

DOI: 10.13382/j.jemi.B2407463

基于声纹特征融合的风机叶片异常识别方法^{*}

余洪伍¹ 汤占军¹ 马锦雄²

(1. 昆明理工大学信息工程与自动化学院 昆明 650000; 2. 云南龙源新能源有限公司 昆明 650000)

摘要:为实现风机叶片异常时的准确监测,提出一种将互补集合经验模态分解与风机叶片声纹特征进行结合的方法。首先,采集到4种异常工作状态以及正常运行状态下的风机叶片的声纹数据,对其进行降噪、分帧和加窗操作的预处理,通过实验比对,选择互补集合经验模态分解算法进行声纹数据的二次降噪,其次,对二次降噪后的帧信号进行模态分解提取模态分量,通过计算模态分量的皮尔逊相关系数筛选有效的模态分量,并对每层的模态分量提取梅尔频率倒谱系数、线性预测倒谱系数、gammatone倒谱系数、短时能量、以及短时平均过零率特征。最后,基于这些特征组合,采用支持向量机、朴素贝叶斯以及神经网络作为故障分类模型对声纹数据进行识别。研究表明,基于上述5种声纹特征组合在参数寻优后的神经网络模型下可以实现叶片异常的准确识别,识别准确率达到97.5%,该模型对早期异常的风机叶片识别效果较好,具有较好的泛化性能。

关键词: 梅尔频率倒谱系数; 特征融合; 互补集合经验模态分解; 故障诊断; 神经网络

中图分类号: TM315; TH17; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Wind turbine blade anomaly recognition method based on sound feature fusion

Yu Hongwu¹ Tang Zhanjun¹ Ma Jinxiong²

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650000, China;
2. Yunnan Longyuan New Energy Co., Ltd., Kunming 650000, China)

Abstract: In order to achieve accurate monitoring of abnormal wind turbine blades, a method combining complementary ensemble empirical mode decomposition with the sound features of wind turbine blades was proposed. Firstly, the voiceprint data of four kinds of fan blades under abnormal working conditions and normal operating conditions are collected and pre-processed for noise reduction, frame division and window addition. Through experimental comparison, the complementary ensemble empirical mode decomposition algorithm is selected for secondary noise reduction of voiceprint data. Secondly, the modal decomposition of frame signals after secondary noise reduction is carried out to extract modal components. The effective modal components were selected by calculating the Pearson correlation coefficient of the modal components, and the characteristics of mel frequency cepstrum coefficient, linear prediction cepstrum coefficient, gammatone cepstrum coefficient, short-time energy and short-time mean zero crossing rate were extracted for each layer of modal components. Finally, based on these feature combinations, support vector machine, naive Bayes and neural network are used as fault classification models to identify voicing data. The research results show that the neural network model based on the combination of the above five vowels features and the parameter optimization can achieve the accurate recognition of blade anomalies, with the recognition accuracy of 97.5%. The model has a good recognition effect on early abnormal fan blades, and has good generalization performance.

Keywords: mel frequency cepstrum coefficients; feature fusion; complementary ensemble empirical mode decomposition; fault identification; neural networks

0 引言

目前风力发电已成为我国发电产业的重要组成部分,根据国家能源局发布的数据,截止到 2023 年 11 月底,我国风电装机总量达 4.1 亿千瓦,同比增长 17.6%,占全国发电装机的 14.39%,随着电源结构加快向多元化绿色化转变,风力发电在经济高质量发展中发挥着越来越重要的作用。作为风电机组的关键部位,风机叶片造价约占总机 20% 左右,由于叶片长期受到紫外线、风沙、雷电等外部环境的影响,以及扫风过程中风况施加的交替应力的因素,在长时间的运行下容易出现裂缝、破损乃至断裂等问题,因此,及时的对风机叶片进行异常检测非常重要,有效的异常检测能够减少运维成本,提高生产效率,保证作业安全。

在风机叶片异常检测领域,目前已有光纤光栅^[1]、振动分析^[2-3]、声发射^[4]、红外热成像^[5]、SCADA 数据监测^[6]等技术,以上检测技术虽能取得良好的实验效果,但还存在一些局限性,光纤光栅、振动分析及声发射检测技术需提前在叶片表面或内部安装传感器,可能损坏叶片原有结构,红外热成像检测技术则需要持续热激励加热风机叶片,并需要专业设备及操作人员,成本较高,SCADA 数据监测虽成本较低,但其数据维度过高,采样频率较低,相关属性分析模糊,工况对数据影响大,分类模型准确度有局限性。除以上技术外,机器视觉检测也是风机叶片检测领域的一种重要技术手段,孙栋钦等^[7]通过对无人机拍摄的图像进行处理,并改进 ISOA-KELM 模型,实现了对叶片表面腐蚀速率的准确预测,Diazp 等^[8]通过级联掩膜 R-CNN 的检测模型,结合图像增强技术,实现了叶片缺陷的准确分类。但视觉检测技术受环境天气因素影响较大,机组运行状态下不易获得含有效状态信息的高清图像,且对早期异常的叶片识别率较低。

由于异常状态下的叶片质量和刚度分布不均匀,叶片气动性能受到影响,会产生非线性效应、动态失稳以及喇叭效应^[9],因此可通过提取反应叶片状态的声音信息,实现叶片健康状态的监测。邹宜金等^[10]利用风机叶片扫风具有周期性的特点,将风机叶片的声纹信息转化成频谱图并进行切割,采用叶片之间的稳态差异法对异常进行检测,取得较高的异常识别率,但此方法无法识别出风机叶片组出现同样故障的情况,且没有对故障类型进行分类识别。

针对上述问题,提出一种将互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)与风机叶片声纹特征进行结合的方法。对预处理后的声纹信号进行模态分解提取模态分量,根据相关

系数筛选出有效的模态分量,对每层模态分量提取梅尔频率倒谱系数(mel frequency cepstrum coefficients, MFCC)、线性预测倒谱系数(linear prediction cepstral coefficients, LPCC)、gammatone 倒谱系数(gammatone cepstral coefficients, GTCC)、短时能量、以及短时平均过零率特征。基于这些特征组合,采用支持向量机(support vector machine, SVM)、朴素贝叶斯和神经网络作为故障分类模型,并将模型应用到西南某风电场,实验证明,以上特征组合在参数寻优后的神经网络模型下有着较高的故障识别率。

1 故障识别算法描述

1.1 声音信号处理

风机叶片在野外运行过程中,不仅遭受雨雪、风沙、狂风等恶劣环境的影响,同时受到风电机组复杂的输入力的影响,导致采集到的风机叶片声纹信号中含有复杂的背景噪声^[11],因此需要对采集的声纹信号进行相应的预处理。

声纹信号的预处理包括降噪、分帧、加窗等操作,采集到声纹信号后,首先进行降噪处理,其目的是滤除背景噪声中最主要的风噪。为了让通带内频率保持最大的平坦性,选用巴特沃斯带通滤波器进行滤波,其平方幅频响应公式为:

$$H^2(p) = \frac{1}{1 + (p/j\omega_c)^{2N}} \quad (1)$$

$$p = \frac{s^2 + \omega_u \omega_l}{s(\omega_u - \omega_l)} \quad (2)$$

式中: ω_c 为截止频率, ω_u 为上限截止频率, ω_l 为下限截止频率, N 为滤波器的阶数。综合对比数据处理的效果,滤波器的阶数选择为 6~12,下限截止频率为 50~100 Hz,上限截止频率为 4~6 kHz。

随后,将去噪后的声纹信号划分为若干个小片段,称为分帧。为保证相邻的两帧信号平稳过渡,避免信号丢失,两帧之间需要有重叠,可表示为:

$$M = N - \frac{LW}{L(1-W)} \quad (3)$$

式中: M 为帧数; N 为信号长度; L 为帧长; W 为重叠率。

声纹识别中一般选 20~30 ms 为一帧,与语音信号相比,风机叶片声纹信号更加平稳,可适当增加帧长以提升识别精度,根据文献[12]在变压器中的分帧方法,取帧长为 500 ms,重叠率为 40%。

预处理后的声纹信号在进行特征提取时需进行离散傅里叶变换,为避免变换过程中的信号失真,对分帧后的信号施加汉明窗(hamming),汉明窗公式为:

$$W(n) = \begin{cases} 0.54 - 0.46\cos(\frac{2\pi n}{A-1}), & 0 \leq n \leq A-1 \\ 0, & \text{其他} \end{cases} \quad (4)$$

式中: A 为汉明窗长度。

1.2 互补集合经验模态分解 (CEEMD)

EMD (empirical mode decomposition, EMD), 是一种非线性信号的处理算法, 通过将信号分解为一系列不同模态的模态分量 (intrinsic mode functions, IMF), 并通过去除前几个含有高频噪声的 IMF 以达到去噪效果^[13-14]。传统的经验模态分解目前虽然广泛应用于信号处理领域, 但 EMD 存在严重的模态混叠现象, 导致 IMF 失真, 影响信号的特征提取效果。在 EMD 的基础上提出的集合经验模态分解 (ensemble empirical mode decomposition, EEMD) 方法, 虽解决了 EMD 算法模态混叠的问题, 但仍存在模式耦合以及噪声抑制较弱的缺陷^[15]。互补集合经验模态分解方法是在 EEMD 的基础上由 Yeh 等提出, 通过向信号添加正负白噪声的互补处理方法, 来消除重构信号中的残余辅助噪声, 进一步提高了计算效率和信号重构精度。风机叶片声纹除最主要的风噪之外, 还存在少量变桨噪声、环境噪声以及机械运行噪声, 频率范围比较广泛, 通过 CEEMD 模态分解方法, 可以达到二次降噪的作用^[16]。

CEEMD 分解步骤如下:

步骤 1) 在原始信号 $O(t)$ 上添加 M 组正负成对形式的白噪声信号 $N(t)$, 得到 $2M$ 个新的信号

$$\begin{bmatrix} Y_1(t) \\ Y_2(t) \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} O(t) \\ N(t) \end{bmatrix} \quad (5)$$

式中: $Y_1(t)$ 、 $Y_2(t)$ 分别为加入正、负白噪声后的信号。

步骤 2) 对步骤 1) 中得到的 $2M$ 个信号分别进行经验模态分解, 每个信号分解为一系列模态分量, 记第 i 个

$$H_m(k) = \begin{cases} 0, & k < f(m-1); \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))}, & f(m-1) \leq k \leq f(m); \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m+1)-f(m))}, & f(m) < k \leq f(m+1); \\ 0, & k > f(m+1); \end{cases} \quad (8)$$

式中: $f(m)$ 为滤波器的中心频率。

2) 线性预测倒谱系数 (LPCC)

线性预测倒谱系数是线性预测系数 (linear prediction coefficients, LPC) 在倒谱域的表示方式, 可以用来反映声信号的包络信息。它可以用较少的参数有效正确的反映声纹的时频特性。并能有效地抑制高频噪声和低频噪声, 具有很好的鲁棒性。LPCC 与 MFCC 相比, 在抗噪能力和特征表达能力方面具有一定优势, 在不同工作状态下风机叶片的声纹数据分析中, 不同的缺陷会导致声音的包络特性发生变化, LPCC 可以捕捉这些变

信号的第 j 个模态分量为 $S_{i,j}$ 。

步骤 3) 对步骤 2) 中算得的 $2M$ 组对应模态分量进行求和取平均运算, 得到信号 $O(t)$ 经过互补集合经验模态分解后的各阶模态分量, 其中第 j 个模态分量为:

$$S_j = \frac{1}{2M} \sum_{i=1}^{2M} S_{i,j} \quad (6)$$

1.3 相关系数计算

声纹信号经过模态分解后, 得到若干 IMF 分量。每个分量包含不同的特征信息, 通过相关系数指标分析各 IMF 分量与原始信号的相关程度, 并对 IMF 分量进行筛选, 相关系数计算公式为:

$$\rho = \frac{\sum_{k=1}^n IMF_i(k) S_i(k)}{\sqrt{\sum_{k=1}^n (IMF_i(k))^2 \sum_{k=1}^n S_i^2(k)}} \quad (7)$$

式中: $IMF_i(k)$ 为第 i 个 IMF 分量, $S_i(k)$ 为 $IMF_i(k)$ 与原始信号的差值。

1.4 声纹特征选择

1) 梅尔倒谱系数 (MFCC)

在声信号识别技术中, 梅尔倒谱系数 (MFCC) 是目前最常见的声音特征^[17], 它将标准的频率进行对数变换, 并映射到 mel 频域, MFCC 模拟了人耳对声音频率的感知方式, 能够更好地捕捉声音的频谱特性。对于风力发电机叶片声音, MFCC 可以有效地提取声音的频谱信息, 从而用于分析不同频率下的声音特征, 以区分不同类型的异常声音和正常运行声音。求取 MFCC 特征的步骤包括: 对信号在 mel 频域傅里叶变换、通过 mel 滤波器组获取信号能量、通过逆变换 (离散余弦变换) 去除耦合。滤波器组的传递函数为:

化, 从而区分不同的缺陷类型。

3) gammatone 倒谱系数 (GTCC)

gammatone 倒谱系数特征提取方法是一种重要的听觉感知特征提取方法, 目前在人类声音辨识与目标定位等领域得到普遍运用, gammatone 倒谱系数通过使用一组 gammatone 滤波器, 这些滤波器在频率上呈对数均匀分布并相互交叠, 实现了类似于人耳的频率选择特性。滤波后的信号经过倒谱变换, 得到了反映声音特征的 gammatone 倒谱系数^[18-19], 具有很好的抗噪声干扰能力。通过提取 gammatone 倒谱系数, 可以捕捉叶片声音信号

的频率和幅度特征,并将其转化为可供分析和比较的数值特征,这些特征能够反映叶片不同损伤模式所导致的声音变化,例如裂纹、磨损、皮层脱落以及松动等。

4) 短时能量以及短时平均过零率

短时能量是指声纹信号在一帧时间里的能量幅值,在声信号中,声音强度与信号的能量有密切关系,通过计算信号在不同帧内的能量大小,可以提取声音的强度特征。短时过零率指信号在一帧内符号改变的次数,相较于低频信号,高频信号的振动周期较短,振动方向的变化频率更快,有更多的过零点。短时平均过零率能反映声纹信号的频率特征。声纹信号第 i 帧的过零率计算如式(9)和式(10)所示。

$$R_{zci} = \frac{1}{2} \sum_{i=0}^N | \operatorname{sgn}[s(i)] - \operatorname{sgn}[s(i-1)] | \quad (9)$$

$$\operatorname{sgn}[s(i)] = \begin{cases} 1, s(i) \geq 0 \\ -1, s(i) < 0 \end{cases} \quad (10)$$

2 实验过程与结果

2.1 数据信息

本实验使用的数据集来源于现场采集的西南地区某风电场的异常与正常风机运行时候的声纹信息,包括 2 台正常风机以及 4 台叶片异常风机。其中,风电场的风机额定功率均为 1.5 MW,叶轮直径为 82 m,最小叶轮转速为 0.940 rad/s,最大叶轮转速为 2.000 rad/s,在数据记录期间,风速范围 4~12 m/s。声纹信号采集系统包括 DES-C8TPT 型传感器、MPS-140801 采集卡以及 SignalPad 数据采集软件。采集的机组编号、受损类型、时长如表 1 所示,叶片的受损类型如图 1 所示。

表 1 声纹数据集信息

Table 1 Information of voiceprint data

编号	机组编号	叶片受损类型	采集时长/min
Data 1	12#,65#	叶片正常	6
Data 2	33#	叶片中部合膜缝破损	6
Data 3	17#	叶片中部前缘开裂	6
Data 4	42#	叶片根部破损	6
Data 5	25#	叶片叶尖破损	6

DES-C8TPT 型传感器安装方式为可扩展磁吸和螺栓两种方式,可在-40℃~60℃下正常工作,十分适合风机所处的工作环境,其内含 8 个高精度数字麦克风,利用阵列定位和定向增强算法,具有较高的信噪比和屏蔽环境干扰的能力,采样频率范围为 20 Hz~96 kHz。经过实地考察,在叶片正下方采集效果最好。考虑到风机在运行时随风向偏航的情况,为保证装置能够一直采集叶片的扫风声纹,将采集装置安装到风机的塔筒上,距离地面 3 m 左右。为了保证采集到质量较高的声纹信号,同时




图 1 风机叶片 4 种受损类型

Fig. 1 Four damage types of wind turbine blades

为避免冗余的高频信息,装置的采样频率设置为 48 kHz。

2.2 CEEMD、EEMD 和 CEEMDAN 算法分解结果对比

通过实验比较声信号处理领域中比较常用的自适应噪声完全集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)、CEEMD 和 EEMD 3 种算法在对中部前缘开裂声纹信号分解方面的效果,实验结果为 EEMD 和 CEEMD 分别分解得到 11 个 IMF,CEEMDAN 分解得到 13 个 IMF,3 种分解结果均含有 1 个残差分量。EEMD 和 CEEMD 分解得到更少的 IMF,信号分解更简洁和高效。图 2 是 3 种模态分解算法对同一帧声纹信号模态分解的前 4 层模态分量图,其中图 2(a)为 EEMD 算法信号分解图,图 2(b)为 CEEMD 算法信号分解图,图 2(c)为 CEEMDAN 算法信号分解图。

可以看出:与 EEMD 相比,CEEMD 分解图的 IMF1~IMF4 的时域波形与原始信号的波形接近,说明 CEEMD 分解的模态分量与原始信号相似性和相关性更高,在分解过程中较好地保留了原始信号的主要时域特征,包括振荡、衰减、起伏等,并能够有效地抑制噪声干扰,提取出原始信号中的真实时域信息,有更好的分解效果。CEEMDAN 的分解结果图中,IMF1、IMF2 和 IMF3 的频率信号的峰值接近,未能较好的分解信号的频率分量。EEMD 和 CEEMD 分解图中,随着 IMF 阶数增大,其频率成分越来越单一,表现出更强的规律性。通过 3 种算法分解结果对比可以得到:CEEMD 算法在分解风机叶片声纹信号方面表现出更好的效果和性能,其高度的相似性

和相关性,以及对频率分量的准确提取,使得 CEEMD 成为选择的分解方法。

2.3 声纹特征提取及融合

对风机正常运行工况声纹以及 4 种异常运行工况声




图 2 3 种模态分解算法的模态分量对比图
Fig. 2 Comparison of modal components of three modal decomposition algorithms




图 3 帧信号特征提取与融合流程

Fig. 3 Frame signal feature extraction and fusion process

纹信号做分帧处理特征提取及融合如图 3 所示,有以下 4 个步骤:

步骤 1)通过模态分量皮尔逊相关系数计算,确定有效模态分量层数 n ,相关系数越高,各模态分量的有效信息越多,以 0.05 为阈值,根据相关系数排列次序,选择系数大于 0.05 的模态分量,根据实验结果,各运行工况的叶片声纹 n 值均为 8,图 4 为模态分量相关系数图。

步骤 2)对每层模态分量提取 13 维 MFCC、LPCC 和 GTCC,并按照式(9)和(10)计算每层模态分量的短时能量 E_i 和短时平均过零率 ZCR_i 。

步骤 3)依次拼接特征 MFCC、LPCC、GTCC、 E_i 和 ZCR_i ,形成大小为 (1×41) 的特征向量。

步骤 4)按照相关系数排列次序,依次拼接步骤 3)得到的特征向量,形成大小为 $(n \times 41)$ 的特征向量。

2.4 实验结果分析

实验所用的声纹信号包括正常叶片声纹、叶片中部合膜缝破损声纹,叶片中部前缘开裂声纹,叶片根部破损声纹和叶片叶尖破损声纹 5 种。每种声纹信号的样本数为 200,采用五折交叉验证的测试方法,其中每种声纹 160 个为训练样本,40 个为测试样本。各声纹信号的采样频率为 48 kHz,实验将多种特征组合在 SVM^[20],朴素贝叶斯^[21]和神经网络^[22]模型下进行分类识别,并采用平均识别率作为各模型的性能评价指标(识别率取 20 次平均值)。表 2 为各特征组合在 3 种分类模型下的识别率。

表 2 不同特征组合的识别率

Table 2 Recognition rate of different feature combinations				
(%)				
特征	SVM	神经网络	朴素贝叶斯	
MFCC	76.6	80.8	81.6	
GTCC	68.2	70.1	70.8	
LPCC	77.1	72.5	71.7	
MFCC_GTCC	87.7	87.6	81.4	
MFCC_LPCC	85.3	87.2	84.1	
GTCC_LPCC	79.4	78.1	76.2	
MFCC_GTCC_LPCC	83.6	86.8	88.7	
MFCC_GTCC_LPCC_ E_i _ ZCR_i	95.0	96.2	93.8	




图 4 模态分量相关系数图

Fig. 4 Correlation coefficients of modal components

由表 2 可知,相比 MFCC,GTCC,LPCC 等单特征或双特征组合,MFCC_GTCC_LPCC_ E_i _ZCR $_i$ 特征组合能显著提高故障声纹的识别率,3 种分类模型识别率均能提高 10% 以上,相比 MFCC_GTCC_LPCC 特征组合,MFCC_GTCC_LPCC_ E_i _ZCR $_i$ 特征组合在 3 种分类模型下识别率分别提高 11.4%、9.4%、5.1%。与 SVM 和朴素贝叶斯分类模型相比,神经网络对五特征组合以及三特征组合的识别率最高,为尽可能提高风机叶片异常时的识别率,选择神经网络进行参数寻优。

分别采用贝叶斯优化^[23]、网格搜索^[24]、随机搜索^[25]对神经网络的全连接层数、全连接层大小、激活函数、正则化强度等进行参数寻优,其中,迭代数为 50,评估指标为故障平均识别率,寻优结果如表 3 所示。

表 3 寻优算法性能对比

Table 3 Performance comparison of optimization algorithms

优化算法	参数寻优时间/s	故障平均识别率/%
贝叶斯优化	598. 81	97. 5
网格搜索	1 848. 12	97. 3
随机搜索	617. 61	96. 9

由表 3 可以看出,采用贝叶斯优化的神经网络故障识别率最高,5 种声纹信号在参数寻优后的平均识别率为 97. 5%,且参数寻优的时间最短。相较于贝叶斯优化,网格搜索在寻优过程中要遍历所有可能的参数值,导致寻优时间较长,而且容易陷入局部最优解,降低了故障识别的效率。随机搜索调参依赖迭代次数,且随机搜索时不容易寻找到最优参数组合,导致故障平均识别率不如贝叶斯优化,图 5 为贝叶斯优化算法的模型训练结果。

参数寻优后的模型包括 3 层全连接层,其大小依次为 28、194、273。模型正则化强度 (Lambda) 设置为




图 5 贝叶斯优化模型训练图

Fig. 5 Training diagram of Bayesian optimized model

0.083 398,采用 ReLU 函数为激活函数。5 种声纹经过参数寻优后的神经网络模型识别的混淆矩阵如图 6 所示,由图 6 可知,正常叶片和叶尖破损的识别准确率达到 100%,根部破损叶片的识别率为 98.0%,前缘开裂叶片的识别率为 97.7%,合缝膜破损叶片的识别率为 95.6%。在实际中,叶尖破损的区域长度约 6 cm,面积约为 13 cm²,相较于其他几种异常叶片,其破损面积更大,导致声音特征变化更明显,故障分类模型对其的识别率最高。合缝膜破损的叶片的损伤区域长度最小,约为 5 cm,属于叶片的早期异常类型,与正常叶片相比,声音特征变化最不明显,故障分类模型对其仍取得较高的识别准确率,说明上述方法对早期异常的风机叶片识别效果较好。




图 6 5 种声纹识别的混淆矩阵

Fig. 6 Confusion matrix of five voiceprint recognition

图 7 为各声纹特征 L2 范数平行坐标图,L2 范数是一种衡量向量之间距离的指标,在 L2 范数平行坐标图

中,横轴为各声纹特征,纵轴为对应特征的数据样本,由图 7 可知,MFCC、LPCC、GTCC、短时平均过零率 4 种特征数据样本的二范数差值均小于 0.05,短时能量特征样本的二范数差值小于 0.1,表明所验证的数据样本之间差异较小。




图 7 各特征 L2 范数平行坐标图

Fig. 7 Parallel coordinate diagram of L2 norm of each feature

5 种声纹各选取 140 个训练数据,30 个测试数据以及 30 个验证数据进行神经网络模型的拟合,图 8 是模型的拟合回归图,表现输出数据与目标数据直接的相关性,图 8 为神经网络模型拟合回归图。




图 8 神经网络模型拟合回归图

Fig. 8 Regression diagram fitted by neural network model

由图 8 可知,训练集、验证集、测试集和整体的拟合值 R 分别为 0.979 16、0.976 22、0.973 15 和 0.977 48,说明此神经网络模型在训练集、验证集和测试集上都具有较高的拟合能力,并且具有良好的泛化能力。图 9 为 5 种风机叶片声纹在参数寻优后的神经网络模型下的受试者工作特征 (receiver operating characteristic, ROC) 曲线,即 ROC 曲线。




图 9 5 种风机叶片声纹 ROC 曲线图

Fig. 9 ROC curves of five wind turbine blade voiceprint

ROC 曲线中横坐标为假正率,纵坐标为真正率。ROC 曲线越靠近左上角,分类器的性能越好,能够同时实现较低的假正率和较高的真正率,ROC 曲线的线下面积 (area under the curve, AUC) 是对 ROC 曲线的度量,代表着分类器的整体性能。AUC 值越大,分类器区分能力和准确性越高^[26]。由图 9 可以看出,5 种声纹的 AUC 均接近于 1,表明文章方法在风机叶片异常识别方面效果较好。

为了进一步验证所提出的基于声纹特征融合用于故障诊断的有效性。选择公开的环境声音数据集 ESC50 进行分类模型的泛化性验证,其中包括动物声音 (奶牛、狗、青蛙、公鸡)、自然声音 (海浪、雨声、雷电、篝火)、人类非语言声音 (咳嗽、刷牙、笑、鼓掌)、家庭声音 (敲门、洗衣、闹钟、点击鼠标) 以及室外噪音 (引擎、烟花、鸣笛、机舱) 共 5 类别 20 种声音片段,通过上文验证的神经网络模型分类识别,识别率达到 96.8%,图 10 为环境声音识别的混淆矩阵。实验验证了分类模型的泛化性能较好,再次说明了文章提出的基于风机声纹特征融合进行叶片异常识别的有效性。

3 结 论

为实现风机叶片异常时的准确监测,提出一种风机叶片声纹特征提取并融合的方法。将采集到的不同工作状态下的风机叶片的声纹数据,进行降噪、分帧和加窗操作的预处理后,选择互补集合经验模态分解算法对声纹信号进行二次降噪,用于去除信号中的变桨噪声、环境噪声以及机械运行噪声。通过计算皮尔逊相关系数筛选有效的模态分量,对每层的模态分量提取包含声信号频谱特性、包络特性以及时间域的特征,其中包括:梅尔频率




图 10 环境声音识别的混淆矩阵

Fig. 10 Confusion matrix of environmental sound recognition

倒谱系数、线性预测倒谱系数、gammatone 倒谱系数、短时能量、以及短时平均过零率特征,结果表明,所提出的方法在参数寻优后的神经网络模型下对叶片的早期异常有着较高的识别准确率。该方法在风机叶片状态的监测方面,由于传感器安装方便成本较低,而且可利用现有机组的 SCADA 冗余通道就可以进行数据采集,进而能够快速识别早期的叶片异常,对不同的异常类型能实现准确的分类,具有投资小、检测实时性强等优势,以及很好的工程应用和推广价值。本文提出的异常检测方法为风机叶片智能运维领域提供了新的方法论,本文仅讨论了异常的识别,以声特征理论为基础,找寻声纹特征与叶片缺陷大小的关系是后续研究目标。

参考文献

[1] 李明辉,黄鹏宇,陈诗,等. 基于光纤光栅的风机叶片应变与振动监测技术 [J]. 南京航空航天大学学报, 2023, 55 (5): 898-904.

LI M H, HUANG P Y, CHEN SH, et al. Strain and vibration monitoring technology of fan blade based on Fiber Bragg grating [J]. Journal of Nanjing University of Aeronautics and Astronautics, 2023, 55 (5): 898-904.

[2] 顾永强,冯锦飞,张哲玮,等. 基于模态参数的在役风力发电机叶片损伤识别研究 [J]. 太阳能学报, 2022, 43 (3): 350-355.

GU Y Q, FENG J F, ZHANG ZH W, et al. Research on blade damage identification of in-service wind turbine based on modal parameters [J]. Acta Energaie Solaris

Sinica, 2022, 43 (3): 350-355.

[3] THERESA L, ALEXANDER B. Vibration-based fingerprint algorithm for structural health monitoring of wind turbine blades [J]. Applied Sciences, 2021, 11 (9): 4294-4294.

[4] MOTAMED K P, ABEDIAN A, NASIRI M. Optimal sensors layout design based on reference-free damage localization with lamb wave propagation [J]. Structural Control and Health Monitoring, 2020, 27 (4), DOI: 10.1002/stc.2490.

[5] 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.

LIU Y, CHU Y H, LI B. Fan blade corrosion detection based on continuous thermal excitation infrared detection [J]. Laser & Infrared, 2023, 53 (5): 716-722.

[6] 马良玉,袁乃正. 基于 CFSFDP 与 LightGBM 的风电机组异常状态预警研究 [J]. 太阳能学报, 2023, 44 (5): 401-406.

MA L Y, YUAN N ZH. Research on abnormal state warning of wind turbine based on CFSFDP and LightGBM [J]. Acta Energaie Solaris Sinica, 2023, 44 (5): 401-406.

[7] 孙栋钦,汤占军,李英娜,等. 基于 ISOA-KELM 的风机叶片腐蚀速率预测 [J]. 表面技术, 2022, 51 (11): 271-304.

SUN D Q, TANG ZH J, LI Y N, et al. Prediction of fan blade corrosion rate based on ISO-KELM [J]. Surface Technology, 2022, 51 (11): 271-304.

[8] DIAZP M, TITTUS P. Fast detection of wind turbine blade damage using cascade mask R-DSCNN-aided drone inspection analysis [J]. Signal, Image and Video Processing, 2023, 17 (5): 2333-2341.

[9] EMRE B, JUN W Z, ZHONG W S, et al. Consistent modelling of wind turbine noise propagation from source to receiver[J]. The Journal of the Acoustical Society of America, 2017, 142 (5): 3297-3310.

[10] 邹宜金,连应华,黄新宇,等. 基于声纹的高泛化性风机叶片异常检测方法研究 [J]. 电子科技大学学报, 2021, 50 (5): 795-800.

ZOU Y J, LIAN Y H, HUANG X Y, et al. Research on anomaly detection method of highly generalized fan blade based on voice print [J]. Journal of University of

- Electronic Science and Technology of China, 2021, 50(5):795-800.
- [11] 赵娟,陈斌,李永战,等. 复杂背景噪声下风机叶片裂纹故障声学特征提取方法[J]. 北京邮电大学学报, 2017,40(5):117-122.
ZHAO J, CHEN B, LI Y ZH, et al. Acoustic feature extraction method for fan blade crack fault under complex background noise [J]. Journal of Beijing University of Posts and Telecommunications, 2017,40(5):117-122.
- [12] 王丰华,王邵菁,陈颂,等. 基于改进 MFCC 和 VQ 的变压器声纹识别模型[J]. 中国电机工程报, 2017, 37(5):1535-1543.
WANG F H, WANG SH J, CHEN S, et al. Transformer voice recognition model based on improved MFCC and VQ [J]. Proceedings of the CSEE, 2017, 37(5): 1535-1543.
- [13] 王立宪,马宏忠,戴锋. 基于改进 SVD_EMD 的绝缘子泄漏电流去噪方法[J]. 电子测量与仪器学报, 2022, 36(1): 166-173.
WANG L X, MA H ZH, DAI F. Insulator leakage current denoising method based on improved SVD_EMD [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 166-173.
- [14] MEND D B, WANG H T, YANG S Y, et al. Fault analysis of wind power rolling bearing based on EMD feature extraction [J]. Computer Modeling in Engineering & Sciences, 2022, 130(1): 543-558.
- [15] YANG F, SHENG G, XU Y, et al. Application of EEMD and high-order singular spectral entropy to feature extraction of partial discharge signals [J]. IEEE Transactions on Electrical and Electronic Engineering, 2018, 13(7): 1002-1010.
- [16] DING Y F, CHEN Z J, ZHANG H W, et al. A short-term wind power prediction model based on CEEMD and WOA-KELM [J]. Renewable Energy, 2022, 189: 188-198.
- [17] 狄晓栋,李震梅,李宗哲,等. 基于混合特征 MGCC 的干式变压器故障诊断[J]. 电子测量技术, 2021, 44(12): 57-62.
DI X D, LI ZH M, LI ZH ZH, et al. Fault diagnosis of dry-type transformer based on hybrid feature MGCC [J]. Electronic Measurement Technology, 2021, 44(12): 57-62.
- [18] HYUNSIN P, D C Y. CNN-based learnable gammatone filterbank and equal-loudness normalization for environmental sound classification [J]. IEEE Signal Processing Letters, 2020,27:411-415.
- [19] MURUGAIYA R, ABAS E P, SILVA D C L. Probability enhanced entropy (PEE) novel feature for improved bird sound classification [J]. Machine Intelligence Research, 2022, 19(1): 52-62.
- [20] 付乐天,李鹏,高莲. 考虑样本异常值的改进最小二乘支持向量机算法[J]. 仪器仪表学报, 2021, 42(6): 179-190.
FU L T, LI P, GAO L. Improved least squares support vector machine algorithm considering sample outliers [J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 179-190.
- [21] YU X S, XIN J L, YING T N, et al. Efficient jamming identification in wireless communication: Using small sample data driven naive bayes classifier [J]. IEEE Wireless Communications Letters, 2021, 10(7): 1375-1379.
- [22] 许晓伟,赖际舟,吕品,等. 基于双层神经网络模型参数辨识的变结构多模型自主导航方法[J]. 中国惯性技术学报, 2021,29(4):428-436.
XU X W, LAI J ZH, LYU P, et al. Variable structure multi-model autonomous navigation method based on two-layer neural network model parameter identification [J]. Journal of Chinese Inertial of Technology, 2021,29(4): 428-436.
- [23] MURUGESAN M, THILAGAMANI S. Bayesian feed forward neural network-based efficient anomaly detection from surveillance videos [J]. Intelligent Automation & Soft Computing, 2022, 34(1): 389-405.
- [24] 樊简,赵硕,蔡文硕,等. 采用网格搜索的非合作卫星时差累积协同定位方法[J]. 国外电子测量技术, 2022, 41(3): 56-62.
FAN J, ZHAO SH, CAI W SH, et al. Time difference accumulation collaborative positioning method for non-cooperative satellites using grid search [J]. Foreign Electronic Measurement Technology, 2022, 41(3): 56-62.
- [25] 龙家雨,宋美琪,柴翔,等. 基于聚类和随机搜索优化的核反应堆数字孪生参数反演模型[J]. 原子能科学技术, 2024, 58(1): 125-134.
LONG J Y, SONG M Q, CHAI X, et al. Inversion model of nuclear reactor digital twin parameters based on clustering and random search optimization [J]. Atomic Energy Science and Technology, 2024, 58(1):

125-134.

- [26] 李伟红,田真真,龚卫国,等. 改进的 ESMD 用于公共场所异常声音特征提取[J]. 仪器仪表学报,2016,37(11):2429-2437.

LI W H, TIAN ZH ZH, GONG W G, et al. Improved ESMD for abnormal sound feature extraction in public places [J]. Chinese Journal of Scientific Instrument, 2016,37(11):2429-2437.


作者简介



余洪伍,2017 年于中南大学信息科学与工程学院获得学士学位,现为昆明理工大学硕士研究生,主要研究方向为风力发电机故障诊断。

E-mail: 2232821368@qq.com

Yu Hongwu received his B. Sc. degree from School of Information Science and Engineering, Central South University in 2017. Now he is a M. Sc. candidate at Kunming University of Science and Technology. His main research interest includes wind turbine fault diagnosis.



汤占军(通信作者),2007 年获昆明理工大学硕士学位,高级工程师,硕士生导师,主要研究方向智能控制。

E-mail: tzj504@163.com

Tang Zhanjun (Corresponding author), received his M. Sc. degree from Kunming University of Science and Technology in 2007. Now he is a senior engineer and a master's supervisor at Kunming University of Science and Technology. His main research interest includes intelligent control.