

DOI: 10.19783/j.cnki.pspc.210919

基于深度特征融合网络的风电机组行星齿轮箱故障诊断方法

李东东, 赵阳, 赵耀, 蒋海涛

(上海电力大学电气工程学院, 上海 200090)

摘要: 行星齿轮箱是风电机组中的重要部件, 对风电机组的安全可靠运行具有重要意义。为此, 提出一种基于深度特征融合网络的行星齿轮箱故障诊断方法, 用于实现变速工况、样本不足和强噪声场景下的故障诊断。首先将原始信号扩展到多个特征域。其次利用多维堆栈稀疏自编码器提取各域特征。最后针对传统 Softmax 分类器对融合信息分类能力不足的问题, 提出基于竞争粒子群算法优化的回声状态网络进行特征融合并输出诊断结果。经多场景不同故障诊断方法对比实验, 所提方法在行星齿轮箱变速工况下分类效果良好, 并对训练样本的减少和外界噪声有很强的鲁棒性。

关键词: 行星齿轮箱; 故障诊断; 多场景; 深度学习; 堆栈稀疏自编码器; 回声状态网络; 深度特征融合网络

A fault diagnosis method for a wind turbine planetary gearbox based on a deep feature fusion network

LI Dongdong, ZHAO Yang, ZHAO Yao, JIANG Haitao

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The planetary gearbox is a critical part of a wind turbine. It is of great significance for safety and reliability. Therefore, a fault diagnosis method for a planetary gearbox based on a deep feature fusion network is proposed to operate under variable speed conditions, with limited numbers of samples and in strong noise scenarios. First, the original signal is expanded into multiple characteristic domains. Then a multi-dimensional stack sparse autoencoder is used to extract the features of each domain. Finally, to solve the problem that the traditional Softmax classifier is not capable of classifying the fusion information, an echo state network optimized by competitive swarm optimizer is proposed to perform feature fusion and output the diagnostic results. The experimental results of fault diagnosis in multiple scenarios show that the proposed method has a good classification performance in variable speed conditions. In addition, it is also robust to a reduction in the number of training samples and external noise.

This work is supported by the National Natural Science Foundation of China (No. 51977128).

Key words: planetary gearbox; fault diagnosis; multiple scenarios; deep learning; stack sparse autoencoder; echo state network; deep feature fusion network

0 引言

近年来, 随着新能源地位的不断提升, 风能成为当今世界的重要能源之一, 风力发电系统得到了广泛的研究和应用^[1-2]。行星齿轮箱有结构紧凑、功率密度高和传动效率高等优点, 是风电机组传动系统中的重要部件^[3]。在动态载重负荷和频繁变化的运行工况下, 行星齿轮箱易发生故障, 并导致高额

维护成本^[4]。因此, 准确诊断齿轮箱故障对于提高风电机组的安全性、可靠性和经济性有着重要意义。

传统故障诊断方法通常对故障信号进行分解和处理, 提取故障特征, 并结合分类算法进行模式识别^[5]。文献[4]建立了行星齿轮箱正常和分布式故障状态下的振动信号模型, 推导了各类故障下的故障特征频率。文献[6]对原始信号进行经验模态分解, 并以峭度为准则提取故障特征量, 以J-散度和KL-散度为指标判别故障。文献[7]利用多重分形谱从振动信号中提取了多维特征量, 将特征量作为支持向量机的输入, 实现了故障识别。然而, 由于行星齿轮箱结构复杂, 故障工况多变, 实际采集的行星齿

基金项目: 国家自然科学基金项目资助(51977128); 上海市青年科技启明星计划项目资助(21QC1400200); 上海市自然科学基金项目资助(21ZR1425400)

轮箱故障信号具有较强的非平稳性, 导致其可区分性较差。上述方法对人工经验和信号处理技术的要求较高, 普适性较差, 在推广应用易造成信息缺失^[8]。

近年来, 由于人工智能技术的发展, 行星齿轮箱的智能诊断方法得到了广泛的研究^[9]。其中, 深度学习具有高智能、高效率 and 强泛化能力等优点^[10], 能够满足故障诊断对特征自适应提取的要求, 减少对人工经验的依赖, 并实现对原始数据的故障特征信息的充分保留^[11]。文献[12]构造了基于 LeNet-5 的卷积神经网络 (Convolutional Neural Network, CNN), 取得了较好的故障分类效果。文献[13]提出了一种 CNN 的改进方法, 实验结果表明改进后的网络对外界干扰有较强的鲁棒性。文献[14]针对齿轮箱振动信号的多尺度特性, 提出了一种多尺度卷积神经网络 (Multiscale Convolutional Neural Network, MSCNN), 成功提取了不同尺度下的诊断信息。文献[15]提出了一种多通道加权卷积神经网络, 以多通道图像为输入, 有效提取了振动信号的故障特征。文献[16]设计了一种基于堆栈稀疏自编码器 (Stacked Sparse Auto-Encoder, SSAE) 的深度学习模型, 以齿轮箱振动信号的时频图像为输入, 有效实现了状态分类。文献[17]从风电机行星齿轮箱的三轴振动信号中分别提取特征, 并结合特征增强与特征融合算法取得了很好的故障诊断效果。

上述文献表明, 深度学习方法在行星齿轮箱智能故障诊断中取得了显著的成就, 然而深度学习的性能依赖于大量含标记、同分布的训练样本^[18-20]。由于风机行星齿轮箱运行环境恶劣、运行工况多变、机械故障复杂等因素, 获取符合足够条件的样本在实际中需要花费大量的时间与经济成本, 样本的数量不足、干扰成分过多导致实际分类效果差。

针对在实际风电机行星齿轮箱故障诊断中可能出现的变速工况、样本不足和强噪声场景, 本文提出了一种基于深度特征融合网络 (Deep Feature Fusion Network, DFFN) 的故障诊断方法。为充分提取原始信号的故障特征信息, 尽可能减少信息缺失, 该方法将原始时域信号拓展到多特征域, 并构造多维堆栈稀疏自编码器 (Multi-Dimensional Stack Sparse Auto-Encoder, MD-SSAE) 用于从各特征域中提取故障信息。针对传统 Softmax 分类器对融合信息处理能力不足的问题, 本文引入回声状态网络 (Echo State Network, ESN) 对多维故障信息进行融合, 并输出诊断结果。此外, 为解决传统 ESN 难以获得最优参数组合的问题, 在粒子群算法 (Particle Swarm Optimizer, PSO) 中引入混沌初始化策略和基

于竞争策略的粒子更新机制, 设计了基于竞争粒子群算法 (Competitive Swarm Optimizer, CSO) 优化的 ESN, 并将其应用于深度特征融合网络。通过多场景下的故障诊断案例分析, 验证所提方法在实际应用中的可行性与普适性, 为风电系统平稳运行提供理论和技术支持。

1 理论基础

1.1 堆栈稀疏自编码器

自编码器是一种典型的三层神经网络, 通过将输入数据进行编码和解码, 用无监督的方式实现对高维数据的降维^[21]。编码器 ϕ 和解码器 φ 定义为

$$\phi: \mathbf{Z} = \sigma(\mathbf{W}\mathbf{X} + \mathbf{b}) \quad (1)$$

$$\varphi: \mathbf{X}' = \sigma'(\mathbf{W}'\mathbf{Z} + \mathbf{b}') \quad (2)$$

式中: $\mathbf{X} \in \mathbf{R}^N$ 为输入向量; $\mathbf{Z} \in \mathbf{R}^M$ 为压缩向量; $\mathbf{X}' \in \mathbf{R}^N$ 为对 \mathbf{X} 重构的输出向量; $\mathbf{W} \in \mathbf{R}^{M \times N}$ 为输入层和隐藏层之间的连接权值; $\mathbf{W}' \in \mathbf{R}^{M \times N}$ 为隐藏层和输出层之间的连接权值; $\mathbf{b} \in \mathbf{R}^M$ 和 $\mathbf{b}' \in \mathbf{R}^M$ 分别为输入层和隐藏层的偏置向量; σ 和 σ' 分别表示编码过程和解码过程的激活函数。

自编码器结构如图 1 所示, 通过训练 \mathbf{W} 和 \mathbf{W}' 使重构误差最小化, 重构误差表示为

$$L(\mathbf{X}, \mathbf{X}') = \|\mathbf{X} - \mathbf{X}'\|^2 = \|\mathbf{X} - \sigma'[\mathbf{W}'\sigma(\mathbf{W}\mathbf{X} + \mathbf{b}) + \mathbf{b}']\|^2 \quad (3)$$

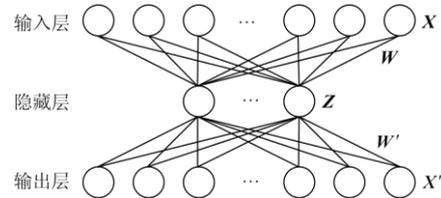


图 1 自编码器结构

Fig. 1 Structure of autoencoder

为实现高维数据的深层特征提取, 可以将多个自编码器进行堆叠构造深度学习模型^[22], 即堆栈自编码器, 其损失函数可以定义为

$$J(\mathbf{W}, \mathbf{b}) = \frac{1}{m} \sum_{i=1}^m \left[\frac{1}{2} \|\sigma(\mathbf{W}\mathbf{X}^{(i)} + \mathbf{b}) - \mathbf{Y}^{(i)}\|^2 \right] + \frac{\lambda}{2} \sum_{l=1}^{n-1} \sum_{i=1}^{s_l^i} \sum_{j=1}^{s_l^{i+1}} [\mathbf{W}_{ji}^{(l)}]^2 \quad (4)$$

式中: \mathbf{W} 、 \mathbf{b} 和 σ 分别为权值矩阵、偏置向量和激活函数; m 为样本数; $\mathbf{X}^{(i)}$ 为原始输入样本; $\mathbf{Y}^{(i)}$ 为样本对应的标签; λ 为正则化常数; n 为层数; s_l^i 和 s_l^{i+1} 为矩阵 $\mathbf{W}^{(l)}$ 的行和列。

为降低堆栈自编码器的计算量并使其容易收敛, 本文在自编码器中添加稀疏约束, 使隐藏层中

的一些神经元处于非激活状态, 其在损失函数中表现为稀疏性附加项^[23]。因此, 标准堆栈稀疏自编码器的损失函数为

$$L_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = J(\mathbf{W}, \mathbf{b}) + \beta \sum_{j=1}^{s_2} KL(\rho \parallel \hat{\rho}_j) \quad (5)$$

$$KL(\rho \parallel \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (6)$$

式中: β 为稀疏性惩罚项的权重; ρ 为稀疏性参数; $\hat{\rho}$ 为平均激活值; s_2 为隐藏层节点数。

1.2 回声状态网络

回声状态网络是一种循环神经网络, 通常使用储存池模拟神经元进行特征计算, 具有很强的特征记忆能力和特征表达能力^[24]。ESN 结构如图 2 所示, 网络由输入层 $\mathbf{u} = \{u_1, u_2, \dots, u_M\}$ 、储存池 $\mathbf{h} = \{h_1, h_2, \dots, h_G\}$ 和输出层 $\mathbf{o} = \{o_1, o_2, \dots, o_S\}$ 构成。其中, M 取决于输入数据维度, G 为 ESN 的超参数, S 取决于输出类别数。网络中: $\mathbf{W}_{\text{in}} \in \mathbf{R}^{M \times G}$ 、 $\mathbf{W}_{\text{h}} \in \mathbf{R}^{G \times G}$ 、 $\mathbf{W}_{\text{out}} \in \mathbf{R}^{G \times S}$ 分别为输入层、储存池和输出层的权值矩阵。在本文深度特征融合网络中, ESN 的储存池作为信息处理媒介表现为大规模随机稀疏网络, 将输入特征向量从低维映射到高维状态空间, 在高维状态空间对网络的部分连接权值进行训练, 从而实现特征融合。网络表示为

$$\mathbf{h}(t+1) = f_1(\mathbf{W}_{\text{in}} \mathbf{u}(t+1) + \mathbf{W}_{\text{h}} \mathbf{h}(t)) \quad (7)$$

$$\mathbf{o}(t+1) = f_2(\mathbf{W}_{\text{out}} \mathbf{h}(t+1)) \quad (8)$$

式中: t 为样本指标; f_1 和 f_2 为网络使用的激活函数。

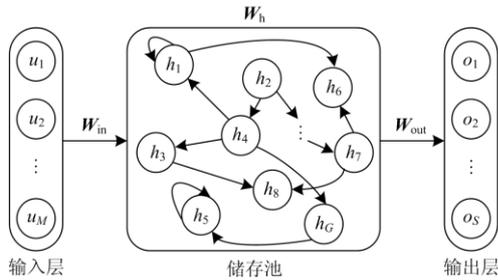


图 2 ESN 结构

Fig. 2 Structure of ESN

ESN 在训练中需要确定 3 个权值矩阵, 使用启发式参数优化方法, 首先随机生成 \mathbf{W}_{in} 和 \mathbf{W}_{h} , 然后最优计算 \mathbf{W}_{out} 。为了保证 ESN 的信息处理与分类性能, 生成的 \mathbf{W}_{h} 需要满足回声状态特性和可分离性。回声状态特性是指储存池会渐进地冲掉初始条件中的信息, 通过调整 \mathbf{W}_{h} 的谱半径实现; 可分离性是指可以从不同的输入中产生不同的状态, 通过在储存池中使用较小的连接率实现。当 \mathbf{W}_{in} 和 \mathbf{W}_{h} 确定

时, \mathbf{W}_{out} 可以通过求解一个优化问题得到, 表述为

$$\mathbf{W}_{\text{out}} = \arg \min_{\mathbf{W}_{\text{out}}} \text{MSE}(\mathbf{o}^{\text{desired}}, \mathbf{o}) \quad (9)$$

$$\text{MSE}(\mathbf{o}^{\text{desired}}, \mathbf{o}) = \frac{1}{S} \frac{1}{T} \sum_{s=1}^S \sum_{t=1}^T [o_s^{\text{desired}}(t) - o_s(t)]^2 \quad (10)$$

式中: $o_s^{\text{desired}}(t)$ 为样本 t 第 s 个输出的真实标签; T 为训练样本数; $o_s(t)$ 为样本 t 第 s 个输出的预测标签。

1.3 竞争粒子群算法

上述回声状态网络的训练使用启发式参数优化方法, 参数的设置对网络性能影响较大。为寻求最优的参数组合, 并降低人为因素对深度特征融合网络的影响, 引入竞争粒子群优化算法。竞争粒子群算法是近年来提出的一种新的粒子群优化算法, 其实现简单、收敛快速, 被广泛应用于求解单目标优化问题^[25]。在粒子群算法中, 粒子群包含 N 个粒子, 每个粒子表示一个优化问题的候选解, 在群迭代过程中更新粒子, 寻找最优解^[26]。每个粒子有其单独的位置和速度, 分别表示为 $\mathbf{X}_p = \{x_p^1, x_p^2, \dots, x_p^D\}$ 和 $\mathbf{V}_p = \{v_p^1, v_p^2, \dots, v_p^D\}$, D 为优化问题的决策变量个数。

竞争粒子群算法较传统粒子群算法的优势在于其强大的粒子更新机制。首先将第 k 次迭代的粒子群状态表示为 $P(k) = \{\mathbf{X}_1(k), \mathbf{X}_2(k), \dots, \mathbf{X}_N(k)\}$, 在计算出 $P(k)$ 中所有粒子的适应度后, 将群随机分成两个相等的组。随后将两组粒子进行两两竞争, 适应度更好的粒子为胜者, 直接进入 $P(k+1)$, 另一个粒子为败者, 使其在胜者的基础上进行更新并转移到 $P(k)$ 。为了便于表述, 将胜者和败者的位置和速度分别表示为 $\mathbf{X}_{p,w}(k)$ 、 $\mathbf{V}_{p,w}(k)$ 、 $\mathbf{X}_{p,l}(k)$ 、 $\mathbf{V}_{p,l}(k)$, 则败者的更新过程为

$$\mathbf{V}_{p,l}(k+1) = r_1(p,k) \mathbf{V}_{p,l}(k) + r_2(p,k) (\mathbf{X}_{p,w}(k) - \mathbf{X}_{p,l}(k)) + \bar{\lambda} r_3(p,k) (\bar{\mathbf{X}}_p(k) - \mathbf{X}_{p,l}(k)) \quad (11)$$

$$\mathbf{X}_{p,l}(k+1) = \mathbf{X}_{p,l}(k) + \mathbf{V}_{p,l}(k+1) \quad (12)$$

式中: $r_1(p,k)$ 、 $r_2(p,k)$ 、 $r_3(p,k)$ 为服从均匀分布 $[0,1]$ 的随机系数; $\bar{\mathbf{X}}_p(k)$ 为粒子群的全局平均位置; $\bar{\lambda}$ 为控制 $\bar{\mathbf{X}}_p(k)$ 的参数。

2 深度特征融合网络

在行星齿轮箱的故障诊断中, 原始信号中不同的特征域具有不同的价值信息和故障特征^[27]。而现有的深度学习模型以单维特征提取为主, 易造成信息缺失, 且分类性能优秀、应用广泛的 Softmax 分

类器在融合信息的处理中表现欠佳。因此,为充分利用故障特征信息,本文提出一种基于 MD-SSAE 和 CSO-ESN 的深度特征融合网络,网络结构如图 3

所示,该网络利用多个 SSAE 同时从各特征域中提取特征信息,并使用 CSO-ESN 实现信息融合,并输出诊断结果。

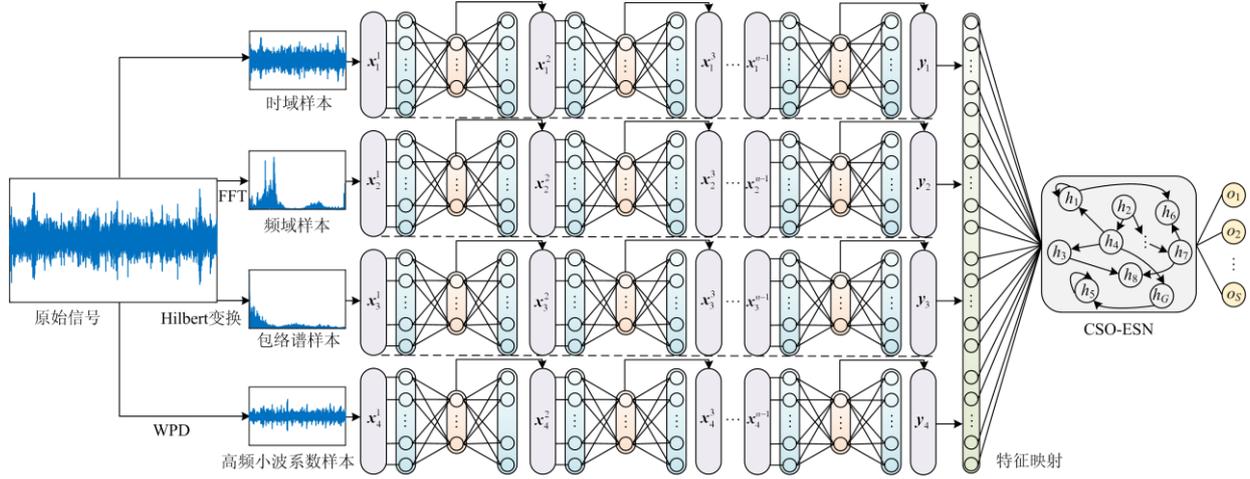


图 3 DFFN 网络结构

Fig. 3 Network structure of DFFN

2.1 多维堆栈稀疏自编码器

如图 3 所示,首先对原始信号进行预处理,为充分提取各类故障特征,分别提取原始时域样本中的时域特征信息、经快速傅里叶变换(Fast Fourier Transform, FFT)后的频域样本中的频域特征信息、经 Hilbert 变换后的包络谱样本中的冲击特征信息和经小波包分解(Wavelet Packet Decomposition, WPD)后的高频小波系数样本中的非平稳特征信息。将上述各类信息作为 MD-SSAE 的输入,SSAE 由输入层 x^1 、若干隐藏层 $x^j (j=2,3,\dots,n-1)$ 和输出层 $y (y=x^n)$ 构成,特征提取阶段的损失函数为

$$L_{k \text{ sparse}}^j(\mathbf{W}_k^j, \mathbf{b}_k^j) = \frac{1}{2m} \sum_{i=1}^m \left\| \sigma'_k \left[\mathbf{W}_k^{j,j} \cdot \sigma_k \left(\mathbf{W}_k^j \cdot \mathbf{x}_k^{j,i} + \mathbf{b}_k^j \right) + \mathbf{b}_k^{j,j} \right] - \mathbf{x}_k^{j,i} \right\|^2 + \frac{\lambda_k}{2} \sum_{s=1}^j \sum_{c=1}^c(\mathbf{W}_k^s) \sum_{r=1}^r(\mathbf{W}_k^s) \left\{ \left[\mathbf{W}_k^s \right]_{rc} \right\}^2 + \beta_k \sum_{t=1}^r(\mathbf{W}_k^s) KL(\rho_k \| \hat{\rho}_{k,t}^j) \quad (13)$$

式中: $k=1,2,3,4$, 表示第 k 个 SSAE; $j=1,2,\dots,n_k$, 表示第 j 个 AE; $c(\mathbf{W}_k^s)$ 和 $r(\mathbf{W}_k^s)$ 分别为权值矩阵 \mathbf{W} 的行和列。

2.2 竞争粒子群算法优化的回声状态网络

如 1.2 节所述,ESN 的训练过程是一种启发式的参数优化过程,这使得其难以获得最优的参数组合。此外,若由人工确定储存池规模、谱半径、稀疏度和输入变化因子会影响 ESN 的泛化性能。CSO

算法具有操作简单、所需参数少和易于实现等优点,因此,为了能高效地实现不同特征域的信息融合,本文提出了 CSO-ESN,具体优化步骤如下:

- 1) 初始化参数,设置最大迭代次数、种群规模,并以 ESN 的 4 个关键参数(储存池规模、谱半径、稀疏度、输入变化因子)为优化变量;
- 2) 利用 Logistic 映射对粒子群初始位置和速度进行混沌初始化;
- 3) 根据式(10)计算每个粒子对应的 ESN 模型在训练集上的均方根误差,作为适应度值;
- 4) 将两组粒子两两竞争,根据适应度值的大小分别标记为胜者和败者;
- 5) 根据式(11)、式(12)更新败者粒子的速度与位置,计算更新粒子的适应度值、全局最优值和对应的最优解;
- 6) 若达到最大迭代次数或适应度值达标,则优化结束,转到步骤 7), 否则返回步骤 4);
- 7) 得到最优粒子,即最优网络参数组合。

2.3 故障诊断模型

通过 MD-SSAE 的特征提取,得到特征向量 $\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \mathbf{y}_4$ 。将特征向量全连接,构造 ESN 的输入向量 \mathbf{u} , 使用 CSO 优化 ESN 结构参数,训练 CSO-ESN 并输出诊断结果。综上,基于 DFFN 的故障诊断流程如图 4 所示。

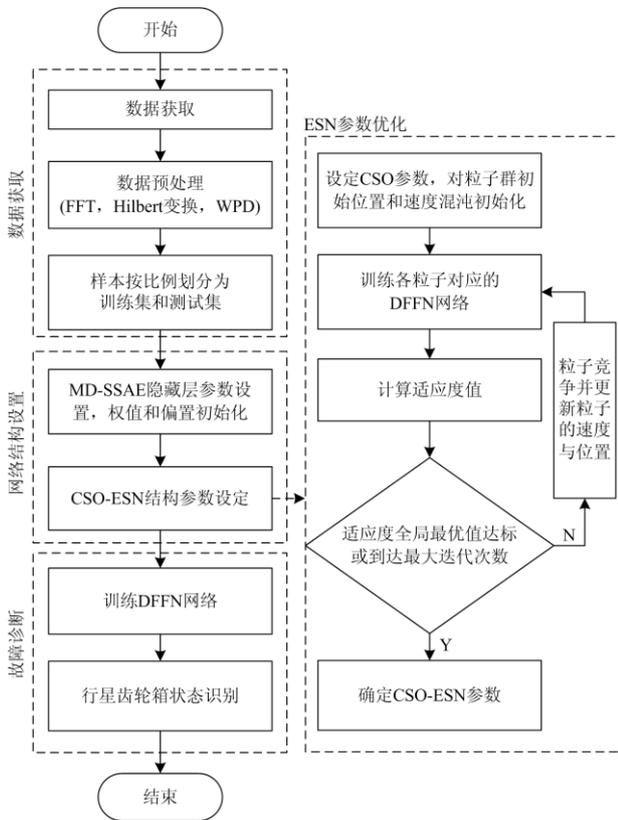


图 4 基于 DFFN 的故障诊断流程

Fig. 4 DFFN based fault diagnosis process

3 实验分析

3.1 实验介绍

风电机组行星齿轮箱故障模拟平台如图 5 所示, 该平台包含 6 个设备: 驱动电机、转速控制器、连轴罩、行星齿轮箱、平行齿轮箱和磁粉制动负载。图 6(a)为实验使用的行星轮, 包括正常(Normal Condition, NC)、点蚀(Chipped Tooth Fault, CTF)、磨损(Surface Wear Fault, SWF)和断齿(Miss Tooth Fault, MTF)4 种状态。为获取故障数据, 选取行星齿轮箱中的某一行星轮, 将其替换为故障行星轮, 使用加速度传感器采集箱体振动信号, 传感器安装位置如图 6(b)所示。

1) 定速实验

设定电机转速恒定为 1 800 rpm, 传感器采样率设置为 12 kHz, 分别采集 4 种工况下不同健康状态行星齿轮箱的振动信号, 如图 7(a)所示。

2) 变速实验

改变负载大小, 调节电动机的转速从 900 rpm 至 1 500 rpm, 持续时间为 100 s, 变速工况下 1 s 内的振动波形如图 7(b)所示, 转速变化如图 8 所示。

图 7 中纵坐标表示多少重力加速度。

旋转机械工作时产生的振动信号具有周期性, 为保证每个样本数据都包含至少一个完整故障周期, 且为了利于网络的训练, 设置样本集中的每个样本包含 2 048 个采样点, 每种工况和转速均取 400 个样本, 共计 3 200 个样本。

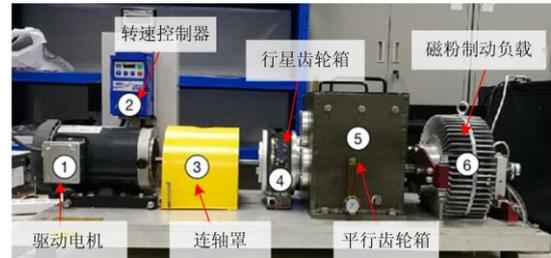


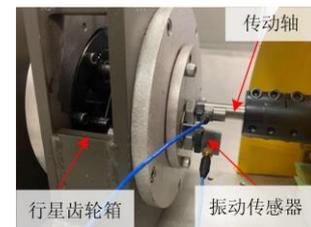
图 5 风电机组故障诊断实验台

Fig. 5 Wind turbine fault diagnosis test bench



正常 点蚀 磨损 断齿

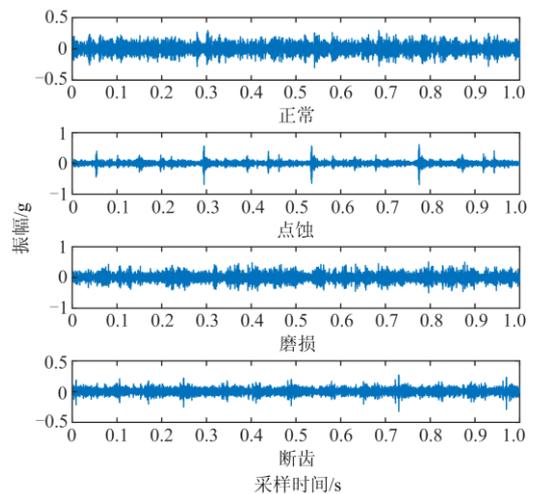
(a) 故障行星轮



(b) 振动传感器安装位置

图 6 故障设置与信号采集

Fig. 6 Fault setting and signal collection



(a) 定速振动信号

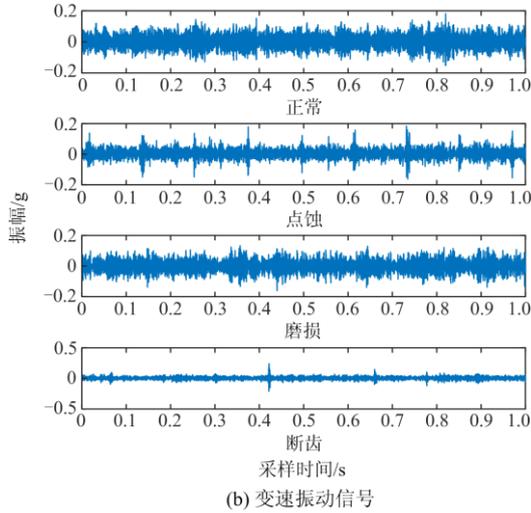


图 7 行星齿轮箱正常与故障时振动信号

Fig. 7 Vibration signal of planetary gearbox at normal and failure conditions

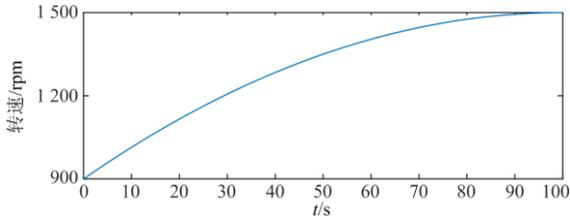


图 8 行星齿轮箱转速变化曲线

Fig. 8 Speed curve of planetary gearbox

3.2 模型参数

网络结构如图 3 所示, 各特征域样本对应的 SSAE 隐藏层节点数如表 1 所示, 其中第一层节点数为各样本的输入维度。CSO-ESN 使用 sigmoid 为激活函数, 种群大小设置为 100, 优化迭代次数为 200。训练过程使用 Adam 优化算法, 初始学习率设置为 0.01, 训练迭代次数为 200。

表 1 MD-SSAE 结构参数

Table 1 Structural parameters of MD-SSAE

输入样本	层数	隐藏层节点数
时域	5	2048-1024-512-128-32-4
频域	4	1024-512-128-32-4
包络谱	4	1024-512-128-32-4
小波系数	4	1024-512-128-32-4

3.3 算例分析

3.3.1 样本充足场景下的故障诊断

样本充足情况下的训练集和测试集按 3:1 随机划分, 即定速训练样本为 1 200 个, 定速测试样本为 400 个, 变速训练样本为 1 200 个, 变速测试样本为 400 个。使用深度学习网络 CNN^[12](①)、

MSCNN(②)^[14]、SSAE^[16](③)、深度增强融合网络 (Deep Enhanced Fusion Network, DEFN)^[17](④)、MD-SSAE(⑤)、MD-SSAE-ESN(⑥)与使用 PSO 优化 ESN 的 MD-SSAE-PSO-ESN(⑦)作为对比。其中, MSCNN 以时域样本粗粒度化后的 3 个尺度为输入, 单个 CNN 结构与方法①相同; SSAE 以时域样本为输入, 隐藏层节点数同表 1 第一行; DEFN 以各特征域样本为输入, 特征增强后使用四维的稀疏自编码器提取故障信息; MD-SSAE 结构参数同表 1, 特征全连接后采用 Softmax 分类器进行故障识别; MD-SSAE-ESN 参数人为设定, 储存池规模为 300, 谱半径设置为 1, 稀疏度为 10%, 输入变化因子为 0.1。

为减少随机性的影响, 将每组实验重复 10 次, 对测试集的平均分类准确率与训练时间见表 2, 准确率定义为正确分类的样本占测试样本总数的百分比。可见在样本充足的条件下, 各方法都可以实现较高识别准确率, 其中本文提出的 DFFN 模型的诊断结果: 定速工况为 98.03% ± 0.47%, 变速工况为 97.83% ± 0.49%, 相较于经典多尺度特征提取网络 MSCNN 与新型特征融合网络 DEFN 具有更高的准确率和更低的标准差。其中, 由于将时域信号多尺度表达后特征信息易受转速影响, MSCNN 在变速工况下的分类效果明显不如定速工况。而 DEFN 输入为多特征域样本, 故障识别效果优于仅提取时域特征信息的方法, 说明特征融合理论在实际应用中有明显的优势。

表 2 诊断结果对比

Table 2 Comparison of fault diagnosis results

方法	(准确率 ± 标准差)/%		(平均训练/测试时间)/s
	定速工况	变速工况	
①	96.13 ± 0.88	95.65 ± 0.76	262.81/0.48
②	96.90 ± 0.63	95.78 ± 0.92	331.61/0.50
③	96.78 ± 0.79	96.50 ± 0.86	189.36/0.24
④	97.18 ± 0.43	96.70 ± 0.52	273.74/0.47
⑤	95.60 ± 1.78	94.98 ± 1.91	239.22/0.27
⑥	95.03 ± 0.98	94.83 ± 1.17	322.91/0.56
⑦	97.55 ± 0.66	96.93 ± 0.82	661.83/0.63
DFFN	98.03 ± 0.47	97.83 ± 0.49	573.10/0.61

此外, 相较于传统的一维特征提取结合 Softmax 分类器的深度学习网络, 多维特征提取结合 Softmax 分类器的故障识别效果较差, 据此推断 Softmax 分类器对不同特征域的信息融合能力较差, 因此本文引入 ESN 进行特征融合并输出诊断结果。由方法⑥和方法⑦的诊断结果可以看出, ESN 的结构参数对其性能影响较大, 由人工经验设定的结构参数易导致其泛化能力不足, 因此需要引入合适的优化算法

对 ESN 的结构参数进行调整。对比方法⑦与 DFFN 可以看出, CSO-ESN 的特征融合与分类性能优于 PSO-ESN, 且 CSO 的迭代速度较快。

因权重矩阵数量的增加与优化迭代过程中网络训练次数的增加, DFFN 的训练相较于传统方法需要花费更多的时间, 但所需的测试时间增加在较小的范围内, 因此训练后的诊断模型不会增加计算负担。

除准确率指标外, 本文引入受试者工作特征曲线(Receiver Operating Characteristic, ROC), 根据真实类别和预测类别的组合, 测试样本可以划分为真阳性(True Positive, TP)、假阳性(False Positive, FP)、真阴性(True Negative, TN)和假阴性(False Negative, FN), 因此真正类率(True Positive Rate, TPR)和负正类率(False Positive Rate, FPR)计算如下:

$$TPR = \frac{TP}{TP+FN} \quad (14)$$

$$FPR = \frac{FP}{FP+TN} \quad (15)$$

利用 ROC 曲线对 CSO-ESN 的特征融合、分类性能进行评估。绘制方法③、方法④、方法⑤和 DFFN 对变速样本分类的 ROC 曲线, 并计算曲线面积(Area Under Curve, AUC), 如图 9 所示。可见在上述 4 组实验中, 使用 ESN 进行特征融合和健康状态分类的 AUC 值显著优于 Softmax 分类器。在不同参数的 ESN 中, 参数由人工经验设置的 ESN 对点蚀和断齿故障的分类性能较差, CSO-ESN 的 AUC 值优于 PSO-ESN 且均接近于 1, 分类性能优秀。

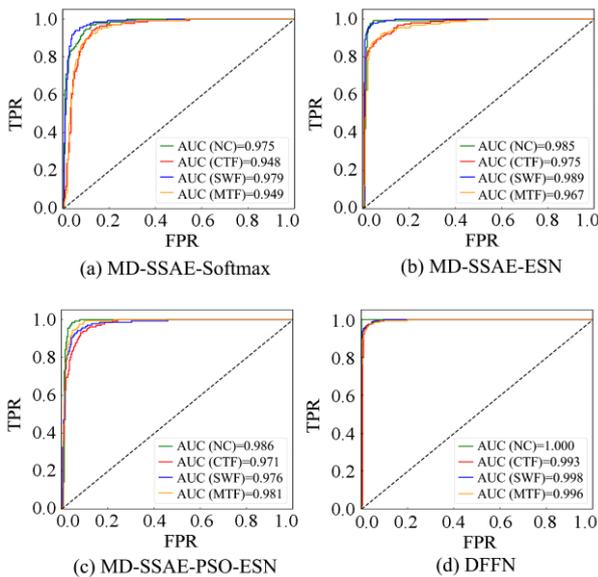


图 9 不同算法故障分类的 ROC 曲线

Fig. 9 ROC curves of fault classification under different faults

3.3.2 样本不足场景下的故障诊断

在风电机组实际工作中, 行星齿轮箱发生故障的频率较低, 因此会产生数据样本不足的问题。为模拟小样本情况, 定义样本充足时的训练集样本数量为 100%, 以变速工况下的实验为例, 实验分别在训练样本-训练集样本总数比例为 10%、20%、30%、40%、50%、60%、70%、80%和 90%的情况下对网络进行训练, 同时测试集样本数量保持不变, 每组重复 10 次后诊断结果均值见图 10。可见从多特征域提取故障信息的方法在不同训练样本比例下诊断准确率均高于仅从时域信号提取特征的方法。在训练样本比例大于 60%的情况下, 各方法的分类准确率趋于稳定, 说明此时训练样本充足。当训练样本比例小于 60%后, 传统深度学习网络 CNN、MSCNN 和 SSAE 的分类能力出现明显下降, 相比之下, 特征融合网络 DEFN 与 DFFN 对样本的减少有很强的鲁棒性, 且 DFFN 总体表现更好, 在 10% 的训练样本比例下仍有 90% 以上的分类准确率。

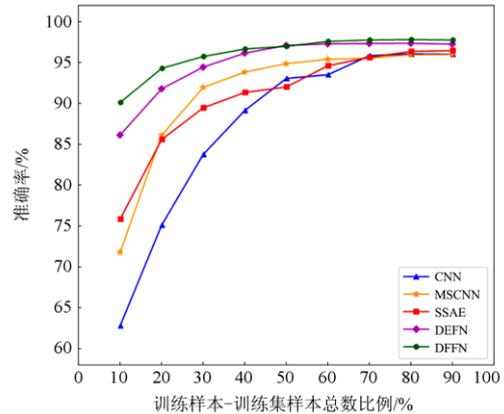


图 10 10%~90%训练样本比例下诊断结果

Fig. 10 Diagnostic results under 10%~90% training-total sample ratio

为进一步验证 DFFN 在小样本情况下的分类性能, 对在 70%、50%、30%、10% 训练样本比例下的 40 组实验进行可视化分析, 分类结果混淆矩阵如图 11 所示, 可以看出, 随着训练样本的减少, 网络对磨损与断齿故障的识别率降低较为明显, 但总体识别率稳定在较高水平, 可以满足实际应用中的故障诊断要求。此外在 10% 训练样本比例下, 采用 t-分布邻域嵌入算法对原始信号与 DFFN 网络特征映射层的特征降维可视化, 如图 12 所示。可见 MD-SSAE 从原始信号多个特征域提取出的特征全连接后表现出良好的类间可分性和类内聚集性, 这些特征可以在 CSO-ESN 中有效融合, 并输出较准确的诊断结果。

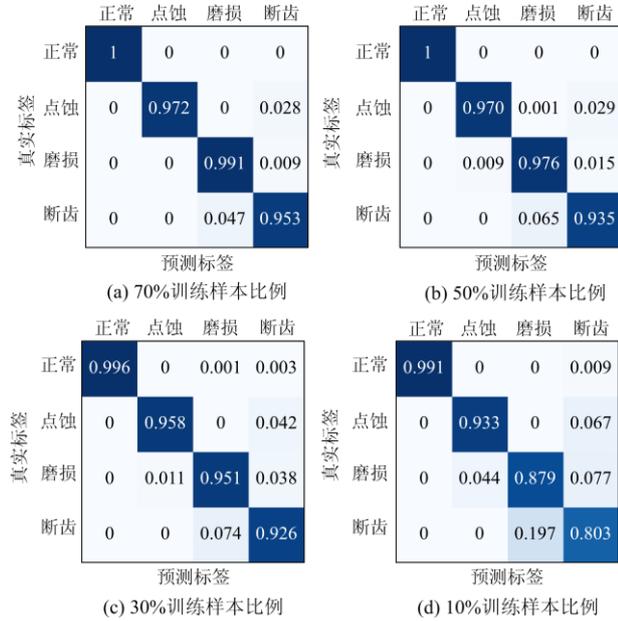


图 11 故障诊断混淆矩阵

Fig. 11 Fault diagnosis confusion matrixes

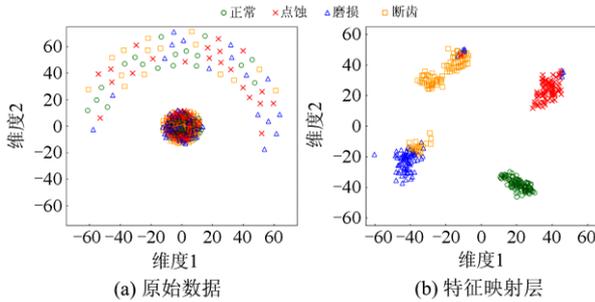


图 12 特征散点图

Fig. 12 Scatter plots of features

3.3.3 强噪声干扰场景下的故障诊断

在风电机组实际工作中，振动信号易受外界噪声影响，导致传统故障诊断模型在实际应用中泛化能力不足。为检验 DFFN 在样本相对充足条件下和样本相对不足条件下的抗噪性，选取上述训练样本-训练集样本总数比例为 70% 和 20% 情况下的训练故障诊断模型，保持训练集样本不变，在原测试集样本中加入高斯白噪声来模拟外界环境。考虑到诊断模型在训练中无法获取到实时的噪声信息，这样的训练和测试方法符合实际应用场景。测试样本中的噪声含量通过信噪比来表示。

$$R_{SN} = 10 \lg \left(\frac{P_{signal}}{P_{noise}} \right) \quad (16)$$

为了测试不同噪声含量下 DFFN 模型的诊断效

果，在测试集中添加不同含量的噪声，诊断结果均值见表 3、表 4。可以看出，在样本相对充足的情况下，各方法对信噪比大于 8 dB 的测试集均有较好的诊断效果；而对信噪比小于 8 dB 的测试集，DFFN 诊断模型表现出明显的优势。此外，在测试样本信噪比为 -2 dB 的强噪声干扰下，传统深度学习方法的可靠性大大降低，而 DFFN 仍可以实现 85% 以上的诊断准确率。在样本相对不足的场景下，传统深度学习方法在测试集添加强噪声后表现很差，分类效果近乎于随机划分，相比之下，DFFN 诊断模型在测试集信噪比大于 2 dB 的条件下可以实现 85% 以上的诊断准确率。综上所述，本文所提方法抗干扰能力强于传统深度学习方法，噪声无法掩盖所有特征域的故障信息，多维特征提取可以显著提升深度学习方法在强噪声干扰下的特征提取能力。

表 3 70%训练样本比例下诊断结果对比

Table 3 Comparison of fault diagnosis results under 70% training-total sample ratio

R_{SN}/dB	诊断准确率/%					
	MSCNN		SSAE		DFFN	
	定速	变速	定速	变速	定速	变速
10	95.73	94.85	95.43	95.18	97.88	97.70
8	95.23	94.38	95.13	93.23	97.18	96.53
6	89.25	87.88	91.30	89.58	96.15	95.65
4	86.53	83.80	89.95	83.33	92.00	93.13
2	82.20	79.75	85.25	79.30	92.45	90.15
0	77.53	73.30	73.98	66.25	91.03	86.63
-2	69.10	63.65	67.55	61.38	86.63	85.03

表 4 20%训练样本比例下诊断结果对比

Table 4 Comparison of fault diagnosis results under 20% training-total sample ratio

R_{SN}/dB	诊断准确率/%					
	MSCNN		SSAE		DFFN	
	定速	变速	定速	变速	定速	变速
10	87.38	86.05	85.60	85.28	95.48	93.90
8	85.50	79.88	82.08	77.90	92.13	92.53
6	78.25	67.60	77.93	65.28	89.45	90.70
4	56.28	48.83	59.03	41.33	88.68	88.78
2	40.68	34.45	37.30	29.05	87.40	85.93
0	30.70	26.23	31.10	29.35	81.95	80.65
-2	30.33	24.43	26.88	25.08	77.93	72.25

4 结论

针对风电机组行星齿轮箱故障诊断中可能出现的变速工况、样本不足和强噪声场景，提出了基于 MD-SSAE 与 CSO-ESN 的深度特征融合网络。该网络可以同时从行星齿轮箱的多个特征域中提取特征

信息, 并使用 CSO-ESN 进行信息融合, 实现样本故障信息的充分利用。主要结论如下:

1) 为实现 ESN 主要结构参数的优化, 本文在 PSO 的基础上引入混沌初始化策略和基于竞争策略的粒子更新机制, 在样本充足场景下的诊断实验结果表明, 本文提出的深度特征融合网络的故障识别率优于经典多尺度特征提取网络 MSCNN 与新型特征融合网络 DEFN, 且 CSO-ESN 的特征融合与分类性能优于 Softmax 分类器, 以及依据人工经验设置参数的 ESN 和 PSO-ESN 3 种方法。

2) 针对风电机组行星齿轮箱的定速工况和变速工况, 在样本充足情况下, DFFN 对变速工况下的故障诊断平均准确率为 97.83%, 略低于定速工况下的 98.03%, 符合实际需求且均优于其他对比算法。因此, 本文提出的 DFFN 可以应用于变速工况下的行星齿轮箱状态识别。

3) 在样本不足场景下的故障诊断实验结果表明, DFFN 在训练样本-训练集样本总数比例为 10% 的情况下, 故障识别准确率仍能达到 90% 以上, 对样本的减少表现出很强的鲁棒性。

4) 相较于传统深度学习方法, DFFN 对外界噪声干扰的敏感度较低。在样本相对充足的情况下, 信噪比为 -2 dB 的强噪声干扰下可以实现 85% 以上的识别准确率。在样本相对不足的情况下, 信噪比大于 2 dB 的条件下可以实现 85% 以上的诊断准确率。实验结果表明, 所构建的网络可以有效地应用于较恶劣条件下风电机组行星齿轮箱的故障诊断。

参考文献

- [1] NADOUR M, ESSADKI A, NASSER T. Improving low-voltage ride-through capability of a multimegawatt DFIG based wind turbine under grid faults[J]. *Protection and Control of Modern Power Systems*, 2020, 5(4): 370-382.
- [2] 薛帅, 高厚磊, 郭一飞, 等. 大规模海上风电场的双层分布式有功控制[J]. *电力系统保护与控制*, 2021, 49(3): 1-9.
XUE Shuai, GAO Houlei, GUO Yifei, et al. Bi-level distributed active power control for a large-scale wind farm[J]. *Power System Protection and Control*, 2021, 49(3): 1-9.
- [3] 张露江, 张利, 杨要伟, 等. 基于改进贝叶斯网络的风机齿轮箱自动诊断策略研究[J]. *电力系统保护与控制*, 2019, 47(19): 145-151.
ZHANG Lujiang, ZHANG Li, YANG Yaowei, et al. Research on automatic diagnosis strategy of wind turbine gearbox based on improved Bayesian network[J]. *Power System Protection and Control*, 2019, 47(19): 145-151.
- [4] 冯志鹏, 褚福磊. 行星齿轮箱齿轮分布式故障振动频谱特征[J]. *中国电机工程学报*, 2013, 33(2): 118-125.
FENG Zhipeng, CHU Fulei. Vibration spectral characteristics of distributed gear fault of planetary gearboxes[J]. *Proceedings of the CSEE*, 2013, 33(2): 118-125.
- [5] 赵若好, 马宏忠, 魏旭, 等. 基于 EWT 及多尺度形态谱的高压并联电抗器故障诊断研究[J]. *电力系统保护与控制*, 2020, 48(17): 68-75.
ZHAO Ruoyu, MA Hongzhong, WEI Xu, et al. Research on fault diagnosis of a high voltage shunt reactor based on EWT and multiscale spectral spectrum[J]. *Power System Protection and Control*, 2020, 48(17): 68-75.
- [6] 郭艳平, 颜文俊, 包哲静, 等. 基于经验模态分解和散度指标的风力发电机滚动轴承故障诊断方法[J]. *电力系统保护与控制*, 2012, 40(17): 83-87.
GUO Yanping, YAN Wenjun, BAO Zhejing, et al. Fault diagnosis of bearing in wind turbine based on empirical mode decomposition and divergence index[J]. *Power System Protection and Control*, 2012, 40(17): 83-87.
- [7] 李东东, 周文磊, 郑晓霞, 等. 基于多重分形谱和支持向量机的风电机组行星齿轮箱故障诊断与研究[J]. *电力系统保护与控制*, 2017, 45(11): 43-48.
LI Dongdong, ZHOU Wenlei, ZHENG Xiaoxia, et al. Diagnosis and research of wind turbine planetary gearbox faults based on multifractal spectrum support vector machine (SVM)[J]. *Power System Protection and Control*, 2017, 45(11): 43-48.
- [8] WEI D, HAN T, CHU F, et al. Weighted domain adaptation networks for machinery fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2021, 158.
- [9] LIU R, YANG B, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: a review[J]. *Mechanical Systems and Signal Processing*, 2018, 108: 33-47.
- [10] 孔祥轩, 郑楚韬, 仇志成, 等. 基于广义深度学习的含 DG 配网故障诊断方法[J]. *电网与清洁能源*, 2020, 36(11): 53-57.
KONG Xiangxuan, ZHENG Chutao, QIU Zhicheng, et al. Fault location of distribution network with DG based on GDL[J]. *Power System and Clean Energy*, 2020, 36(11): 53-57.
- [11] 王挺韶. 基于深度学习的风力发电机故障诊断研究[D]. 广州: 华南理工大学, 2020.
WANG Tingshao. Researches on fault diagnosis of wind power systems using deep learning algorithms[D]. Guangzhou: South China University of Technology, 2020.
- [12] WEN L, LI X, GAO L, et al. A new convolutional neural

- network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [13] 常淼, 沈艳霞. 基于改进卷积神经网络的风电轴承故障诊断策略[J]. 电力系统保护与控制, 2021, 49(6): 131-137. CHANG Miao, SHEN Yanxia. Fault diagnosis strategy of a wind power bearing based on an improved convolutional neural network[J]. Power System Protection and Control, 2021, 49(6): 131-137.
- [14] JIANG G, HE H, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3196-3207.
- [15] 叶壮, 余建波. 基于多通道加权卷积神经网络的齿轮箱振动信号特征提取[J]. 机械工程学报, 2021, 57(1): 110-120. YE Zhuang, YU Jianbo. Feature extraction of gearbox vibration signals based on multi-channels weighted convolutional neural network[J]. Journal of Mechanical Engineering, 2021, 57(1): 110-120.
- [16] SAUFI S R, AHMAD Z A B, LEONG M S, et al. Gearbox fault diagnosis using a deep learning model with limited data sample[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6263-6271.
- [17] PU Z, LI C, ZHANG S, et al. Fault diagnosis for wind turbine gearboxes by using deep enhanced fusion network[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70.
- [18] MAO W, LIU Y, DING L, et al. A new structured domain adversarial neural network for transfer fault diagnosis of rolling bearings under different working conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70.
- [19] LI X, ZHANG W, DING Q, et al. Diagnosing rotating machines with weakly supervised data using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2020, 16(3): 1688-1697.
- [20] 李帷韬, 焦点, 张倩, 等. 基于深度迁移学习的玻璃绝缘子自爆状态智能认知方法研究[J]. 中国电机工程学报, 2020, 40(11): 3710-3721. LI Weitao, JIAO Dian, ZHANG Qian, et al. Research on intelligent cognition method of self-exploding state of glass insulator based on deep migration learning[J]. Proceedings of the CSEE, 2020, 40(11): 3710-3721.
- [21] LI Y, REN J, LIU J, et al. Deep sparse autoencoder prediction model based on adversarial learning for cross-domain recommendations[J]. Knowledge-Based Systems, 2021, 220.
- [22] 解颖, 王丰华, 傅正财. 基于栈式自编码器的变压器机械故障诊断[J]. 高压电器, 2020, 56(9): 46-53. XIE Ying, WANG Fenghua, FU Zhengcai. Mechanical fault diagnosis of power transformer based on stacked auto encoder[J]. High Voltage Apparatus, 2020, 56(9): 46-53.
- [23] 田昊洋, 马文嘉, 王丰华, 等. 基于稀疏自动编码器的特高压变压器可听噪声分析[J]. 高压电器, 2020, 56(9): 67-73. TIAN Haoyang, MA Wenjia, WANG Fenghua, et al. Research on audible noise of UHV power transformer based on sparse autoencoder[J]. High Voltage Apparatus, 2020, 56(9): 67-73.
- [24] WU Z, LI Q, XIA X. Multi-timescale forecast of solar irradiance based on multi-task learning and echo state network approaches[J]. IEEE Transactions on Industrial Informatics, 2021, 17(1): 300-310.
- [25] CHENG R, JIN Y. A competitive swarm optimizer for large scale optimization[J]. IEEE Transactions on Cybernetics, 2015, 45(2): 191-204.
- [26] 孟荣, 赵冀宁, 周通. 基于改进惯性权重粒子群算法的抢修小组快速调配策略[J]. 电网与清洁能源, 2021, 37(7): 17-24. MENG Rong, ZHAO Jining, ZHOU Tong. Rapid deployment strategy of emergency repair team based on improved inertial weighted PSO[J]. Power System and Clean Energy, 2021, 37(7): 17-24.
- [27] 陈仁祥, 黄鑫, 胡小林, 等. 多源信息深度融合的行星齿轮箱故障诊断方法[J]. 振动工程学报, 2020, 33(5): 1094-1102. CHEN Renxiang, HUANG Xin, HU Xiaolin, et al. Planetary gearbox fault diagnosis technique based on multi-source information deep fusion[J]. Journal of Vibration Engineering, 2020, 33(5): 1094-1102.

收稿日期: 2021-07-18; 修回日期: 2021-08-26

作者简介:

李东东(1976—), 男, 博士, 教授, 博士生导师, 研究方向为风力发电与电力系统稳定控制、智能用电; E-mail: powerlidd@163.com

赵阳(1997—), 男, 硕士研究生, 研究方向为风电机组行星齿轮箱故障诊断; E-mail: zhaoyang9704@foxmail.com

赵耀(1987—), 男, 通信作者, 博士, 副教授, 研究方向为电机设计与控制、电力系统稳定性分析。E-mail: nihaozhaoyao@163.com

(编辑 姜新丽)