and the optimal threshold selection algorithm, designing and improving an edge detection algorithm based on the improved Canny algorithm. Through automatic image segmentation, sub image high and low threshold calculation, and other operations, infrared image edge information is obtained. Based on this, features such as perimeter, major axis, and short axis of the blade crack image are extracted. Using the optimized support vector machine model using the improved firefly algorithm, further analyze the feature vectors and obtain the visual detection results of blade cracks. The experimental results show that the F1 value of the crack detection result obtained after the application of the new research technology exceeds 0.9, meeting the inspection requirements of wind turbines.

Key words: infrared image; wind turbines; blades; edge detection; crack detection; support vector machine

收稿日期: 2023-11-28

基金项目: 山东省工业和信息化厅技术创新项目(202350100992)

作者简介: 杨德海(1970—), 男, 山东成武人, 硕士, 高级工程师, 研究方向: 机械设计和制造, 数控设备研发, 智能系统设计等。

[†] 通信联系人, E-mail: jiupingshi2rx@163.com

由于风电机组长期暴露在自然环境中,受到风、雨、雪等自然气候的影响^[1],以及机组运行中的振动、摩擦等因素的作用,叶片可能会出现裂纹。这些裂纹不仅会影响叶片的强度和刚度,还会降低风电机组的性能和稳定性,严重时甚至可能导致机组停机或故障^[2]。因此,对风电机组叶片进行定期的检测和维修是保障风电机组正常运行的重要措施。近年来,随着人工智能技术的快速发展,基于图像处理和深度学习的裂纹检测方法逐渐成为研究热点。

文献[3]以传统的 YOLO-v3 算法为基础,结合包含注意力机制的挤压与激励网络,构建叶片表面检测识别模型。将现场采集图像输入模型中后,自动进行特征提取、特征融合和损伤检测,并通过自适应尺度的锚框标注出检测结果。通过测试可知,该方法检测时间较长。文献[4]依靠无人机拍摄大量叶片图像,针对其进行去噪和增强处理后,提取出图片包含的纹理和色彩特征。依托于支持向量机算法设计裂纹检测模型,并通过改进萤火虫算法优化模型参数,将特征向量输入优化后的模型,即可得出叶片裂纹视觉检测结果。但是,该方法稳定性较差。文献[5]提出在实验室内针对叶片进行测试,观察其不同工况下的振动信号,利用小波包-奇异值分解算法处理振动信号,获取裂纹叶片振动信号的时频特征,再将其输入基于核极限学习机的裂纹检测模型中,通过自动学习识别出叶片裂纹情况。但是,该方法检测结果存在较大误差。

为了辅助风电机组叶片巡检工作,提出了一种基于红外图像边缘检测算法的风电机组叶片裂纹视觉检测技术。该技术利用红外热像仪获取风电机组叶片的红外图像,然后通过基于图像边缘检测算法对图像进行处理,实现叶片裂纹的自动检测。

1 风电机组叶片裂纹视觉检测技术

1.1 风电机组叶片红外图像线性变换

考虑到风电机组叶片工作环境较为复杂,现场采集叶片红外图像中边缘细节信息比较模糊,会干扰最终裂纹检测结果。因此,在图像预处理阶段需要实现叶片红外图像增强,先将红外图像转换为灰度化图像^[6],将确定每个像素点的灰度值。再应用引导滤波器,定义线性移变滤波模式,对输入的红外图像进行线性变换,剔除噪声像素点后,即可得到滤波输出结果。

$$b_k = \sum_{j=1}^J w_{kj}(\alpha) a_j \quad (1)$$

式中, a 表示输入的风电机组叶片红外图像, J 表示红外图像中包含的像素点数量, k, j 表示像素索引, α 表示引导图像, w 表示滤波器内核参数, b 表示滤波后输出红外图像。

引导滤波器处理风电机组叶片红外图像时,主要是以一个像素点为中心,通过固定半径的方形窗设置一个处理区域,在该区域内进行局部线性滤波运算^[7],直到遍历所有像素点后,即可得到最终红外滤波图像。对于任意一个方形框来说,其线性运算时引导图像和输出图像之间的关系可以表示为公式(2)。

$$b_k = \bar{c}_k \alpha_k + \bar{d}_k \quad (2)$$

其中:

$$\begin{cases} \bar{c}_k = \frac{1}{n} \sum_{i=1}^n c_i \\ \bar{d}_k = \frac{1}{n} \sum_{i=1}^n d_i \end{cases} \quad (3)$$

式中, $\bar{c}, \bar{d}$ 均表示方形窗中像素平均值, n 表示方形窗内像素点数量, c, d 表示窗口内选定像素点的像素值。

通过引导滤波器完成叶片红外图像去噪处理后,将图像中的纹理细节信息凸显出来,可以更好地辅助叶片裂纹视觉检测。

1.2 叶片红外图像分割

在叶片裂纹检测之前,需要对预处理后的红外图像进行分割,获取图像中的风电机组叶片目标,再针对该目标继续检测分析。图像分割过程中,选用最大类间方差法确定最优分割阈值^[8],实际操作步骤如下所示:

针对叶片红外图像,计算所有像素的分布概率:

$$P_o = \frac{m_o}{J} \quad (4)$$

式中, o 表示灰度值, P_o 表示灰度值 o 的分布概率, m_o 表示灰度值为 o 的像素数量。

在红外图像分割过程中,定义一个初始阈值,基于此将图像中的所有像素点划分为两类,并针对两类像素点集合分别计算像素值方差和灰度均值^[9]。以第一类像素点为例,其方差和灰度均值计算结果为:

$$\sigma_1 = \sum_{g=1}^{\epsilon_1} [f_g(x, y) - \eta_1]^2 \quad (5)$$

$$\eta_1 = \frac{1}{\epsilon_1} \sum_{g=1}^{\epsilon_1} f_g(x, y) \quad (6)$$

式中, σ_1 表示类方差, ϵ_1 表示第一个像素类别中包含的像素点数量, g 表示像素点编号, (x, y) 表示像素点坐标, f 表示样本均数差别的显著性检验函数, η_1 表示第一个像素类别的灰度均值。

按照同样的方法进行计算,可以得到第二个像素类别中像素的方差和灰度均值。结合两类问题发生概率,得出类间方差计算结果。

$$\varphi^2 = P_1 (\eta_1 - \bar{\eta})^2 + P_2 (\eta_2 - \bar{\eta})^2 \quad (7)$$

式中, φ^2 表示类间方差, P_1 、 P_2 表示两类问题发生概率, η_2 表示第二个像素类别的灰度均值, $\bar{\eta}$ 表示红外图像的总灰度均值。

以最大类间方差为目标,设置式(8)所示的条件,选取最优图像分割阈值。

$$\varphi^2 | T = \max(\varphi^2) \quad (8)$$

式中, T 表示最佳图像分割阈值。

依托于最优分割阈值选取结果,完成风电机组叶片红外图像的分割处理,读取不同类别的像素灰度值,使得二者类间方差达到最大,从包含背景信息的红外图像中,完整分割出叶片目标。

1.3 基于边缘检测算法的裂纹特征提取

结合熵图像自动分块算法和改进最优阈值选取算法,设计一种基于改进 Canny 的自适应边缘检测算法,基于此实现图像裂纹边缘信息提取,并提取出周长、长轴、短轴等纹理特征^[10]。

从图像灰度值入手,通过式(9)推算出叶片红外分割图像的熵,再按照图 1 所示的模式将熵值较大的图像划分为多个熵值较小的红外子图像。

$$H = - \sum_{o=1}^{255} \lambda_o \ln \lambda_o \quad (9)$$

式中, H 表示分割后红外图像的熵值, λ 表示目标灰度值像素点占比。




图 1 图像分块示意图

将分割后的图像按照图 1 所示的划分模式平均分为 4 个子区块,再判断划分后图像子区块的平均熵值与原始图像熵值的和是否大于 0,若计算结果大于 0 代表当前图像块混乱程度较小,可以针对每个子区块继续划分。重复上述操作,直到满足式(10),即可停止图像分块处理。

$$\left| - \frac{(H_1 + H_2 + H_3 + H_4)}{4} + H \right| \leq \epsilon \quad (10)$$

式中, H_1 、 H_2 、 H_3 、 H_4 表示四个子区块图像的熵, ϵ 表示熵增阈值。

风电机组叶片红外图像分块结束后,针对每一块图像分别进行阈值分割,即可检测出图像子块包含的边缘信息。通过迭代式最优阈值选择法,确定一个高阈值和一个低阈值,前者负责分割真实边缘和非真实边缘,后者则是主要针对非真实边缘部分,将其分为伪边缘和非边缘两类。上述处理结束后,将划分后的图像块恢复到最初状态,并将每个子图像块的边缘提取结果连接起来,得到整体红外图像边缘检测结果。

从风电机组叶片红外图像的边缘轮廓入手,提取叶片裂纹图像包含的周长、长轴、短轴等纹理特征信息。其中,周长可以直接获取,长短轴特征的计算较为复杂,需要先确定某一轮廓在 x 轴和 y 轴方向的值,并计算出两个方向的最大距离值,根据最大距离值即可确定长轴计算结果和裂纹走向。再根据裂纹走向随机选定多个横向裂纹采样点,计算同一纵坐标上两个采样点之间的横坐标距离,即可完成短轴长度计算。通过一系列运算,得到风电机组叶片裂纹红外图像的特征向量,作为后续视觉检测的依据。

1.4 风机叶片裂纹视觉检测

在机器学习领域,选择可以自动进行分类和回归分析的支持向量机算法,设置一个超平面后,考虑当前叶片裂纹红外图像的特征信息,将当前叶片图像样本划分到对应的类别中,输出裂纹视觉检测结果。其中,SVM 分类过程如图 2 所示。

按照图 2 所示的 SVM 分类算法进行风电机组叶片裂纹视觉检测时,最终检测结果会受到惩罚因子和核函数两个参数的影响。为了得到最优裂纹视觉检测结果,本研究应用改进萤火虫算法优化 SVM 参数,求出最优惩罚因子和核函数参数。实际操作过程中,引入基于映射的 logistic 映射策略,生成初始萤火虫种群。

$$U_{\omega+1} = \vartheta(1 - U_{\omega})U_{\omega} \tag{11}$$

式中， ω 表示种群内个体数量， U 表示种群， ϑ 表示混沌系数。




图 2 SVM 分类效果图

按照图 3 所示的 logistic 映射原理生成新的初始种群后,通过式(12)一式(14),获取萤火虫个体初始位置和迭代更新位置。

$$\rho_{z\zeta}(0) = \frac{\rho_{z\zeta} - \Phi}{u - \Phi} \tag{12}$$

$$\rho_{z\zeta}(\tau + 1) = \vartheta \rho_{z\zeta}(\tau) [1 - \rho_{z\zeta}(\tau)] \tag{13}$$

$$\rho_{z\zeta} = \Phi + \rho_{z\zeta}(\tau + 1)(u - \Phi) \tag{14}$$

式中， ρ 表示萤火虫个体位置， z 表示个体编号， ζ 表示维度， τ 表示迭代次数， u 表示个体位置上限， Φ 表示个体位置下限。




图 3 logistic 映射示意图

考虑到萤火虫算法寻优过程中,迭代步长的选择是一个关键环节。对此,提出基于荧光因子的自适应步长概念。

$$Q_z = \frac{\|\rho_z - \rho'\|}{D} \tag{15}$$

式中， Q 表示荧光因子， ρ' 表示萤火虫最优位置， D 表示最优位置的萤火虫个体与其他萤火虫之间的最远距离。

依托于荧光因子设定合理的萤火虫更新步长：

$$\psi_z = \psi_{\min} + (\psi_{\max} - \psi_{\min}) \tag{16}$$

式中， ψ 表示更新步长， $\psi_{\max}$ 、 $\psi_{\min}$ 表示最大和最小步长设定值。

设定移动步长后,应用萤火虫寻优算法进行迭代计算,得出惩罚因子和核函数参数最优解,将其代入 SVM 检测模型中。再利用优化调整后的检测模型分析预先提取的特征向量,即可自动生成叶片裂纹视觉检测结果。

2 实验分析

2.1 数据集

基于红外图像边缘检测算法的风电机组叶片裂纹视觉检测技术设计完成后,为了检验其实际应用效果,以云南某风电场为实验对象,通过红外设备采集风电机组叶片样本图像 500 张,尺寸为 200×200 像素,生成叶片裂纹视觉检测所需的实验数据集。所使用的实验平台是处理器频率为 2.92 GHz 的个人计算机,内存为 50 GB。由 MATLAB R2020b 编程训练算法,并使用 MATLAB 配套图形化工具 SIMULINK 进行算法实现。

为了解决样本分布不均匀问题,对原始图像进行扩充处理,得到图 4 所示的扩充结果。




图 4 红外图像扩充示意图

扩充处理后,得到包含 800 张叶片红外图像的数据集。通过裁剪的方式,将所有红外图像的大小统一为 300×300 像素。选取其中 200 张红外图像作为测试集,其余图像则是应用在基于支持向量机

的裂纹视觉检测模型训练过程中。

2.2 参数设置

在风电机组叶片裂纹视觉检测处理之前,需要优化支持向量机参数,该阶段设置改进萤火虫算法参数如表 1 所示。

表 1 改进萤火虫算法参数

项目	参数值
种群规模	50
最大迭代次数	100
荧光素挥发速率	0.5
初始荧光素	5
更新速率	0.6
初始感知半径	10
初始步长	0.25
最小步长	0.001
最大步长	1
调整个体感知范围	0.08

利用上述算法进行迭代寻优,可以得出图 5 所示的适应度变化曲线。




图 5 适应度变化曲线

根据图 5 可知,当进化代数达到 10,适应度到达稳定状态,证明该算法可以更快地搜索到最优参数,代入支持向量机检测模型,将其调整到最优状态。

2.3 叶片裂纹视觉检测结果

叶片裂纹视觉检测过程中,先对红外图像进行增强处理和边缘信息检测,得到图 6 所示的处理结果。

根据边缘检测结果提取裂纹特征后,利用优化后支持向量机模型进行裂纹检测,最终得到图 6 所示的检测结果。

从图 7 可以看出,新研究检测方法应用后,无论裂纹 1 和裂纹 2 这两种裂纹较大区域,还是裂纹

3 和裂纹 4 这两种裂纹较小区域,皆可以准确和完整标记全部叶片裂纹区域,证明了新设计检测技术具有较好的应用效果。




图 6 叶片图像增强和边缘检测结果




图 7 风电机组叶片裂纹视觉检测结果

2.4 检测性能对比

选取文献[3]和文献[4]给出的检测方法,基于与本文方法相同的数据集,同步进行叶片裂纹视觉检测,统计三种方法检测结果,并计算出检测结果精确率和召回率的加权调和平均值(F1),以此来检验每种方法应用性能。

$$F1 = \frac{1}{\beta^2 \times p \times r} \tag{17}$$

式中,F1 表示加权调和平均值, β 表示非负权重值, p 表示裂纹视觉检测结果的精确率, r 表示检测结果的召回率。

根据图 8 所示的对比结果可知,新研究技术的检测结果 F1 值达到了 0.9 以上,而其他两种方法作为对比的检测方法的 F1 值在 0.6—0.8 之间,充分证明了基于红外图像边缘检测算法的新技术具有更加优越的叶片裂纹检测性能。




图 8 不同方法裂纹检测结果 F1 值对比

3 结 论

在风电机组叶片裂纹视觉检测技术的研究中，红外图像边缘检测算法为我们提供了强有力的工具。通过此技术，能够更加准确、有效地检测出叶片表面的微小裂纹，为风电机的维护和检修提供及时、准确的依据。虽然该技术在实验中取得了较好的成果，但仍需要在实际应用中进一步的验证和完善。

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—4631.

[2] 李响,刘书海,肖华平,等. 风电叶片检测机器人设计与运动仿真研究[J]. 现代制造工程, 2023(4): 51—58.

[3] 蒋兴群,刘波,宋力,等. 基于改进 YOLO-v3 的风力机叶片表面损伤检测识别[J]. 太阳能学报, 2023, 44(3): 212—217.

[4] 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.

[5] 刘钦东,罗勇水,张军华,等. 基于 WPT-SVD-KELM 的大型风力机叶片表面裂纹识别方法研究[J]. 太阳能学报, 2023, 44(3): 155—161.

[6] 基于模型参数辨识的航空发动机风扇叶片裂纹故障诊断[J]. 航空发动机, 2023, 49(1): 115—121.

[7] 陈雪莲,曾劲,马辉. 基于固定界面法的旋转裂纹叶片动力学特性分析[J]. 航空发动机, 2022, 48(6): 105—109.

[8] 刘启栋. 基于卷积神经网络的风机叶片损伤检测[J]. 热力发电, 2023, 52(3): 88—93.

[9] 黄鑫,张小栋,张英杰,等. 基于改进 DBNs 的三维叶尖间隙叶片裂纹诊断方法[J]. 振动. 测试与诊断, 2022, 42(2): 213—219+402.

[10] 李永乐,骆贵兵,杨辉. 静叶可调轴流式引风机叶片断裂原因分析及对策[J]. 热力发电, 2021, 50(4): 114—119.

(上接第 99 页)

参考文献

[1] 彭荣超. 晶圆检测设备产业的现状、挑战与发展趋势研究[J]. 中国设备工程, 2023(7): 174—176.

[2] 郭民,王蕊. AOI 技术在 PCB 缺陷检测中的设计与实现[J]. 测控技术, 2016, 35(12): 127—130.

[3] 程锦锋,方贵盛,高惠芳. 表面缺陷检测的机器视觉技术研究进展[J]. 计算机应用研究, 2023, 40(4): 967—977.

[4] 方亮泰,董子靖,朱文博,等. 织物表面缺陷检测的研究进展[J]. 毛纺科技, 2023, 51(4): 94—101.

[5] MA J, ZHANG T, YANG C, et al. Review of wafer surface defect detection methods[J]. Electronics, 2023, 12(8): 1787.

[6] 何睿清,周鑫宇,张慧,等. 基于离焦图像的晶圆表面缺陷检

测[J]. 组合机床与自动化加工技术, 2023(7): 110—113, 118.

[7] LI W C, TSAI D M. Wavelet-based defect detection in solar wafer images with inhomogeneous texture[J]. Pattern Recognition, 2012, 45(2): 742—756.

[8] TSAI D M, LUO J Y. Mean shift-based defect detection in multicrystalline solar wafer surfaces[J]. IEEE Transactions on Industrial Informatics, 2010, 7(1): 125—135.

[9] KO J S, RHEEM J Y. Defect detection of polycrystalline solar wafers using local binary mean[J]. The International Journal of Advanced Manufacturing Technology, 2016, 82: 1753—1764.

[10] CHEN X, CHEN J, HAN X, et al. A light-weighted CNN model for wafer structural defect detection[J]. IEEE Access, 2020, 8: 24006—24018.