

基于 RBVS 和 CBCNN 的风机叶片 故障检测和分类方法

周求湛¹, 牟 岩¹, 武慧南¹, 陈 霄¹, 汪 锋², 李 琛²,
张 雯², 刘萍萍³, 王 聪¹

(1. 吉林大学 通信工程学院, 长春 130012; 2. 华锐风电科技(江苏)有限公司, 江苏 盐城 224056; 3. 吉林大学
计算机科学与技术学院, 长春 130012)

摘 要: 为提高风机叶片故障检测时故障分类精度, 提出了一种基于机器学习的风机叶片故障检测和分类方法。首先, 将岭回归与蜂群优化算法(BSO)相结合提出了 R-BSO 特征选择算法, 该算法用于筛选出最优特征子集。然后, 将由 R-BSO 算法提取出的最佳特征组合输入基于 Stacking 策略的分类模型中得出分类结果, 完成叶片故障检测 RBVS 算法的构建。最后, 提出了一种基于卷积注意力机制(CBAM)的卷积神经网络(CNN)叶片故障分类算法 CBCNN。实验结果表明: 本文算法在风机叶片故障检测和分类上具有较好的性能。

关键词: 特征选择; 机器学习; Stacking; 卷积神经网络; 卷积注意力机制

中图分类号: TP274 **文献标志码:** A **文章编号:** 1671-5497(2025)10-3119-12

DOI: 10.13229/j.cnki.jdxbgxb.20240617

Fault detection and classification of wind turbine blades based on machine learning

ZHOU Qiu-zhan¹, MU Yan¹, WU Hui-nan¹, CHEN Xiao¹, WANG Feng², LI Chen²,
ZHANG Wen², LIU Ping-ping³, WANG Cong¹

(1. College of Communication Engineering, Jilin University, Changchun 130012, China; 2. Sinovel Wind Power Technology (Jiangsu) Co., Ltd., Yancheng 224056, China; 3. College of Computer Science and Technology, Jilin University, Changchun 130012, China)

Abstract: To improve the classification accuracy of fault detection for wind-turbine blades, a machine-learning-based fault detection and classification method is proposed. First, a Ridge-regression-enhanced Brain Storm Optimization (R-BSO) feature-selection algorithm is developed to identify an optimal feature subset. The best feature combination extracted by R-BSO is then fed into a Stacking-based classifier to produce the final prediction, completing the RBVS blade-fault detection framework. Finally, a convolutional neural network equipped with a Convolutional Block Attention Module (CBAM), termed CBCNN, is introduced for blade-fault classification. Experimental results demonstrate that the proposed

收稿日期: 2024-06-03.

基金项目: 盐城市重点研发计划(工业)项目(BE2023008); 国家自然科学基金项目(62071199).

作者简介: 周求湛(1974-), 男, 教授, 博士. 研究方向: 微弱信号检测. E-mail: 13504465154@163.com

通信作者: 王聪(1990-), 男, 副教授, 博士. 研究方向: 优化理论. E-mail: wangcong2020@jlu.edu.cn

algorithms achieve superior performance in both detection and classification of wind-turbine blade faults..

Key words: feature selection; machine learning; stacking; convolutional neural network; convolutional block attention module(CBAM)

0 引言

风能作为一种清洁的可再生能源,大力发展风电产业是未来的发展趋势。风机叶片作为风电机组的关键部件,常年遭受雨水、强风、沙暴、雷击、严寒和紫外线侵袭,导致风机叶片会出现开裂、结冰以及叶片不平衡等现象。不仅会使风机工作效率下降,而且会导致风电机组的使用寿命缩短,对风电机组维护人员的人身安全造成严重威胁。因此,及时对风机叶片进行故障检测和分类,不仅可以提高风电机组的使用安全性,还能创造更多的经济效益。

Anindya等^[1,2]通过实验证明了使用压电陶瓷贴片进行激励和使用扫描激光多普勒测振仪(Scanning laser doppler vibrometer,SLDV)或压电陶瓷贴片来测量振动以检测损坏的可行性。但该方法需要进一步测试不同的较小损伤和损伤类型,以进一步验证方法的灵敏度。共振曲线方法(Resonance curve, RC)方法可用于操作损坏检测,而操作挠度形状(Operational deflection shape, ODS)即方法产生非对称轮廓,这是一种易于解释的方法,用于检测不移动结构中的损坏。洛斯阿拉莫斯国家实验室(LANL)的研究人员在国家可再生能源实验室(NREL)和国家风能技术中心(NWTC)进行的全面疲劳测试中,从9 m CX-100叶片中提取了振动分析的实验测量值。在目前的研究中,使用了基于人工神经网络(ANN)的机器学习算法,包括基于标准ANN形式的自动关联神经网络(AANN)和与径向基函数(RBF)网络自动关联的新方法,这些算法针对快速高效的运行进行了优化。Dervilis等^[3-5]将这种模式识别方法引入风能领域,并试图通过将振动响应数据与新颖性检测技术相结合解决这些方法的有效性。Wang等^[6]将多通道卷积神经网络(MCNN)应用于风电机组叶片和叶片角度故障检测。该方法能够自动有效地捕获导入的原始振动信号中的故障特征,并在多个卷积神经网络(Convolutional neural networks,CNN)模型中识别其状态。将每个模型获得的结果发送到输出层,即最大输出网络

(MAXNET),以计算最准确的状态。首先,在风电机组叶片状态检测方面,基于叶片角度异常、叶片表面损伤和叶片断裂3种常见故障类型构建叶片模型。振动信号用于故障检测。本文风电机组故障诊断方法采用三轴振动传感器和图像采集卡捕获振动信号,然后应用新的MCNN算法识别状态。实验结果表明,所提方法对4种大型风电机组叶片故障类型的识别准确率高达87.8%。

目前风机叶片的研究存在如下问题:①在风机叶片故障检测的方法中,传统的特征选择方法并不能完全除去冗余特征,并且单一的分类模型在一定程度上具有局限性,致使其分类准确率较低;②在故障分类方法中,复杂度较低的故障诊断技术诊断效果略差。因此,需要对不同类型的振动信号进行特性分析,根据其特性构建有效的故障诊断模型。

针对上述问题,本文提出了一种基于机器学习和深度学习的风机叶片故障检测和分类方法。①首先将传统的特征选择方法与群智能算法相结合提出了R-BSO特征选择算法,该算法通过使用岭回归算法(Ridge regression)过滤掉冗余特征,降低特征集的整体维度,再利用蜂群优化算法(Bee swarm optimization,BSO)筛选出最优特征子集;选取随机森林、XGBoost和极度随机树3种在本文使用的数据集上表现较好的学习器,利用软投票机制对上述3种模型两两进行集成,将得到的3个集成后的强学习器作为Stacking策略的基学习器,将逻辑回归作为元学习器,构建分类模型;最后将由R-BSO算法提取出的最佳特征组合输入基于Stacking策略的分类模型中得出分类结果,完成叶片故障检测RBVS算法的构建。

经过实验验证,本文提出的R-BSO算法优于其他对比算法,可以更好地特筛选出最佳特征组合;然后将本文提出的RBVS算法与其他对比算法进行实验对比,能够得出RBVS算法的评价指标均高于其他对比模型,在检测风机叶片故障信号上具有较好的性能。②利用箱线图对正常振动信号、裂纹振动信号和结冰振动信号的简单特征进行分析,可以得出利用简单特征构建的故障诊

断算法难以区分以上 3 类振动信号。因此,本文采用神经网络从信号中提取复杂特征,再利用分类器实现对以上 3 类信号的分类,并提出一种基于卷积注意力机制(Convolutional block attention module, CBAM)的 CNN 叶片故障诊断算法 CBCNN,该算法首先利用短时傅里叶变换(Short-time fourier transform, STFT)得到各类信号的时频图用来表征信号的时频特性,将得到的时频图灰度化处理;然后利用二维卷积层提取信号的时频特征,经过多层卷积层和池化层后,最后结合 CBAM 卷积注意力机制完成基于卷积注意力机制的卷积神经网络叶片故障诊断算法 CBCNN 的构建。通过与对比算法进行实验验证及结果分析,可以得出本文所提出的 CBCNN 算法能更准确地实现风机叶片正常振动信号、裂纹振动信号和结冰振动信号的分类。

1 基于 R-BSO 和 Stacking 策略的叶片故障检测算法

1.1 特征提取与筛选

本文所使用的数据集为 Zenodo 公开数据集,该数据集包含 3 种风机叶片的振动信号,分别为正常振动信号、裂纹振动信号和结冰振动信号。该振动信号是由工作范围为 $\pm 10g$ ($g=9.8 \text{ m/s}^2$) 的 8 个加速度计所组成的网络采集而来。本文是在该数据集的基础上进行研究。

由于风机叶片转动时产生的正常振动信号和故障振动信号具有差异性,因此,可以对以上两类振动信号进行特征提取,利用提取后的信号特征构建故障信号检测方法,实现正常振动信号和故障振动信号的区分。本文所选用的时域和频域特征包括如下特征:均值、标准差、方根幅值、RMS 均方根、峰峰值、偏度、峭度、峰值因子、裕度因子、波形因子、脉冲因子、能量最大频率、重心频率、平均频率、1~8 频段能量。其中,1~8 频段能量是利用小波包分解技术进行 3 层小波包分解得到的各频段的能量。

上述特征中,某些特征之间的关联性强,冗余特征较多,如果不滤除冗余特征,将导致模型的分类精度较低。由于特征选择直接影响后续模型分类的性能,因此,选择出最佳特征组合十分重要。群智能特征选择算法中的 BSO 算法在特征筛选上

具有较为优越的性能^[7,8]。但是,由于特征集合中存在着冗余特征可能会导致 BSO 算法陷入局部最优解的问题。Ridge regression 算法作为嵌入式特征选择算法中的一种,能够有效降低过拟合风险,提高模型的泛化能力。因此,本文利用 Ridge regression 算法对上述所有特征进行预筛选,将特征集中的冗余特征进行滤除,能够有效减少特征维度,在提高 BSO 算法搜索效率的同时,也能够使 BSO 算法避免产生局部最优解的问题。综上所述,本文提出了一种基于岭回归策略的蜂群优化算法(R-BSO),用来筛选出更优的特征子集。

R-BSO 算法结合了 Ridge regression 算法以及 BSO 算法的优点,可在本文基于风机叶片振动信号提取的 22 维时域和频域特征集合中筛选出最佳特征组合。R-BSO 算法结构图如图 1 所示。

R-BSO 算法包括数据转换、基于岭回归的预筛选特征和基于 BSO 算法的最终特征筛选 3 个步骤。

1.1.1 数据转换

R-BSO 算法首先将输入的多维特征数据进行数据转换,将输入数据转换成可用于 Ridge regression 算法的数据矩阵:

$$X = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & & \vdots \\ x_{m1} & \cdots & x_{mn} \end{pmatrix} \quad (1)$$

式中: x_{ij} 为第 i 个样本的第 j 个特征。

1.1.2 预筛选特征

利用 Ridge regression 算法对上述所有特征进行预筛选,将特征集中的冗余特征进行滤除,能够有效减少特征维度,在提高 BSO 算法搜索效率同时,也能够使 BSO 算法避免产生局部最优解的问题。

1.1.3 最终特征筛选

利用经过预筛选后的特征集合得到初始参考解,通过局部搜索,每只蜜蜂得到一定数量的特征子集。然后对每个特征子集的准确率予以计算,将最高准确率所对应的特征集合更新为当前时刻的全局最优解,并与其他特征集合一并存入存储单元中。此存储单元的一个解决方案将被选作下一次迭代的参考解,直至迭代结束,最后将最终选取的全局最优解作为最佳特征组合予以返回,并输出各特征的重要性排名和各特征的重要性得分。




图 1 R-BSO 算法结构图

Fig. 1 Structure of the R-BSO algorithm

1.2 本文叶片故障检测算法

在模型分类中,单一模型在做分类时会表现出一些局限性,而 Stacking 策略可以将强学习器进行集成,将这些较为强大的学习器作为 Stacking 策略的基学习器,用于提取输入数据的数据特征,可以产生稳定性更强且准确率更高的分类结果。因此,Stacking 策略可以集成强学习器的优势,以达到较高的分类准确率。Stacking 策略的结构图如图 2 所示。




图 2 Stacking 策略结构图

Fig. 2 Stacking strategy structure diagram

Stacking 策略中有两个学习层,第 1 层中使用不同的机器学习算法作为基学习器,第 2 层中的元学习器对第 1 层的输出结果进行分类。由于 Stacking 策略中的第 1 层将这些较为强大的学习器作为基学习器,用于提取输入数据的数据特征,因此,第

2 层容易出现过拟合的问题。为了避免该问题,Stacking 策略的第 2 层应采用复杂度较低的分类器。而逻辑回归(Logistic regression)方法只有较为简单的线性变换,且具有特征筛选的功能,因此,在 Stacking 算法的第二层中,逻辑回归不仅能有效解决过拟合的问题,还可以滤除第 1 层学习器提取的冗余特征。

为了使整个健康监测模型产生更为稳定且准确的分类结果,选取随机森林、XGBoost 和极度随机树 3 种在本文所使用的数据集上表现较好的模型,并利用软投票机制对上述 3 种模型两两进行集成,将得到的 3 个集成后的强学习器作为 Stacking 策略的基学习器。利用投票机制将模型进行集成可以充分发挥各模型的优势,使各子模型间优势互补。因此,将投票机制集成后的模型分别作为 Stacking 策略的基学习器,可以更好地对数据集中的数据特征进行抽取,并增强模型的泛化能力。在投票机制中包含硬投票和软投票两种,相比硬投票,软投票会使概率高的模型获得更多的权重,因此表现更好。

综上所述,本文首先利用基于岭回归的蜂群优化算法(R-BSO)在提取的振动信号时域和频域特征中筛选出最佳特征组合;然后选取随机森林、XGBoost 和极度随机树 3 种在本文所使用的数据集上表现良好的学习器,利用软投票机制对上述 3 种模型两两进行集成,将得到的 3 个集成后

的强学习器作为 Stacking 策略的基学习器,将逻辑回归作为元学习器,构建分类模型;最后将由 R-BSO 算法提取出的最佳特征组合输入基于

Stacking 策略的分类模型中得出分类结果,完成叶片健康监测 RBVS 算法的构建。其结构如图 3 所示。




图3 RBVS算法结构图

Fig. 3 Structure of RBVS algorithm

2 基于卷积注意力机制和卷积神经网络的叶片故障分类算法

2.1 特征分析

选择有效的分类特征是风机叶片故障诊断模型进行故障分类的重要一环,常用于风机叶片故障诊断的特征包含简单特征和神经网络提取的复杂特征。

通过对叶片正常振动信号、裂纹振动信号和结冰振动信号的均值、标准差、方根幅值、RMS均方根、峰峰值、偏度、峭度、峰值因子、裕度因子、波形因子、脉冲因子、能量最大频率、重心频率、平均频率、1~8频段能量22个简单特征利用箱线图进行对比可以得出,利用简单特征构建的故障诊断算法难以区分正常振动信号、裂纹振动信号和结冰振动信号3类信号。因此,本文采用神经网络从信号中提取复杂特征,再利用分类器实现对以上3类信号的识别。

使用短时傅里叶变换得到各类振动信号的时频图表征信号的时频特性,STFT利用移动加窗快速傅里叶变换计算,得到信号的一系列频谱,并可以反映信号的频谱随时间的变化^[9-12]。信号 $s(t)$ 的STFT定义如下:

$$\text{STFT}(e^{j\omega}) = \sum_{m=-\infty}^{\infty} s(t)w(t-m)e^{-j\omega m} \quad (2)$$

式中: $w(t-m)$ 为窗函数。图4是对风机叶片正常、裂纹和结冰振动信号分别作STFT得到的结果图。其中,重叠窗口是0.005 s,窗口长度是0.01 s。

通过对正常振动信号、裂纹振动信号和结冰振动信号的时频特性进行分析,可以得出其时频特征中包含能很好表征不同类别振动信号的特征。

2.2 本文算法

卷积神经网络作为深度学习算法中较为经典的一种,它采用多层感知器分析与获取数据中的特征^[13-15]。CNN在对图像的特征提取上也有着较为优越的性能。

通过对正常振动信号、裂纹振动信号和结冰振动信号的时频图对比,可以得出其时频特征中包含能很好地表征不同类别振动信号的特征。因此,利用短时傅里叶变换得到各类叶片振动信号的时频图。由于CNN在对图像的特征提取上也有着较为优越的性能,因此,利用CNN网络对经过灰度化处理后的时频图进行特征提取。

卷积神经网络主要有3种类型层,分别是卷积层、池化层和全连接层^[16]。CNN的基本结构如图5所示。

由于通过对正常振动信号、裂纹振动信号和




图 4 振动信号的时频图

Fig. 4 Time-frequency plot of vibration signal




图 5 CNN 结构

Fig. 5 Structure of CNN algorithm

结冰振动信号的时频图对比,可以得出其时频特征中包含能表征不同类别振动信号的特征。首先利用短时傅里叶变换得到信号的时频图表征信号的时频特性,依靠 CNN 网络对经过灰度化处理的时频图提取特征,最后经过识别层进行分类输出,得出分类结果。基于 CNN 的分类模型具有更好地区分正常振动信号、裂纹振动信号和结冰振动信号的性能。本文所设计的基于 CNN 的分类模

型 S-CNN 如图 6 所示。




图 6 S-CNN 结构

Fig. 6 Structure of S-CNN

利用 S-CNN 算法对本文所使用的振动信号的数据集进行特征提取时,并非提取的所有特征都有利于模型性能的提升。一般情况下,某些局部特征才是区分不同类型振动信号的重中之重。针对上述问题,本文通过添加注意力机制改变模型的兴趣点,进而提升模型对某些能够有效区分不同类型振动信号的局部特征的敏感度。因此,通过添加注意力机制可以使模型的特征提取能力进一步增强,从而提升整个模型的性能。

注意力机制是通过赋予每个特征图中的元素不同的注意力权重提高某些能够有效区分不同类型振动信号的局部特征的作用效果,忽略不重要的特征,从而提高模型整体性能^[17-19]。

根据不同的特征采样方式,注意力机制可以分为软注意力和硬注意力。与硬注意力相比,软注意力利用加权的方式选择输入数据,权重系数在 0~1,训练过程可通过利用梯度下降和反向传播机制进行,因此,在区域特征或空间特征上表现会更好。

软注意力又包含空间注意力、通道注意力以及混合注意力 3 种。

空间注意力通过对输入特征图中不同的区域设置不同的权重,寻找对网络影响最大的特征部分。而通道注意力通过分配各个通道之间的资源,能够有效减小冗余通道的影响^[20]。混合注意力则融合了空间注意力与通道注意力两种注意力机制,使与任务相关特征的权重得到最大限度的提升。卷积注意力是混合注意力中极具代表性的一种^[21],其结构如图 7 所示。

CBAM 增加了通道注意力分支以及空间注意力分支,分别计算注意力权重,并与输入特征图相结合,输出注意力加权结果 F' 以及 F'' 。CBAM 模块能够学习不同维度的注意力权重,比起单一




图7 CBAM模块结构

Fig. 7 CBAM module structure

的空间注意力和通道注意力,CBAM在实际网络中对模型性能的提升幅度更大。因此,本文通过添加CBAM改变模型的兴趣点,进而提升模型对某些能够有效区分不同类型振动信号的局部特征的敏感度,忽略不重要的特征,从而进一步提升模

型的整体性能。

本文通过对正常振动信号、裂纹振动信号和结冰振动信号的时频图对比,发现其时频特征中包含可以表征不同类别振动信号的特征。因此,首先利用短时傅里叶变换(STFT)表征信号时频特性的时频图,对得到的时频图进行灰度化处理;然后利用二维卷积层提取信号的时频特征,经过多层卷积层和池化层后,最后结合CBAM卷积注意力机制完成基于卷积注意力机制的卷积神经网络叶片故障诊断算法CBCNN的构建。CBCNN结构如图8所示。




图8 CBCNN算法结构图

Fig. 8 CBCNN algorithm structure diagram

3 实验结果与分析

以下所有相关实验均在具有 Intel(R) Core (TM) i5-12500H (CPU@2.50 GHz) 处理器和 16 G RAM 的 Windows 64 位操作系统中进行。

3.1 叶片故障检测算法实验结果与分析

本文首先对 R-BSO 算法进行评估,并将其与其他 5 种特征选择算法进行比较,包括 ReliefF 算法、蜂群优化算法 (BSO)、递归特征消除算法 (RFE)、LASSO 和 Ridge regression。然后对 RBVS 算法进行评估,将本文所选取的表现较好的随机森林^[22]、XGBoost^[23]、极度随机树^[24] 3 种单一模型以及 ReliefF RF^[25]、RFXGB^[26] 和 LGBXGB^[27] 作为对比算法,进行了实验比较和结果对比。

采用的评价指标如下:

(1) 准确率 (Accuracy)。用来评价对正常和故障两类信号判断正确次数的比例,可以评估算法检测故障信号的能力,其表达式如下:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

式中:TP 为正确检测的正样本;FP 为错误检测的正样本;TN 为正确检测的负样本;FN 为错误检测的负样本。

(2) 精确率 (Precision)。用来评价检测的准确程度,其表达式如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4)$$

(3) 召回率 (Recall)。用来评价检测的全面性,其表达式如下:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5)$$

(4) F_1 分数 (F_1 -score)。用来综合评价算法的精确率和召回率,其表达式如下:

$$F_1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

(5) ROC 曲线面积 (AUROC)。用来评估算法的可靠性,越可靠的模型对应的 AUROC 值

越高。

(6)PRC 曲线面积(AUPRC)。用来评估算法稳定性以及可靠性,越可靠的模型对应的 AU-PRC 值越高。

将 R-BSO 算法与其他特征选择算法在本文所利用的公开数据集上进行比较。图 9 和图 10 分别为 R-BSO 算法与其他算法的 ROC 曲线和 PRC 曲线的对比分析。




图 9 R-BSO 算法与其他算法的 ROC 曲线对比
Fig. 9 ROC curve comparison between R-BSO algorithm and other algorithms




图 10 R-BSO 算法与其他算法的 PRC 曲线对比
Fig. 10 PRC curve comparison between R-BSO algorithm and other algorithms

如图 9 和图 10 所示,R-BSO 算法在该数据集上检测裂纹故障的 AUROC 值和 AUPRC 值分别为 0.966 4 和 0.968 6。在其他对比算法中,最高的 AUROC 值与 AUPRC 值分别为 0.960 6 和 0.963 0。因此,R-BSO 算法均优于其他特征选择算法。综上所述,本文所提出的 R-BSO 特征选择算法可以有效地选择出最佳特征组合,使模型整体性能得到提升。

再利用 Accuracy、Precision、Recall、 F_1 -score 评价指标,将 R-BSO 算法和其他对比算法进行比

较,结果如表 1 所示。

表 1 R-BSO 算法与其他算法性能对比

特征算法	Accuracy	Precision	Recall	F_1 -score
R-BSO	0.893 7	0.894 4	0.893 5	0.899 8
RFE	0.843 7	0.826 4	0.872 6	0.848 9
LASSO	0.851 5	0.847 0	0.860 2	0.853 6
Ridge	0.884 3	0.887 5	0.881 9	0.884 7
BSO	0.887 5	0.876 5	0.893 2	0.889 9
ReliefF	0.867 1	0.855 8	0.885 0	0.870 2

从表 1 可以看出,R-BSO 算法的 Accuracy 是 0.893 7,而其他方法的最高准确率只有 0.887 5。R-BSO 算法 Precision、Recall 和 F_1 -score 的值分别为 0.894 4、0.893 5 和 0.899 8,而其他对比算法中,最高的 Precision、Recall 和 F_1 -score 的值分别为 0.887 5、0.893 2 和 0.889 9。因此,R-BSO 算法各评价指标均高于其他特征选择方法。综上所述,从整体评价指标而言,本文提出的 R-BSO 算法在特征选择上性能最佳。

然后,使用 R-BSO 特征选择算法选择最佳特征组合,根据 R-BSO 算法得出,最佳特征组合的特征数为 11,最佳特征组合中包含的特征为:能量最大频率、均值、偏度、峭度、1 频段能量、3 频段能量、5 频段能量、6 频段能量、8 频段能量、裕度因子和方根幅值。将上述得出的最佳特征组合作为本文分类模型的输入特征。

将本文选取的表现效果较好的随机森林、XGBoost、极度随机树 3 种单一机器学习模型以及 ReliefF RF、RFXGB 和 LGBXGB 作为对比算法,评估并对比本文提出的 RBVS 算法对叶片故障的检测性能。

如图 11 和图 12 所示,RBVS 算法在该数据集上检测裂纹故障的 AUROC 值和 AUPRC 值分别为 0.981 4 和 0.979 1。对比算法中,ReliefF RF 算法的 AUROC 值最高,为 0.971 5。在对比算法中,LGBXGB 算法的 AUPRC 值最高,为 0.971 9。通过对比 RBVS 算法与其他算法的 ROC 曲线和 PRC 曲线,可以看出 RBVS 相较于其他算法可靠性更高。

综上所述,可以看出,RBVS 算法的 Accuracy 是 0.938 4,而其他方法的最高准确率为 0.924 1,说明 RBVS 算法无论与本文所选取的表现良好的单一模型相比,还是与其他论文中的相关算法相比,在准确区分正常信号和故障信号方面具有较高的




图 11 RBVS算法与对比算法的ROC曲线比较
Fig. 11 Comparison of ROC curves between RBVS and contrast algorithms

准确率。对于RBVS算法的Precision、Recall、 F_1 -score、AUROC和AUPRC,RBVS算法均高于其他对比算法。因此,综上所述,从整体评价指标而言本文提出的RBVS算法在检测风机叶片故障信号上具有较好的性能。

表2所示分别为RBVS算法与其他算法对叶片故障检测的Accuracy、Precision、Recall、 F_1 -score、AUROC和AUPRC性能指标的值。




图 12 RBVS算法与对比算法的PRC曲线比较
Fig. 12 Comparison of PRC curves between RBVS and contrast algorithms

3.2 叶片故障分类算法实验结果与分析

本文依据公开数据集进行验证测试,被测数据包括叶片正常振动信号、裂纹振动信号以及结冰振动信号。

将LSTM^[28]和CNN^[29]与S-CNN算法作为对比算法,其中,LSTM是从信号的时域波形中提取特征,将得到的特征输入识别层,得出分类结果;CNN是从信号的一维时域波形中提取特征,将得到的特征输入识别层,得出分类结果。

表 2 RBVS 算法故障检测性能

Table 2 Fault detection performance of RBVS algorithm

评价指标	RBVS	随机森林	XGBoost	极度随机树	Relieff RF	RFXGB	LGBXGB
Accuracy	0.938 4	0.909 8	0.869 6	0.924 1	0.915 2	0.908 0	0.912 5
Precision	0.932 9	0.923 1	0.879 1	0.922 3	0.918 1	0.907 1	0.907 9
Recall	0.950 4	0.902 6	0.870 1	0.933 3	0.919 7	0.917 9	0.926 5
F_1 -score	0.941 6	0.912 7	0.874 6	0.927 8	0.918 9	0.912 5	0.917 1
AUROC	0.981 4	0.967 9	0.951 9	0.968 4	0.971 5	0.970 4	0.971 2
AUPRC	0.979 1	0.965 4	0.951 6	0.962 9	0.970 3	0.970 8	0.971 9

由各算法的模型损失变化图和模型准确率变化图(见图13)可以得出,利用LSTM从本文所使用的数据中各类信号的时域波形内提取特征与利用CNN从信号的一维时域波形中提取特征,再利用识别层得出分类结果的分类效果并不是很理想;本文通过短时傅里叶变换表征信号的时频特性,利用CNN网络对经过灰度化处理后的时频图提取特征构建S-CNN算法,通过该算法与LSTM和CNN对比可以看出,S-CNN算法拟合效果更好且Loss值更小;由于利用S-CNN算法对本文所使用的振动信号的数据集进行特征提取时,并非提取的所有特征都有利于模型的性能提升,因此,本文通过添加卷积注意力机制CBAM改变模型的兴趣点,构建叶片故障诊断CBCNN

算法。通过CBCNN算法与上述3种算法进行对比,可以得出CBCNN算法的Loss值最低且准确率提升较为明显,其拟合效果也是最好的。综上所述,CBCNN算法能从各类信号的时频图中提取出用于区分不同类别叶片振动信号的有效特征。各算法的模型损失变化图和模型准确率变化图如图13所示。

表3为本文提出的CBCNN算法与其他算法的Accuracy对比。

从表3中可以看出,本文提出的CBCNN在测试集上的Accuracy有了十分显著的提高,说明本文提出的CBCNN算法在对风机叶片的正常振动信号、裂纹振动信号和结冰振动信号的分类上具有较好的性能。与其他3种对比算法相比,本




图 13 CBCNN算法与其他算法的模型损失和模型准确率变化

Fig. 13 Model loss and model accuracy change between CBCNN algorithm and other algorithms

文提出的方法利用CNN网络对经过灰度化处理后的时频图提取特征,具备可以很好地区分正常振动信号、裂纹振动信号和结冰振动信号的性能,由于并不是提取的全部特征都有利于模型性能的

提升,一般情况下某些局部特征是区分不同振动信号的关键,因此,通过添加卷积注意力机制改变模型的兴趣点,可以使模型具备更强的特征提取能力,从而进一步提升整个模型的性能,最终更准

表 3 准确率仿真结果

Table 3 Simulation results of accuracy

	CBCNN	S-CNN	LSTM	CNN
验证集	0.990 0	0.880 6	0.689 6	0.596 5
测试集	0.901 3	0.816 5	0.668 7	0.536 5

确地实现风机叶片正常振动信号、裂纹振动信号和结冰振动信号的区分。

4 结 论

(1)首先将传统的单一特征选择方法与群智能算法相结合提出了R-BSO算法,该算法通过使用Ridge regression算法过滤掉冗余特征,降低特征集的整体维度,然后利用BSO算法筛选出最优特征子集;再选取随机森林、XGBoost和极度随机树3种在本文所使用的数据集上表现较好的学习器,利用软投票机制对上述3种模型两两进行集成,将得到的3个集成后的强学习器作为Stacking策略的基学习器,将逻辑回归作为元学习器,构建分类模型;最后将由R-BSO算法提取出的最佳特征组合输入基于Stacking策略的分类模型中得出分类结果,完成叶片健康监测RBVS算法的构建。

(2)经过实验验证,本文提出的R-BSO算法优于其他对比算法,可以更好地特筛选出最佳特征组合;然后将本文提出的RBVS算法与其他算法进行实验对比,证明了RBVS算法的评价指标均高于其他模型,在检测风机叶片故障信号上具有较好的性能。

(3)利用箱线图对正常振动信号、裂纹振动信号和结冰振动信号的简单特征进行分析,可以得出利用简单特征构建的故障诊断算法难以区分正常振动信号、裂纹振动信号和结冰振动信号3类信号的结论。因此,本文采用神经网络从信号中提取复杂特征,再利用分类器实现对以上3类信号的分类,并提出了一种基于卷积注意力机制的卷积神经网络叶片故障诊断算法CBCNN。通过与其他算法进行实验验证对比分析,证明了本文所提出的CBCNN算法可以更准确地实现风机叶片正常振动信号、裂纹振动信号和结冰振动信号的分类。

参考文献:

[1] Anindya G, Sundaresan Mannur J, Schulz Mark J, et al. Structural health monitoring techniques for wind turbine blades[J]. Journal of Wind Engineering and In-

dustrial Aerodynamics, 2000, 85(3): 309-324.

- [2] Mayes R L. An experimental algorithm for detecting damage applied to the I-40 bridge over the Rio-grande [C] //Smart Systems for Bridges, Structures, and Highways Conference on Smart Structures and Materials, Nashville, Tennessee, 1995: 219-225.
- [3] Dervilis N, Choi M, Taylor S G, et al. On damage diagnosis for a wind turbine blade using pattern recognition[J]. Journal of Sound and Vibration, 2014, 333(6): 1833-1850.
- [4] Sohn H, Worden K, Farrar C R. Novelty detection under changing environmental conditions[C] //Smart Systems for Bridges, Structures, and Highways Conference on Smart Structures and Materials, Newport Beach, USA, 2001: 108-118.
- [5] Scholz M, Vigario R. Nonlinear PCA: a new hierarchical approach[C] //The 10th European Symposium on Artificial Neural Networks, Bruges, Belgium, 2002:439-444.
- [6] Wang M H, Lu S D, Hsieh C C, et al. Fault detection of wind turbine blades using multi-channel CNN[J]. Sustainability (Switzerland), 2022, 14(3): No. 1781.
- [7] 宋秉霏. 小样本(医疗)数据的群智能特征选择算法研究[D]. 长春: 吉林大学通信工程学院, 2023.
- Song Jian-fei. Research on swarm intelligence feature selection algorithm for small sample (medical) data [D]. Changchun: College of Communication Engineering, Jilin University, 2023.
- [8] Jia H M, Li J D, Song W L, et al. Spotted hyena optimization algorithm with simulated annealing for feature selection[J]. IEEE Access, 2019, 7: 71943-71962.
- [9] Ou Y W, Tatsis K E. Vibration-based monitoring of a small-scale wind turbine blade under varying climate conditions. part I : an experimental benchmark [J]. Structural Control & Health Monitoring, 2021, 28(6): No. 2660.
- [10] Philipp G, Lukas L. Non-uniqueness theory in sampled STFT phase retrieval[J]. SIAM Journal on Mathematical Analysis, 2023, 55(5): 4695-4726.
- [11] Gai J X, Zhang L H, Wei Z H. Spectrum sensing based on STFT-ImpResNet for cognitive radio[J]. Electronics, 2022, 11(15): No. 2437.
- [12] 姚欣宜. 地面运动目标振动感知与识别方法研究[D]. 长春: 吉林大学通信工程学院, 2022.
- Yao Xin-yi. Research on moving ground-target perception and recognition method based on vibration [D]. Changchun: College of Communication Engi-

- neering, Jilin University, 2022.
- [13] 李婷, 付德义, 薛扬. 基于AE与STFT的变桨轴承裂纹诊断研究[J]. 振动、测试与诊断, 2021, 41(2): 299-303.
- Li Ting, Fu De-yi, Xue Yang. Research on crack diagnosis of pitch bearing based on AE and STFT[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 42(2): 299-303.
- [14] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]// Advances in Neural Information Processing Systems, Lake Tahoe, USA, 2012: 1097-1105.
- [15] Hubel D H, Wiesel T N. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex[J]. The Journal of Physiology, 1962, 160(1): 106-154.
- [16] Zhou Z H, Wu J, Tang W. Ensembling neural networks: many could be better than all[J]. Artificial Intelligence, 2002, 137(1-2): 239-263.
- [17] Vinay M B, Rekha K S. A model of saliency-based visual attention for rapid scene analysis[J]. International Journal of Recent Technology and Engineering, 2019, 7(6): 412-415.
- [18] 冀泽宇. 分布式轻量化非侵入式电力负荷监测方法研究[D]. 长春: 吉林大学通信工程学院, 2023.
- Ji Ze-yu. Research on distributed lightweight non-intrusive power load monitoring method[D]. Changchun: College of Communication Engineering, Jilin University, 2023.
- [19] 高广尚. 深度学习推荐模型中的注意力机制研究综述[J]. 计算机工程与应用, 2022, 58(9): 9-18.
- Gao Guang-shang. Survey on attention mechanisms in deep learning recommendation models[J]. Computer Engineering and Applications, 2022, 58(9): 9-18.
- [20] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [21] Sanghyun W, Jongchan P, Joon-young L, et al. CBAM: convolutional block attention module[J]. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2018, 11211: 3-19.
- [22] 王涛. 基于随机森林的机载设备异常振动故障检测方法[J]. 电子设计工程, 2023, 31(8): 119-122, 127.
- Wang Tao. Abnormal vibration fault detection method of airborne equipment based on random forest[J]. Electronic Design Engineering, 2023, 31(8): 119-122, 127.
- [23] 马康原, 李忠虎, 王金明, 等. 基于XGBoost模型的风电机组故障检测[J]. 内蒙古科技大学学报, 2023(4): 349-353.
- Ma Kang-yuan, Li Zhong-hu, Wang Jin-ming, et al. Wind turbine fault detection based on XGBoost model[J]. Journal of Inner Mongolia University of Science and Technology, 2023(4): 349-353.
- [24] 陈宇韬, 唐明珠, 吴华伟, 等. 基于极端随机森林的大型风电机组发电机故障检测[J]. 湖南电力, 2019, 39(6): 45-51.
- Chen Yu-tao, Tang Ming-zhu, Wu Hua-wei, et al. Fault detection based on extreme random forest for large wind turbine generators[J]. Hunan Electric Power, 2019, 39(6): 45-51.
- [25] 梁川. 基于特征提取和随机森林的风机故障诊断[J]. 科学技术创新, 2020(26): 55-58.
- Liang Chuan. Wind turbine fault diagnosis based on feature extraction and random forest[J]. Scientific and Technological Innovation, 2020(26): 55-58.
- [26] 张好雨. 基于SCADA数据的风机叶片覆冰故障检测与预测[D]. 北京: 北京交通大学机械工程学院, 2022.
- Zhang Hao-yu. Detection and prediction of wind turbine blade icing fault based on SCADA data[D]. Beijing: College of Mechanical Engineering, Beijing Jiaotong University, 2022.
- [27] 杨亚男. 基于SCADA数据的风机叶片故障诊断系统研究[D]. 北京: 华北电力大学控制与计算机工程学院, 2020.
- Yang Ya-nan. Research on fan blade fault diagnosis system based on SCADA data[D]. Beijing: College of Control and Computer Engineering, North China Electric Power University, 2020.
- [28] 刘天奇, 贾明峰, 赵薇. 基于振动信号的风机叶片故障检测[J]. 电力设备管理, 2023(20): 90-92.
- Liu Tian-qi, Jia Ming-feng, Zhao Wei. Vibration signal-based fault detection of wind turbine blades[J]. Power equipment management, 2023(20): 90-92.
- [29] 于嵩浩. 风力发电机组叶片健康智能声学监测系统[D]. 北京: 北京邮电大学自动化学院, 2020.
- Yu Song-hao. Intelligent acoustic monitoring system for wind turbine blade health[D]. Beijing: School of Automation, Beijing University of Posts and Telecommunications, 2020.