

DOI: 10.19650/j.cnki.cjsi.J2312297

# 基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断研究\*

吕游<sup>1</sup>, 封烁<sup>2</sup>, 郑茜<sup>2</sup>, 邓丹<sup>2</sup>, 刘吉臻<sup>2</sup>

(1. 华北电力大学新能源电力系统全国重点实验室 北京 102206; 2. 华北电力大学控制与计算机工程学院 北京 102206)

**摘要:**针对海上风电场和高海拔地区风机机组的叶片覆冰故障模型精度低、建模速度慢等问题,提出一种基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断方法。首先,整合监控和数据采集系统的记录数据与风机覆冰情况进行预处理,建立训练数据集;其次,基于改进后的 LeNet5like 网络构建覆冰故障诊断模型,提取数据集中多变量间的相关性特征信息;然后,经网络参数微调迁移学习对模型进行训练,实现对其他风机覆冰故障诊断模型的快速建立;最后,经实验验证,该模型覆冰故障诊断准确率为 98.90%,较无迁移模块网络训练时间缩短 28 s,提升约 15.91%,验证了基于 LeNet5like 的迁移学习风电机组叶片覆冰故障诊断方法的精确性和快速性。

**关键词:**故障诊断;叶片覆冰;迁移学习;LeNet5like 网络;SCADA 数据

**中图分类号:** TH17 TM315 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Research on fault diagnosis of wind turbine icing characteristics based on LeNet5like transfer learning

Lyu You<sup>1</sup>, Feng Shuo<sup>2</sup>, Zheng Xi<sup>2</sup>, Deng Dan<sup>2</sup>, Liu Jizhen<sup>2</sup>

(1. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources, North China Electric Power University, Beijing 102206, China; 2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

**Abstract:** A fault diagnosis of wind turbine icing characteristics based on LeNet5like transfer learning method is proposed, to address the problems of low accuracy and slow modelling speed of icing characteristics fault models, which wind turbine units are in offshore wind farms and high altitude areas. Firstly, the recorded data from the SCADA system and the wind turbine icing situation are pre-processed to build a training dataset; secondly, the icing fault diagnosis model is constructed based on the improved LeNet5like network to extract the correlation feature information between multiple variables in the dataset; then, the model is trained by the transfer learning fine-tuning to achieve the rapid establishment of ice-cover fault diagnosis models for other wind turbines; finally, the model is experimentally validated to have an icing fault diagnosis accuracy of 98.90%, a 28 s reduction in training time and an improvement of about 15.91% over the transfer module-free network, verifying the accuracy and speed of the LeNet5like based transfer learning wind turbine blade ice-cover fault diagnosis method.

**Keywords:** fault diagnosis; blade icing; transfer learning; LeNet5like networks; SCADA data

## 0 引言

随着我国“碳达峰、碳中和”目标的提出以及能源转型战略的持续推进<sup>[1-3]</sup>,以光伏和风电为主体的新能源不

断发展,装机容量逐年上升。但在海上、高山地区建设的大型风电机组所处环境恶劣,设备故障问题频发。其中,风机桨叶覆冰是主要故障之一,严重时将发生叶片断裂、抛冰伤人等一系列危害<sup>[4-6]</sup>。

目前,国内外针对风电机组叶片覆冰故障的诊断研

究方法主要分为两大类:基于覆冰机理分析方法和数据驱动方法<sup>[7]</sup>。传统覆冰机理分析法主要通过传感器和结冰内部机制构建覆冰数学模型进行覆冰诊断<sup>[8]</sup>。例如,文献[9]针对信号个别区间弱特征,构建各故障类别的奇异值向量矩阵进行诊断,但该方法诊断精度不高,计算能力差、计算速度较慢;文献[10]针对风机桨叶覆冰进行了数值仿真模拟与实际覆冰实验,得到了不同外在环境下桨叶表面覆冰的相关模型和覆冰形态,但传感器造价和维护费用较高,过度依赖经验建立模型,普适性较差。

随着监控和数据采集(supervisory control and data acquisition, SCADA)系统在风电场中广泛应用,大量包含异常运行状态的数据变得易于获取,许多通过神经网络使用 SCADA 历史数据构建风机模型的诊断方法被提出<sup>[11]</sup>。例如,文献[12]提出一种基于机器学习的风机桨叶覆冰检测模型,采用决策树、支持向量机和 K 近邻等传统机器学习方法构建分类模型;文献[13]提出了一套使用循环神经网络构建的深度学习模型,并加入了结冰风险投票机制,实现了对风机的覆冰故障检测,但忽视了不同风机的特征分布差异,导致在不同风机测试集上泛化能力不足,重新训练模型耗时过长,难以构建多风机检测模型。

从上述研究可知,传统的风机桨叶覆冰故障诊断方法主要存在两个问题:(1)为建立精确覆冰数学模型需安装多个传感器,这将增添额外的生产和维护成本;(2)实际场景中,不同风机监测数据差异性较大,这导致即使是通过同型号风机数据训练得到的模型,也很难在其他风机的数据上取得可靠的诊断结果,所建立模型难以拓展到多风机场景,缺乏泛化性。

近年来,深度学习发展迅速,其中迁移学习(transfer learning)在处理异质性数据、提高模型泛化能力方面效果显著<sup>[14]</sup>。迁移学习可以把已训练好的模型参数迁移到新的模型来帮助新模型训练,从而加快并优化模型的学习效率,提升模型的泛化能力。文献[15]基于长短期记忆网络(long short-term memory, LSTM)构建时间相关性的风机结冰诊断模型,采用深度代价敏感方式降低数据不平衡对模型的影响,使用对抗迁移学习提高模型的泛化性。文献[16]通过模态特性固有频率的变化来预测累积的覆冰位置和质量,应用深度神经网络迁移学习来检测冰质量分布;文献[17]使用不同条件下风机的 RGB 图像,和 MobileNet、VGG-19 和 Xception 的迁移学习模型输出覆冰预测结果。但上述方法建立的迁移学习模型,其网络计算速度较慢,模型建立时间较长,图像数据获取与处理难度较大,难以建立多风机覆冰模型。

传统 LeNet-5 神经网络层数较浅,在使用 SCADA 数

据训练过程中拟合程度较低。上述迁移学习方法虽然比传统风机桨叶覆冰故障诊断方法取得了泛化性的优势,但仍有进一步提升空间。为此,本文提出了基于 LeNet5like 的迁移学习风机桨叶覆冰故障诊断方法,采用易于处理且获取容易的 SCADA 数据集作为神经网络的训练输入;针对数据集低频采样、样本小的特点,对传统浅层 LeNet-5 神经网络进行改进,使其加快网络运算速度,提高目标故障诊断精度,增加模型的泛用性;通过网络参数微调迁移学习方式,可以在已有风机模型基础上更快速地建立多风机诊断模型,提升对目标风机特征迁移的精确度,适用于多风机桨叶覆冰故障诊断。

本文通过在传统 LeNet-5 网络结构基础上进行改进,增添网络层个数与种类,更换激活函数并微调网络各层参数,作为故障诊断的模型框架,并加入迁移学习模块,形成 LeNet5like 网络;通过对 W1 风机学习故障特征进行网络模型的预训练,使用网络参数微调方式快速建立 W2 风机故障诊断模型。经实际风力发电 SCADA 数据集算例分析,结果表明,相较传统机器学习方法,本文提出的方法准确率高达 98.90%,较传统 LeNet-5 网络训练精度提高约 2%,相较未调用迁移学习模块的训练时间缩短 28 s,提升约 15.91%,并通过齿轮箱数据集验证了网络对多目标分类的精确性;文献[18]通过将其他数据集的数据映射到不足的目标数据集上来扩展不足的数据,其监测方法能够准确地检测出异常行为;文献[19]在相同时频特征提取方式下,制作数量不同的数据集,验证了扩充数据集可以提高分类准确率的事实。故本文对 W1 风机数据集扩充分割,通过训练结果验证了迁移学习应用于多台风机的模型建立时同样具有准确性和快速性优势。该方法提高了网络模型对故障特征的提取能力,加强了模型的泛化性,在保证快速性的同时提高模型的准确性,能够有效地实现风机桨叶覆冰的快速准确诊断。

## 1 LeNet-5 卷积神经网络理论

### 1.1 LeNet-5 卷积神经网络结构

卷积神经网络(convolutional neural network, CNN)是一种带有卷积结构的前馈多层网络,是深度学习领域的经典方法,在处理复杂多特征模型时具有很高的准确率。卷积神经网络的基本组成有:输入层、卷积层、池化层、全连接层和输出层,具体结构如图 1 所示<sup>[20]</sup>。

传统的 LeNet-5 神经网络是一种基于梯度学习的 CNN 结构,最初应用于手写体数字字符识别。LeNet-5 网络结构共有 7 层,具体包含 3 个卷积层,2 个池化层,2 个全连接层。

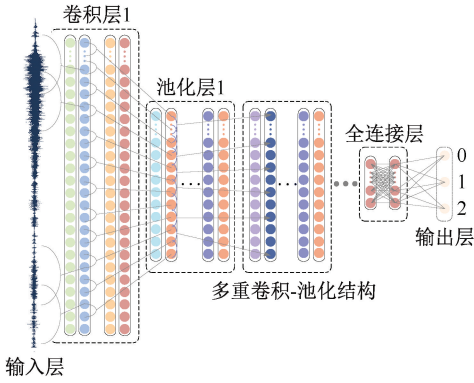


图1 一维卷积神经网络结构图

Fig. 1 Architecture of 1D-CNN

## 1.2 改进的 LeNet5like 网络结构

传统的 LeNet-5 网络结构较为简单,网络层种类单一,参数运算量较大,泛化性不强,且所得模型拟合程度不足,诊断结果准确率不高。本文在传统的 LeNet-5 网络基础上进行了调整与改进<sup>[21]</sup>,对网络层的种类与个数进行了调整,添加三个批归一化层、一个池化层<sup>[22]</sup>和一个失活层,减少每层神经网络的运算所需参数,更换了提取能力更强的网络函数,缩小了运算所需数据规模,提高了泛化性,形成了新的 LeNet5like 网络。

(1) 调整卷积核:将卷积核的大小从  $8 \times 8$  放缩至  $4 \times 8$ ,同时每层卷积核个数调整为 16。放缩大小能加快运算速度,增添个数可以实现对特征的深度提取。

样本数据训练过程数学描述为<sup>[23-24]</sup>:

$$y_i^{l+1}(j) = w_i^l \cdot x^l(j) + b_i^l, \quad l = 1, 2, 3 \quad (1)$$

$$z_i^{l+1}(j) = f[y_i^{l+1}(j)] \quad (2)$$

$$s_i(l) = \text{MaxPool}(z_i^l) \quad (3)$$

$$z_i(r) = f\left[\sum_{i=1}^n u_i^{r-1} \omega_i(r) + b_i(r)\right], \quad r = 1, 2 \quad (4)$$

式中:  $w_i^l$  为第  $i$  个滤波核在  $l$  层的权重;  $b_i^l$  为第  $i$  个滤波核在  $l$  层的偏置;  $x^l(j)$  为第  $l$  层第  $j$  个神经元的输入;  $y_i^{l+1}(j)$  为第  $j$  个神经元在  $l+1$  层的输入,即  $l$  的输出。

符号  $\cdot$  表示内核与该局部区域的点积运算;  $\text{MaxPool}(\cdot)$  是最大池化运算;  $\omega_i(r)$  和  $b_i(r)$  分别为第  $r$  全连接层的第  $i$  个权重值以及偏置值;  $u_i^{r-1}$  为第  $r-1$  全连接层的第  $i$  个输出值,总计  $n$  个。

(2) 增加批归一化层与失活层:网络模型过拟合的原因通常是卷积层数的累加,而数据特征通过批归一化层可以降低特征感,提高泛化能力,增加网络训练速度,其数学描述为<sup>[25]</sup>:

$$\mu_B = \frac{1}{m} \sum_{p=1}^m x_p \quad (5)$$

$$\sigma_B^2 = \frac{1}{m} \sum_{p=1}^m (x_p - \mu_B)^2 \quad (6)$$

$$\hat{x}_p = \frac{x_p - \mu_B}{\sqrt{\sigma_B^2 + \sigma}} \quad (7)$$

$$y_p = \gamma \hat{x}_p + \beta \quad (8)$$

式中:  $x_p$  为批归一化层输入的第  $p$  个元素,  $\mu_B$  是批处理数据均值,  $\sigma_B^2$  是批处理数据方差,经  $\hat{x}_p$  规范化和  $y_p$  尺度偏移后得到参数  $\gamma, \beta$ 。最终得到批归一化计算式(9):

$$x^* = \frac{\gamma(x - \mu)}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (9)$$

而失活层可以随机消除部分特征值,每次迭代时令部分神经元“失活”,避免网络过拟合,并使测试集的表现优于训练集<sup>[26]</sup>。本文采用交叉法验证失活层参数值设定为 0.2。

(3) 更换各层网络函数:本文卷积层的激活函数采用 ReLU<sup>[27]</sup> 替代 Sigmoid,以解决反向传播过程中易发生的梯度消失问题,并加快收敛速度。将优化器的原先的随机梯度下降算法更改为自适应矩估计(adaptive moment estimation, Adam)算法<sup>[28-29]</sup>, Adam 算法使网络加快初始学习速度,自适应更新学习率。数学描述为:

$$\hat{v}_i = \frac{v_i}{1 - \beta_1'} \quad (10)$$

$$\hat{s} = \frac{s_i}{1 - \beta_2'} \quad (11)$$

$$g_i' = \frac{\eta \hat{v}_i}{\sqrt{\hat{s}_i + \epsilon}} \quad (12)$$

$$x_i = x_{i-1} - g_i' \quad (13)$$

式中:  $\eta$  是学习率,  $\epsilon$  是为了维持数值稳定性而添加的常数,常为  $10^{-8}$ 。  $g_i'$  用于迭代自变量。

选择交叉熵函数作为损失函数,因其能够更准确地拟合诊断模型,精确衡量预测值与真实值的差异。其数学描述为:

$$L = -[y \log \hat{y} + (1 - y) \log(1 - \hat{y})] \quad (14)$$

改进后的 LeNet5like 结构如图 2 所示。




图2 LeNet5like 网络结构

Fig. 2 Architecture of LeNet5like



## 2 基于迁移学习的网络模型

### 2.1 迁移学习理论

迁移学习可以把已训练好的模型参数迁移到新的模型来帮助新模型训练,从而加快并优化模型的学习效率,提升模型的泛化能力。在实际应用中,基于参数的迁移学习方法可以共享源域和目标域的参数,只需对神经网络进行调整控制就可以很好地适应目标域。迁移学习原理如下图 3 所示。




图 3 迁移学习原理示意图

Fig. 3 Schematic diagram of transfer learning principle

目前,迁移学习调整神经网络的方式主要分为两种:特征向量提取和网络参数微调,具体流程如图 4 所示。特征向量提取是指计算出预训练模型的卷积层对所有训练和测试数据的特征向量,将其用于训练适配新模型的全连接网络,保留大部分原网络层,其计算复杂度较大;网络参数微调是指冻结预训练模型的部分卷积层,训练剩余的卷积层和全连接层,该方式既利用到神经网络强大的泛化能力,又免去了设计复杂的模型以及耗时良久的训练,因而被普遍使用。




图 4 迁移学习主要方式

Fig. 4 Main approaches of transfer learning

### 2.2 网络参数微调流程

本文采取的是网络参数微调迁移学习方式,具体学习过程如下<sup>[30]</sup>:

1) 得到预训练网络:将 W1 数据集作为网络的输入

数据,对应的结果作为输出数据,对特征提取网络进行预训练。通过对 W1 的深度学习建模,提取对象在故障情况下共有的参数特征。

2) 构建网络参数优化目标函数:在优化网络参数时,首要目标是最小化目标的故障诊断误差:

$$\min \sum_x \|y_i - y_p\|^2 \quad (15)$$

式中:  $y_i$  为真实故障情况数字化表示,  $y_p$  为网络诊断故障情况数字化表示。

在确定 W1 数据后,要将 W1 与 W2 之间的表示发散最小化,保留卷积池化层中大部分参数不变,最小化预训练网络结构中已提取特征的特征变化,第二优化目标的数学形式为:

$$\min \sum \|C_k - C_{k-1}\|^2 \quad (16)$$

将两优化目标结合,得到用以微调网络结构参数的最终优化目标函数:

$$\min \sum \|y_i - y_p\|^2 + \min \sum \|C_k - C_{k-1}\|^2 \quad (17)$$

将该优化目标函数作为网络训练的附加目标函数,通过对特征提取层设定较小的学习率,以达到对预训练网络参数微调的效果,保持网络大部分参数不变,仅让顶层学习到针对不同工况下更专业的特征,最终构建 W2 对象故障诊断模型。

## 3 基于 LeNet5like 网络的迁移学习结构

基于 LeNet5like 网络的风电机组迁移学习结构图如下所示。

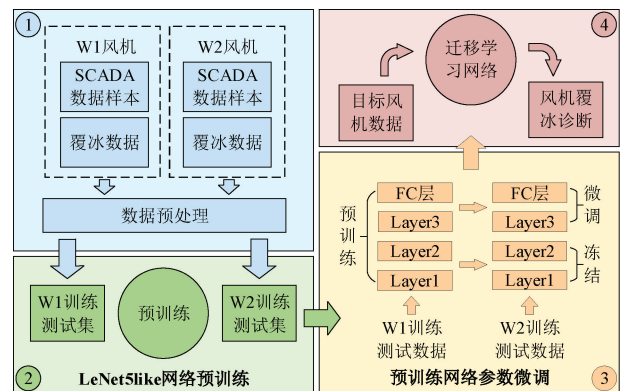


图 5 基于 LeNet5like 网络的风电机组迁移学习结构图

Fig. 5 Transfer learning architecture for wind turbines based on LeNet5like network

1) 整合 W1 风机和 W2 风机的一维 SCADA 数据与覆冰情况并进行数据预处理,主要包括:删除其中的缺失数据与错误数据,以故障数据为标准对正常数据进行降采样,避免数据集不平衡,将得到的 W1 和 W2 数据集进



行归一化处理并按比例划分为训练集与测试集;

2)将筛选后的 W1 特征数据输入 LeNet5like 网络进行特征提取,经卷积层式(1)、式(2)运算后,输入到批归一化层式(9)以降低特征感,提高泛化能力,后通过池化层式(3)操作进一步降维,最终输入到全连接层由式(4)输出网络训练结果。网络习得 W1 风机覆冰特征,W1 风机覆冰故障诊断模型建立;

3)基于预训练完成的特征提取 LeNet5like 网络,针对目标 W2 风机特征数据,经之前对 W1 风机覆冰诊断误差的数学模型确立,通过式(17)构建微调网络结构参数的最终优化目标函数,对步骤 2 建立的预训练网络进行网络参数微调,完成最终的迁移诊断网络;

4)将待诊断目标风机的 SCADA 数据输入到建立好的迁移诊断网络,得到待诊断目标覆冰情况,完成覆冰故障情况诊断。

## 4 算例分析

### 4.1 数据集介绍及多变量间相关性

本文所用一号数据集采集自某风电场两台三桨叶风力发电机(W1、W2)的 SCADA 系统数据,采集时间从 2020 年 11 月 1 日 20 时 20 分至 2021 年 1 月 1 日 21 时 38 分。SCADA 系统每 7 s 采样一次,共采集到 584 380 条一维多变量数据样本,每条数据样本含有包括时间维度在内的 27 维数据变量。具体检测变量数据说明见表 1。

表 1 SCADA 风机检测变量说明

Table 1 Description of SCADA turbines detection variables

序号	检测变量	序号	检测变量
1	风速	14	变桨电机 2 温度
2	发电机转速	15	变桨电机 3 温度
3	网侧有功功率	16	X 方向加速度
4	对风角	17	Y 方向加速度
5	25 s 平均对风角	18	环境温度
6	偏航位置	19	机舱温度
7	叶片 1 桨距角	20	叶片 1ng5 温度
8	叶片 2 桨距角	21	叶片 2ng5 温度
9	叶片 3 桨距角	22	叶片 3ng5 温度
10	叶片 1 速度	23	叶片 1ng5 直流电流
11	叶片 2 速度	24	叶片 2ng5 直流电流
12	叶片 3 速度	25	叶片 3ng5 直流电流
13	变桨电机 1 温度	26	机组状态标识

对所得数据进行首先预处理,具体包括:根据数据中覆冰和不覆冰的时间段,把原始数据分为正常数据即正样本,标签为正常,故障数据即负样本,标签为故障,无效数据即无标签的数据,错误数据为重复数据和异常值数据<sup>[15,31]</sup>;在构建训练集时,首先删除无标签的无效数据和错误数据,将进入故障状态后 10 min 到该状态改变前 10 min 数据提取出来,标记状态码值“1”,作为该故障类型的的数据。将进入正常状态后 30 min 到正常状态改变前 2 h 的数据提取出来,以排除故障状态前后的过渡数据,确保选定的是无故障数据,并加上标签“0”;为平衡训练集的正负样本数量,对正样本进行下采样,最终得到 W1 风机数据正常故障比例为 2:1,分别为 47 784 条和 23 892 条,合计 71 676 条。将数据集按照 3:1 划分为训练集和测试集并封装,便于后续网络训练。对 W2 风机 SCADA 数据进行同样预处理,得到 42 552 条数据。

为便于数据输入运算,所有数据经 Min-Max 归一化处理,与风机覆冰状态一同整合形成训练数据集。数据划分类型及状态信息见表 2。

表 2 一号数据集类型及状态统计表

Table 2 Statistical table of type and status of dataset No. 1

数据状态		W1	W2
降维前	正常	350 255	168 929
	故障	23 892	10 638
	无效	19 739	10 927
降维后	正常	47 784	35 664
	故障	23 892	11 888

因风机叶片覆冰故障种类单一,故本文使用另一组多故障类型数据集用以验证改进后 LeNet5like 网络的精确性。二号数据集为风电场二十七台风机齿轮箱数据集,时间从 2019 年 2 月 10 日 0 时 0 分至 2019 年 4 月 20 日 23 时 50 分,每十分钟记录一条数据。故障共有约 33 种,做相同数据预处理,并筛选出 7、22 号机其中故障样本数目较多的四种故障状态样本与正常运行样本整合,用以后续输入网络进行运算。

当风机叶片发生覆冰故障时,部分 SCADA 数据会表现出一定的共性<sup>[32]</sup>,但在不同风机上可能差异较大。本节对 W1 和 W2 的特征数据分布进行分析,佐证对于风机叶片覆冰诊断模型由单风机向风电机组转化的必要性,W1 和 W2 运行数据具有相同的特征空间和标签空间,体现在其部分运行参数拥有较高相似性,它们的部分特征数据变量相关性对比如下。

本文以风速、发电机转速、环境温度、网侧有功功率为例,说明不同风机不同状态下变量间的相关性。图 6

是 W1、W2 风机正常运行状态下风速-发电机转速散点图,图 7 是 W1、W2 风机叶片覆冰状态下风速-发电机转速散点图。图中可以看出,无论是正常运行还是覆冰故障状态下,W1 和 W2 的风速和发电机转速关系稳定,数值覆盖区域相同,数据分布稀疏程度相似,变量间相关性高。说明无论风机是否发生故障,W1 和 W2 的风速与发电机转速的数据相似性与关联性程度较高,以此训练得到的 W1 覆冰诊断模型在诊断 W2 时会起正向作用。

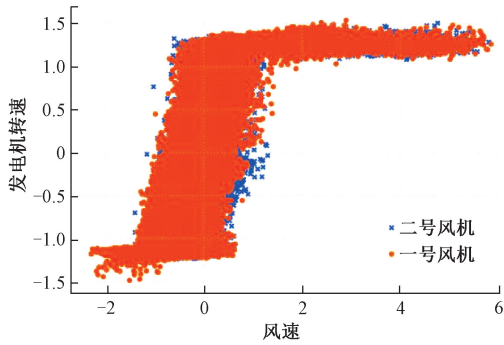


图 6 W1、W2 风速-发电机转速正常运行散点图  
Fig. 6 Scatter diagram of W1, W2 wind speed-generator speed during normal operation




图 7 W1、W2 风速-发电机转速覆冰状态散点图  
Fig. 7 Scatter diagram of W1, W2 wind speed-generator speed during icing

图 8 是 W1、W2 风机正常运行状态下环境温度-网侧有功功率散点图,可看出 W1、W2 的环境温度和网侧有功功率分布基本相似,但在温度较高时,W1 的网侧有功功率数据分布未全覆盖-0.5 到 1.5 区间。而当叶片发生覆冰故障时,W1 和 W2 的数据分布差异明显,覆冰时两台风机的网侧有功功率虽分布区块类似,但位于不同环境温度下,两风机数据几无相似重合区域,具体如图 9 所示。说明尽管在正常运行状态下,W1 和 W2 的环境温度和网侧有功功率数据相关性较高,但覆冰故障下差异极大,这将大大减小 W1 风机覆冰诊断模型的应用在 W2 风机上的准确性。




图 8 W1、W2 环境温度-网侧有功功率正常运行散点图  
Fig. 8 Scatter diagram of W1, W2 ambient temperature-power during normal operation

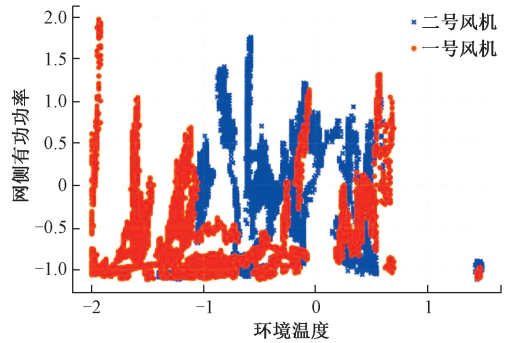


图 9 W1、W2 环境温度-网侧有功功率覆冰状态散点图  
Fig. 9 Scatter diagram of W1, W2 ambient temperature-power during icing

综上,不同观测变量在不同风机桨叶上发生覆冰故障或正常运行时,具有不同的相关性与不同的覆盖区域。因此本文使用 LeNet5like 网络处理原始数据,提取多变量间的相关性特征,通过迁移学习提取风电机组数据公共特征、学习单一风机特有特征,提高故障诊断模型精度。

#### 4.2 实验设置

实验所用计算机配置为 i5-9400 处理器,显卡为 NVIDIA GeForce GTX1050,内存 8 GB,使用 PyTorch 框架搭建训练平台,Python 3.7.0,torch 1.2.0,torchvision 0.4.0,初始学习率设置为 0.001,迭代次数设置为 30 次。本次训练在 Jupyter 平台启用 GPU 训练。

将 LeNet5like 网络各卷积层卷积核大小设置为 32,卷积核个数分别设置为 2、4、8、16,输入封装好的 W1 数据集,所得准确率、损失和用时如图 10、图 11 和表 3 所示。

由图表结果可知,随卷积核个数增加,准确率大幅度提升至 97.80%,损失降低到约 6.5%,相比 2 卷积核网络训练结果,16 卷积核网络的准确率提升约 10%,损失




图 10 不同卷积核个数测试准确率图

Fig. 10 Accuracy graph for different numbers of convolutional kernels




图 11 不同卷积核个数测试损失图

Fig. 11 Loss graph for different numbers of convolutional kernels

表 3 不同卷积核个数测试结果统计表

Table 3 Statistics of test results with different number of convolutional kernels

卷积核个数	最高准确率	最少损失	所用时间/s
16	0.97 807	0.06 490	42
8	0.94 146	0.15 329	39
4	0.91 551	0.22 429	39
2	0.88 816	0.26 920	37




图 12 不同卷积核大小测试准确率图

Fig. 12 Accuracy graph for different convolutional kernel sizes




图 13 不同卷积核大小测试损失图

Fig. 13 Loss graph for different convolutional kernel sizes

表 4 不同卷积核大小测试结果统计表

Table 4 Statistics of test results with different convolutional kernels sizes

卷积核大小	最高准确率	最少损失	所用时间/s
64	0.98 052	0.05 779	49
32	0.97 807	0.06 490	42
16	0.96 613	0.09 561	39
8	0.95 223	0.13 050	39

减少约 76%，时间增加约 13%。

将 LeNet5like 网络各卷积层卷积核个数设置为 16，卷积核大小分别设置为 8、16、32、64，输入封装好的 W1 数据集，所得准确率、损失和用时如图 12、图 13 和表 4 所示。

由图表结果可知，随卷积核大小增加，准确率和损失进一步改善，但卷积核大小 64 与 32 相对比，准确率提高仅为 0.25%，损失减少约 10%，时间增加约 16.7%。相比卷积核大小翻倍、计算量大幅增加，准确率的提升极小。

基于以上结果综合考量，本文 LeNet5like 网络卷积层参数选择卷积核个数为 16，卷积核大小为 32，在保证高准确率的前提下，保证尽可能快的用时。

为了全面合理的评价模型识别精度，本节采取基于混淆矩阵多指标评价体系<sup>[24]</sup>，主要定义了准确率 (Precision)、查全率 (Recall) 与综合指标 (F1) 来定量评价风机覆冰故障诊断的性能，其计算方式如下：

$$Precision = \frac{TP}{TP + FP} \tag{21}$$

$$Recall = \frac{TP}{TP + FN} \tag{22}$$

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall} \tag{23}$$

式中：TP (True Positive) 为待诊断风机覆冰情况判定成正常且分类模型预测为正常；FN (False Negative) 为待诊断



情况判定成正常但分类模型预测为覆冰; FP (False Positive) 为待诊断情况判定成覆冰但分类模型预测为正常; TN (True Negative) 为待诊断情况判定成覆冰且分类模型预测为覆冰。

以上三种测评标准的取值范围均为  $[0, 1]$ , 取值越接近 1, 说明模型在此方面的效果越好。

### 4.3 实验结果与分析

#### 1) W1 风机诊断结果

为评估本文所提 LeNet5like 网络诊断模型的有效性, 利用 W1 风机的数据集对模型进行训练和测试。图 14 和图 15 显示在故障诊断模型的训练和测试阶段基于 LeNet5like 网络获得的精度曲线和损失曲线。




图 14 W1 风机数据训练测试准确率图

Fig. 14 Accuracy graph for training and test on W1




图 15 W1 风机数据训练测试损失图

Fig. 15 Test loss graph for training and test on W1

如图 14 所示, 经过 30 次迭代, 故障分类精度快速收敛趋于稳定, 在 98.4% 以上, 最高准确率为 99.26%。如图 15 所示, 损失函数值在前 10 次迭代中迅速减小, 然后缓慢减小并接近于 0, 在训练 20 次后达到收敛状态, 测试集损失基本维持在 0.05 以下, 最少误差损失为 0.022 6。从图 14 和图 15 可以看出, 模型训练结果接近模型测试结果, 且没有欠拟合或过拟合, 证明了所提出的故障诊断模型的有效性。本次训练时长为 1 m 51 s。

为进一步验证该算法的模型精确性, 本文进行如下对比: 使用传统机器学习经典方法 K 近邻、决策树、随机森林和传统 LeNet-5 网络进行诊断, 以查全率、查准率、F1 系数和混淆矩阵作为评价标准。

根据实验结果可知, 相较各传统机器学习算法和传统 LeNet-5 网络, 本文方法的查全率、查准率和 F1 参数均取得最高指标, 平均提升率约为 3.27%、4.32% 和 3.93%, 在精度高于 90% 时, 取得显著提升。证明了 LeNet5like 网络更好地提取了变量间相关性特征, 显著提高了精确性。评价标准对比如表 5 所示。

表 5 W1 风机数据实验结果对比表

Table 5 Table of experimental comparison results for W1

方法	查全率/%	查准率/%	F1/%
KNN	94.74	99.41	97.02
决策树	94.04	91.91	92.64
随机森林	97.54	92.60	95.00
LeNet-5	97.40	97.24	97.27
LeNet5like	99.20	99.61	99.41

混淆矩阵中对角线上的方块颜色越深, 对应类别的诊断准确度越高, 其余方块颜色越浅越好。各方法的诊断结果混淆矩阵如图 16 所示。

可以看出, LeNet5like 网络较其他传统机器学习方法达到较高的诊断精度, 且对比原传统 LeNet-5 网络有约 2% 的精度提升。对比实验证实了本故障诊断模型的精确性。

若将经 W1 训练后的模型用以测试 W2 风机数据, 所得最高准确率和最少损失分别为 93.38% 和 0.598 7。从数据中可得该诊断结果损失严重, 并不适用于诊断。

若用 LeNet5like 网络对 W2 数据进行训练, 得到 W2 风机数据训练测试准确率图 17 和损失图 18 如下所示。

训练时长为 2 m 56 s, 最少损失为 0.009 2, 最高准确率为 99.77%。

#### 2) 齿轮箱数据集诊断结果

使用多故障类型数据集辅助评估本文所提 LeNet5like 网络诊断模型的有效性。对齿轮箱数据集的 7、22 号风机齿轮箱数据进行处理后得到各 25059、26251 条数据, 各四种故障类型, 具体见表 6。

将 7 号数据集输入 LeNet5like 网络进行训练, 准确率和损失结果如图 19、图 20 所示。

可以看出, 在面对多目标分类时, LeNet5like 网络同样具有较高的准确率与快速收敛特性, 但在精度方面不如单一故障诊断, 最少损失为 0.088 9, 最高准确率为 99.43%。




图 16 各算法对 W1 数据诊断结果混淆矩阵

Fig. 16 Confusion matrix of diagnostic results for W1 data by various algorithms




图 17 W2 风机数据训练测试准确率图

Fig. 17 Accuracy graph for training and test on W2




图 18 W2 风机数据训练测试损失图

Fig. 18 Test loss graph for training and test on W2

表 6 齿轮箱数据集故障表

Table 6 Table of gearbox data set fault

齿轮箱	故障类型	样本数
7	正常	14 323
	机舱急停按钮触发	1 785
	齿轮箱漏油	2 451
	风速低于限值	3 000
	变桨桨叶 1 不同步	3 500
22	正常	17 246
	安全继电器触发	1 245
	齿轮箱漏油	3 470
	桨叶小于设定值时发电机转速(变流器) 1 小于设定值	1 876
	变流器网侧开关无法闭合	2 414




图 19 7 号齿轮箱数据训练测试准确率图

Fig. 19 Accuracy graph for training and test on gear box 7

同样与传统机器学习经典方法和 LeNet-5 网络诊断结果进行横向对比,所得混淆矩阵图如图 21 所示。KNN




图 20 7号齿轮箱数据训练测试损失图

Fig. 20 Test loss graph for training and test on gearbox 7

方法和传统 LeNet-5 在面对多目标分类时效果较好,正确诊断率较高,但决策树结果混乱,目标故障诊断错误较多,而随机森林更是仅能诊断多数样本是否故障,缺乏对少量样本的关注。而本文提出的 LeNet5like 网络诊断结果较好,但在面对不平衡样本时同样易产生错误结果。

将 22 号数据集输入 LeNet5like 网络进行训练,准确率和损失结果如图 22、图 23 所示。

与 7 号齿轮箱数据集对比,22 号的诊断快速性并没有那么优秀,推测可能与数据样本量差异较大有关。在 30 轮次训练后,准确率为 99.12%,损失为 0.089 0。

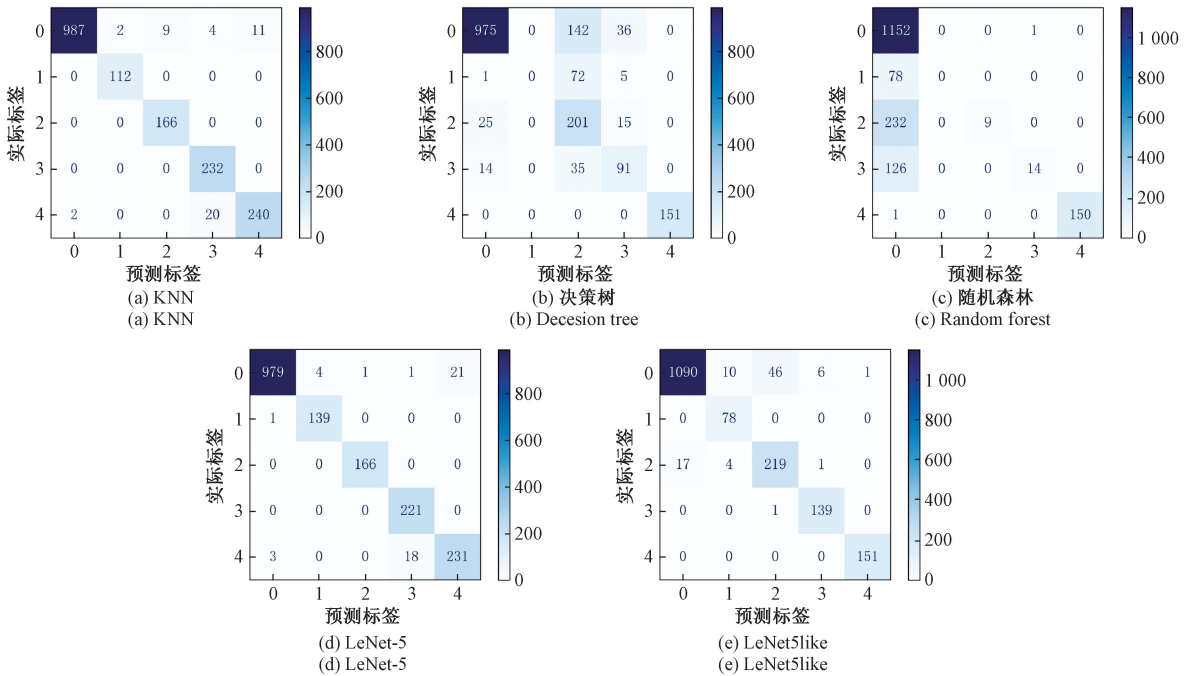


图 21 各算法对 7 号齿轮箱数据诊断结果混淆矩阵

Fig. 21 Confusion matrix of diagnostic results for gearbox 7 by various algorithms




图 22 22 号齿轮箱数据训练测试准确率图

Fig. 22 Accuracy graph for training and test on gearbox 22




图 23 22 号齿轮箱数据训练测试损失图

Fig. 23 Test loss graph for training and test on gearbox 7



将 22 号齿轮箱数据集应用于传统机器学习经典方法和 LeNet-5 网络, 所得结果混淆矩阵图如图 24 所示。结果可看出, 在面对多目标分类时, 传统机器学习

方法如随机森林、决策树具有缺陷, 诊断错误率较高, 但 KNN 算法和 LeNet5like 网络具有多目标正确分类的能力。

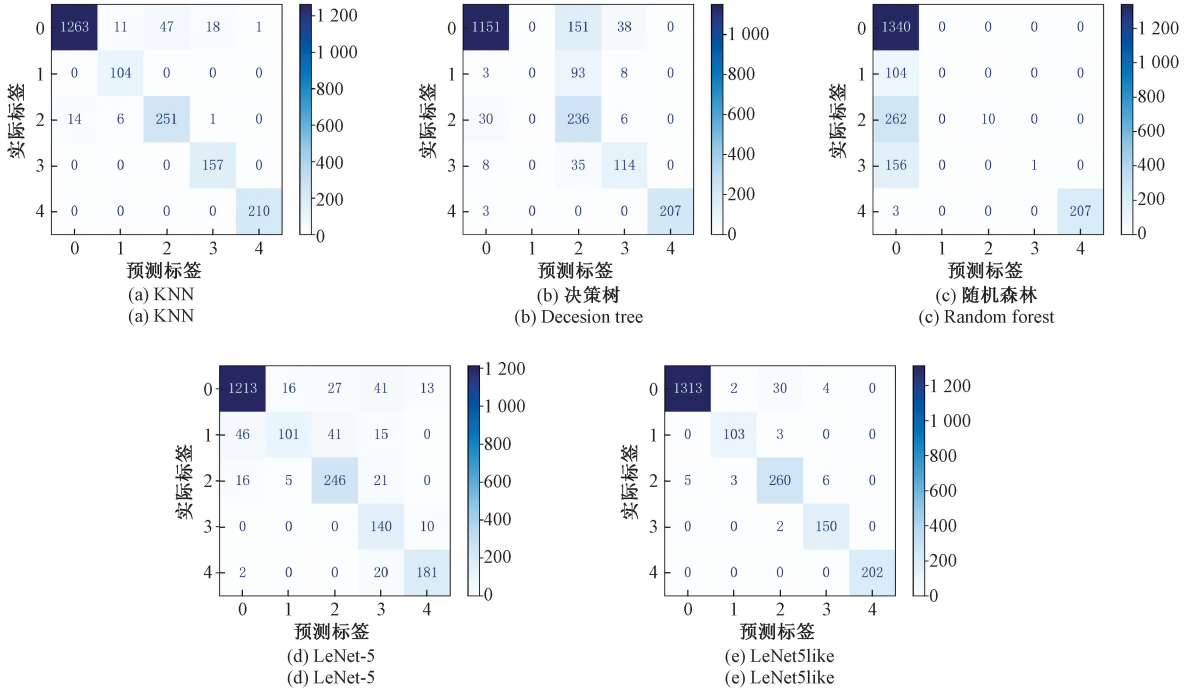


图 24 各算法对 22 号齿轮箱数据诊断结果混淆矩阵

Fig. 24 Confusion matrix of diagnostic results for gearbox 22 by various algorithms

### 3) W2 风机迁移学习诊断结果

将前文 1) 中训练得到的 W1 风机覆冰故障诊断模型作为预训练网络, 用以对 W2 风机数据进行网络参数微调迁移学习故障诊断模型建立。

网络参数微调过程中, 只在训练时进行反向传播计算与 Adam 算法优化, 故同次训练和验证的损失一样。训练次数同样为 30 次, W2 风机数据迁移学习训练测试准确率和损失分别如图 25、26 所示。




图 25 W2 风机数据迁移学习训练测试准确率图

Fig. 25 Accuracy graph for training and test on W2 by transfer learning




图 26 W2 风机数据迁移学习训练测试损失

Fig. 26 Test loss graph for training and test on W2 by transfer learning

本次训练时长为 2 m 28 s, 最少损失为 0.068 9, 最高准确率为 98.90%。相较未调用迁移学习模块对 W2 数据进行训练, 迁移学习预训练网络的训练时间缩短了 28 s, 时间提升约为 15.91%, 同时准确率和损失与其结果相差不大。

同样, 将带有迁移学习模块的 LeNet5like 网络训练结果的参数指标与传统机器学习方法和传统 LeNet-5 网络进行对比, 参数对比如表 7 所示, LeNet5like 网络在三

个参数指标上较其他方法的平均提升率分别为 3.67%、3.86% 和 3.82%。

表 7 W2 风机数据实验结果对比表

Table 7 Table of experimental comparison results for W2

方法	查全率/%	查准率/%	F1/%
KNN	95.09	98.85	96.93
决策树	93.88	95.93	94.89
随机森林	98.25	91.52	94.76
LeNet-5	94.97	97.70	96.32
LeNet5like	99.22	99.86	99.54

混淆矩阵如图 27 所示。

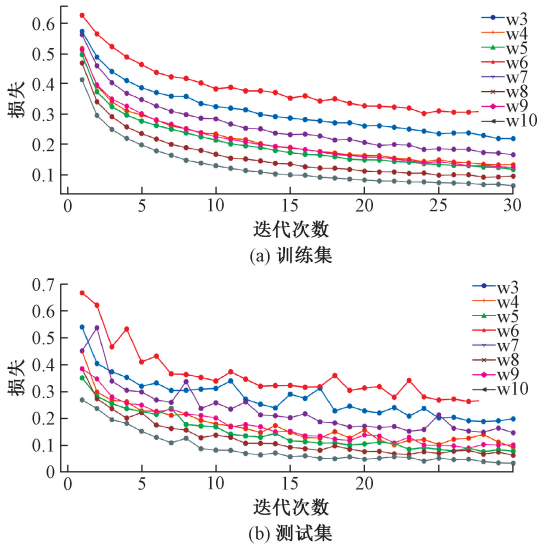


图 27 各算法对 W2 数据诊断结果混淆矩阵

Fig. 27 Confusion matrix of diagnostic results for W2 data by various algorithms

#### 4) 扩充风机数据迁移学习诊断结果

基于文献[18-19]的结果,为进一步验证网络效果,本文选择对 W1 数据集进行扩充。将处理后得到的 W1 数据集中的故障数据集进行上采样,打乱数据集重新分割,得到八组数据集,依次命名为 W3~W10,用以辅助验证网络的迁移学习效果。

首先输入到 LeNet5like 网络进行训练测试,结果如图 28、29 所示。

8 组数据在测试集上的表现均优于训练集,但大量样本数据的测试效果普遍优于小量样本数据,当样本数据量相差一个数量级时,准确率的结果相差约 9.91%,具体结果见表 8。




图 28 扩充风机数据训练集结果图

Fig. 28 Results plot for training set on expanded data




图 29 扩充风机数据测试集结果图

Fig. 29 Results plot for testing set on expanded data

如 3) 节一样,将 1) 节所得的 W1 故障诊断模型作为预训练网络用以训练测试 W3 至 W10 数据,所得结果如图 30 所示。

由结果可得,大部分数据集同样在第 15 次迭代训练后基本收敛,最终准确率在 97% 至 99% 之间。大部分低样本量数据迁移效果均优于原始网络测试结果,尤其是样本量最少的 W6 数据集,从 90.45% 跃升至 97.02%,而样本量最大的 W10 数据集的准确率反而从 99% 下降到 98.77%,可见过大的样本数据量可能造成模型的过拟合,使在测试集的表现稍逊于训练集的效果。

表8 扩充风机数据训练结果表

Table 8 Table of training results for expanded data

	样本数	训练集		测试集			迁移测试		
		准确率/%	损失	准确率/%	损失	时间/s	准确率/%	损失	时间/s
W3	3 762	91.40	0.219 1	930.17	0.186 8	19	97.00	0.127 4	12
W4	11 352	94.99	0.132 9	96.84	0.090 1	59	97.94	0.109 1	39
W5	15 000	95.74	0.117 5	97.71	0.073 7	77	98.24	0.099 2	48
W6	1 971	87.78	0.295 4	90.45	0.255 1	13	97.02	0.137 1	8
W7	7 701	93.49	0.165 9	94.71	0.144 7	44	97.69	0.113 9	26
W8	18 528	96.62	0.091 9	97.99	0.060 2	109	98.52	0.084 7	68
W9	10 368	950.24	0.124 0	96.93	0.087 1	61	98.52	0.095 9	34
W10	38 187	970.69	0.064 1	99.00	0.031 1	188	98.77	0.076 6	121




图30 扩充风机数据迁移学习测试集结果图

Fig. 30 Results plot for testing set on expanded data by transfer learning

在时间上,迁移学习的训练结果所需时间大幅度少于使用原始网络进行训练所需时间,降低幅度从33.90%至44.26%之间不等,样本数据量中等的W9数据集增速最快。

## 5 结 论

本文提出了一种基于LeNet5like的迁移学习风电机组叶片覆冰故障诊断方法。通过LeNet5like网络提取特征得到预训练网络,针对目标风机特征数据对预训练网络进行网络参数微调迁移学习,风电机组的覆冰故障诊断模型建立,并采用某风电场两台三桨叶风力发电机的SCADA系统数据集,和扩充分割后的风电数据集,以及

齿轮箱数据集进行模型训练与验证,得到的主要结论如下:

1) 本文改进的LeNet5like网络可以提取更多的故障特征信息并进行整合,获得更好的训练效果,未使用迁移学习时即达到优于其他传统机器学习方法的诊断效果,在各项参数指标均在90%以上的基础上,在精确率、召回率、F1系数方面分别取得约3.67%、3.86%和3.82%的提升,在多目标分类上同样取得了优于其他算法的结果。

2) 本文方法采用网络参数微调迁移学习方式,有效解决了用未训练网络训练模型花费时间较长的问题,相较未调用迁移学习模块进行训练的模型,准确率达98.90%,损失为0.0689,时间缩短了28s,时间提升约15.91%;对扩充数据集的结果表明,准确率和训练快速性的提升与样本量有关,但依据本文所提方法,准确率基本保证在97%以上,用时减少平均约37%,验证了本文所提基于迁移学习的LeNet5like网络在多台风机的模型建立时具有准确性和快速性的优势。

综上,本文提出的基于LeNet5like的迁移学习风电机组叶片覆冰故障诊断方法,在使用SCADA数据建立风电机组叶片覆冰故障诊断模型时,具有泛化性好、准确率高和建模速度快的优点。

基于当前研究成果,后续将在迁移学习前对数据进行更精细化的预处理,例如:数据的匹配筛选,数据分段,解决相似比较对象间长度不一的问题,就能避免人为筛选的主观性,可以提升迁移学习的正向效率,提高诊断结果的准确率并降低损失;基于诊断结果随样本数据量而波动,下一步网络改进应增加对小量样本的特征提取能力,或进一步平衡数据集。

## 参考文献

[1] 方立德. 关注流体能源与资源准确计量,助力碳达峰



- 与碳中和目标实现[J]. 仪器仪表学报, 2022, 43(1): 1.
- FANG L D. Focus on accurate measurement of fluid energy and resources for peak carbon and carbon neutral goals[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 1.
- [2] 辛保安, 单葆国, 李琼慧, 等. “双碳”目标下“能源三要素”再思考[J]. 中国电机工程学报, 2022, 42(9): 3117-3126.
- XIN B A, SHAN B G, LI Q H, et al. Rethinking of the “three elements of energy” toward carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2022, 42(9): 3117-3126.
- [3] HONG F, JI W M, PANG Y L, et al. A new energy state-based modeling and performance assessment method for primary frequency control of thermal power plants[J]. Energy, 2023, 276: 127594.
- [4] 杨大川. 叶片覆冰对风力机功率特性的影响[D]. 重庆: 重庆大学, 2019.
- YANG D C. Effect of blade icing on power characteristics of wind turbine[D]. Chongqing: Chongqing University, 2019.
- [5] BARKER A, TIMCO G, GRAVESEN H, et al. Ice loading on danish wind turbines: part 1: dynamic model tests[J]. Cold Regions Science and Technology, 2005, 41(1): 1-23.
- [6] PINAR-PÉREZ J M, GARCÍA MÁRQUEZ F P. Managing costs and review for icing problems [M]. Cham: Springer International Publishing, 2018: 97-109.
- [7] 李川, 伍依凡, 杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报, 2023, 44(8): 181-197.
- LI CH, WU Y F, YANG SH. Research progress of fault diagnostics driven by imbalanced data distribution[J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 181-197.
- [8] 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.
- GE CH, YAN J, LIU Y Q, et al. Review of key technologies for operation control and maintenance of offshore wind farm [J]. Proceedings of the CSEE, 2022, 42(12): 4278-4292.
- [9] LIU C, CHENG G, CHEN X, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. Sensors, 2018, 18(5).
- [10] 张毅. 小型风力发电机叶片覆冰的数值仿真及试验研究[D]. 重庆: 重庆大学, 2018.
- ZHANG Y. Numerical study and test of icing on small wind turbine blades [D]. Chongqing: Chongqing University, 2018.
- [11] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.
- [12] JIMÉNEZ A A, MRQUEZ FPG, MORALEDA V B, et al. Linear and nonlinear features and machine learning for wind turbine blade ice detection and diagnosis[J]. Renewable Energy, 2019, 132: 1034-1048.
- [13] 李铭璐. 基于深度学习的风机叶片覆冰故障检测方法研究[D]. 武汉: 华中科技大学, 2019.
- LI M L. Study on failure detection methods of wind turbine icing event based on deep learning[D]. Wuhan: Huazhong University of Science & Technology, 2019.
- [14] 苗建国, 李茂银, 邓聪颖, 等. 非理想数据下基于仿真数据辅助迁移学习的滚动轴承故障诊断[J]. 仪器仪表学报, 2023, 44(4): 28-39.
- MIAO J G, LI M Y, DENG C Y, et al. Rolling bearing fault diagnosis for non-ideal dataset based on finite element simulation and transfer learning [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 28-39.
- [15] 刘曦檬. 基于 SCADA 数据的风机叶片结冰诊断研究[D]. 昆明: 昆明理工大学, 2021.
- LIU X M. Diagnostic study of wind turbine blade icing based on SCADA data [D]. Kunming: Kunming University of Science and Technology, 2021.
- [16] INHO J, HAESEONG C, CHANKYU S, et al. Sustainable data-driven framework via transfer learning for icing-detection of high aspect ratio blades [J]. Cold

- Regions Science and Technology, 2022, 201: 103606.
- [17] NIETO, MTA (ALVELA N, MARIA T), GELBHARDT, et al. Detecting ice on wind turbine rotor blades: Towards deep transfer learning for image data [C]. 6th International Conference on System-Integrated Intelligence, ITALY, 2022.
- [18] JING H, ZHAO C H. A data expansion based piece wise regression strategy for incrementally monitoring the wind turbine with power curve [J]. Journal of Central South University, 2023, 30(5): 1601-1617.
- [19] 张蒙召. 基于半监督生成对抗网络的变电站边坡隐患识别方法研究[D]. 华北电力大学(北京), 2023.  
ZHANG M ZH. Research on substation slope hidden danger identification method based on semi-supervised generation adversarial network [D]. Bei Jing: North China Electric Power University, 2023.
- [20] 徐卓飞, 李旭东, 张婵婵, 等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2022, 43(10): 241-251.  
XU ZH F, LI X D, ZHANG CH CH, et al. Fault diagnosis of rolling bearings with limited samples based on siamese network [J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 241-251.
- [21] 吴晨芳, 杨世锡, 黄海舟, 等. 一种基于改进的LeNet-5模型滚动轴承故障诊断方法研究[J]. 振动与冲击, 2021, 40(12): 55-61.  
WU CH F, YANG SH X, HUANG H ZH, et al. An improved fault diagnosis method of rolling bearings based on LeNet-5 [J]. Journal of vibration and shock, 2021, 40(12): 55-61.
- [22] 鲍光海, 林善银, 徐林森. 基于改进型卷积网络的汽车高度调节器缺陷检测方法[J]. 仪器仪表学报, 2020, 41(2): 157-165.  
BAO G H, LIN SH Y, XV L S. Defect detection method for automobile height regulator based on improved convolution network [J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 157-165.
- [23] 杨洁, 万安平, 王景霖, 等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J]. 中国电机工程学报, 2022, 42(13): 4933-4942.  
YANG J, WAN A P, WANG J L, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion [J]. Proceedings of the CSEE, 2022, 42(13): 4933-4942.
- [24] 王玉静, 吕海岩, 康守强, 等. 不同型号滚动轴承故障诊断方法[J]. 中国电机工程学报, 2021, 41(1): 267-276+416.  
WANG Y J, LYU H Y, KANG SH Q, et al. Fault diagnosis method for different types of rolling bearings [J]. Proceedings of the CSEE, 2021, 41(1): 267-276+416.
- [25] 李东东, 刘宇航, 赵阳, 等. 基于改进生成对抗网络的风机行星齿轮箱故障诊断方法[J]. 中国电机工程学报, 2021, 41(21): 7496-7507.  
LI D D, LIU Y H, ZHAO Y, et al. Fault diagnosis method of wind turbine planetary gearbox based on improved generative adversarial network [J]. Proceedings of the CSEE, 2021, 41(21): 7496-7507.
- [26] 符杨, 任子旭, 魏书荣, 等. 基于改进 LSTM-TCN 模型的海上风电超短期功率预测[J]. 中国电机工程学报, 2022, 42(12): 4292-4303.  
FU Y, REN Z X, WEI SH R, et al. Ultra-short-term power prediction of offshore wind power based on improved LSTM-TCN model [J]. Proceedings of the CSEE, 2022, 42(12): 4292-4303.
- [27] 陈超. 齐峰. 卷积神经网络的发展及其在计算机视觉领域中的应用综述[J]. 计算机科学, 2019, 46(3): 63-73.  
CHEN CH, QI F. Review on development of convolutional neural network and its application in computer vision [J]. Computer Science, 2019, 46(3): 63-73.
- [28] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版), 2018, 46(7): 122-127.  
YANG G C, YANG J, LI SH B, et al. Modified cnn algorithm based on dropout and ADAM optimizer [J]. J. Huazhong Univ. of Sci. & Tech. (Natural Science Edition), 2018, 46(7): 122-127.
- [29] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法[J]. 计算机工程与设计, 2018, 39(2): 441-445+462.

WANG G P, DUAN M, NIU CH Y. Stochastic gradient descent algorithm based on convolution neural network[J]. Computer Engineering and Design, 2018, 39(2): 441-445+462.

- [30] 魏泽涛, 刘友波, 沈晓东, 等. 基于样本数据迁移学习的贫资料地区小水电超短期出力建模及发电预测[J]. 中国电机工程学报, 2023, 43(7): 2652-2666.

WEI Z T, LIU Y B, SHEN X D, et al. Ultra-short-term power generation modeling and prediction for small hydropower in data-scarce areas based on sample data transfer learning[J]. Proceedings of the CSEE, 2023, 43(7): 2652-2666.

- [31] 王言国, 吕鹏远, 兰金江, 等. 基于对抗训练与 Transformer 的风力发电机故障分类方法[J/OL]. 计算机工程: 1-9[2024-01-23].

WANG Y G, LVU P Y, LAN J J, et al. Wind turbine Fault classification based on adversarial training and transformer[J/OL]. Computer Engineering: 1-9[2024-01-23].

- [32] XU J H, TAN W, LI T S. Predicting fan blade icing by using particle swarm optimization and support vector machine algorithm [J]. Computers and Electrical Engineering, 2020, 87, 106751.

## 作者简介



吕游(通信作者), 2009年和2014年于华北电力大学分别获得学士学位和博士学位, 现为华北电力大学副教授, 主要研究方向为能源系统建模、优化及设备状态监测方法。

E-mail: you.lv@ncepu.edu.cn。

**Lyu You** (Corresponding author) received his B. Sc. degree and Ph. D. degree both from North China Electric Power University (NCEPU) in 2009 and 2014, respectively. He is currently an associate professor at NCEPU. His main research interests include energy system modeling, optimization and equipment condition monitoring methods.



封烁, 2021年于华北电力大学获得学士学位, 现为华北电力大学硕士研究生, 主要研究方向为风电机组设备运行状态信息感知。

E-mail: 120212227207@ncepu.edu.cn

**Feng Shuo** received his B. Sc. degree from NCEPU in 2021. He is currently a master student at NCEPU. His main research interests include wind turbine equipment operation state information sensing.