

基于改进北方苍鹰算法与混合核极限学习机的齿轮箱故障诊断

杜董生^{1†}, 王梦姣¹, 冒泽慧², 赵环宇¹

(1. 淮阴工学院 自动化学院, 江苏 淮安 223003; 2. 南京航空航天大学 自动化学院, 江苏 南京 210016)

摘要: 针对行星齿轮箱故障诊断问题, 本文提出了一种基于改进北方苍鹰优化(INGO)算法与混合核极限学习机(HKELM)的行星齿轮箱故障诊断方法. 首先, 引入Savitzky-Golay(SG)滤波对齿轮箱原始信号进行去噪. 利用时变滤波经验模态分解(TVF-EMD)将去噪后的信号分解成多个本征模态函数(IMF), 使用方差贡献率、相关系数和信息熵筛选出最优的IMF. 将最优IMF重构后, 对重构信号进行时间同步平均(TSA)去噪以减少故障诊断模型的数据计算量. 将Tent混沌映射、混合正弦余弦算法和Levy飞行策略用于改进北方苍鹰优化(INGO)算法, 得到一种新的INGO算法. 同时, 引入余弦因子以平衡正弦余弦算法的全局和局部开发能力. 最后, 利用INGO算法对HKELM进行优化, 用以提高HKELM模型的故障诊断准确率. 将所提方法应用于两个案例对模型进行检验, 实验结果表明, 本文所提方法具有可行性和优越性.

关键词: 混合核极限学习机; 改进北方苍鹰优化算法; 时变滤波经验模态分解; 故障诊断

引用格式: 杜董生, 王梦姣, 冒泽慧, 等. 基于改进北方苍鹰算法与混合核极限学习机的齿轮箱故障诊断. 控制理论与应用, 2025, 42(4): 796 – 804

DOI: 10.7641/CTA.2023.30226

Gearbox fault diagnosis based on improved northern goshawk algorithm and hybrid core extreme learning machine

DU Dong-sheng^{1†}, WANG Meng-jiao¹, MAO Ze-hui², ZHAO Huan-yu¹

(1. College of Automation, Huaiyin Institute of Technology, Huai'an Jiangsu 223003, China;

2. College of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China)

Abstract: Aiming at the problem of planetary gearbox fault diagnosis, this paper proposes a fault diagnosis method of planetary gearbox based on the improved northern goshawk algorithm (INGO) and hybrid core extreme learning machine (HKELM). Firstly, savitzky-golay (SG) filtering is introduced to denoise the original signal of the gearbox. In addition, the time varying filtering empirical mode decomposition (TVF-EMD) is used to decompose the denoised signal into multiple intrinsic mode functions (IMF). And the variance contribution rate, correlation coefficient and information entropy are used to screen out the optimal IMFs. After the optimal IMFs are reconstructed, the reconstructed signal is denoised by time synchronization average (TSA) to reduce the data calculation amount of the fault diagnosis model. Secondly, INGO algorithm is obtained by applying Tent chaotic mapping, hybrid sine cosine algorithm and Levy flight strategy to improve the NGO algorithm. At the same time, the cosine factor is introduced to balance the global and local development capabilities of sine cosine algorithm. Finally, the INGO algorithm is used to optimize HKELM to improve the fault diagnosis accuracy of HKELM model. The proposed scheme is applied to two different public data sets to test the model, and the experimental results show that the proposed method is feasible and advantageous.

Key words: hybrid kernel extreme learning machine; improved northern goshawk algorithm; time varying filter based empirical mode decomposition; fault diagnosis

Citation: DU Dongsheng, WANG Mengjiao, MAO Zehui, et al. Gearbox fault diagnosis based on improved northern goshawk algorithm and hybrid core extreme learning machine. *Control Theory & Applications*, 2025, 42(4): 796 – 804

收稿日期: 2023-04-18; 录用日期: 2023-12-27.

†通信作者. E-mail: dshdu@163.com.

本文责任编辑: 宗群.

国家自然科学基金项目(61873107, 62333011), 江苏省青蓝工程中青年学术带头人项目资助.

Supported by the National Natural Science Foundation of China (61873107, 62333011) and the Qinglan Program to Cultivate Middle-aged and Young Science Leaders of Colleges and Universities of Jiangsu Province.

1 引言

行星齿轮箱是支持普通机械设备传动的关键部件。在实际运行过程中, 恶劣的工作环境极易导致其发生故障^[1-2]。故障的发生往往会引起相关机械部件的异常行为, 甚至破坏整个系统的安全运行。因此, 针对行星齿轮箱开展故障诊断技术研究对维持机械设备的安全运转和预防灾难性事故的发生具有重大意义^[3]。

行星齿轮箱振动信号存在非平稳性和非线性的特征, 从振动信号中提取故障特征较困难且不精确。因此, 如何有效提取反映其故障特征的指标信息是实现行星齿轮箱故障诊断的关键。常用的信号分解方法包括经验模态分解、完全集合经验模态分解、自适应噪声完全集合经验模态分解等。然而, 上述信号分解方法均无法同时解决信号的模式分离和噪声干扰问题, 不适用于非平稳信号的分解与故障特征提取。TVF-EMD算法^[4]具有完全自适应、稳定等优点, 可以有效应用于非平稳信号的特征提取。文献[5]对传统TVF-EMD中的参数组合进行了优化, 提取了更清晰和丰富的初始故障特征。文献[6]采用TVF-EMD技术, 有效的分解了分布式发电中测量的非平稳电压信号。本文将采用TVF-EMD方法对行星齿轮箱数据序列进行分解, 并利用方差贡献率、相关系数和信息熵技术对分解得到的本征模态函数 (intrinsic mode function, IMF) 分量进行重构, 精确提取故障特征数据, 并进一步提高故障诊断模型的运行速度, 节省实验时间。

深度学习技术通过采用叠加众多非线性隐藏层的方法, 具备了一体化的特征提取与状态分类功能^[7], 并被广泛应用于系统的故障诊断。文献[8]提出了基于贝叶斯判别分析和时间序列分析的旋转机械故障诊断方法, 解决了没有特征参数对并发故障类型提供一定程度判别信息的问题。文献[9]采用一种新的基于灵敏度分析的加权极限学习机, 得到旋转机械复合故障类别的最终推断。虽然深度学习在行星齿轮箱的故障诊断中有着良好的表现, 但其在故障分类过程中分类结果的好坏一定程度上取决于输入含标记的平衡数据的数量。但由于行星齿轮箱工作环境恶劣等原因, 通常较难获得大量含标记的平衡数据。因此, 对该类对象的故障诊断往往需要在小样本数据下进行。文献[10-11]将HKELM技术成功应用于液压系统和电路系统的小样本数据故障诊断。受此启发, 本文将引入HKELM方法构建一种新的行星齿轮箱故障诊断模型。一方面, HKELM是通过在极限学习机(ELM)^[12-13]中引入多核函数构造得到, 可以较好解决ELM存在的网络隐藏节点难以确定、阈值参数随机设定等缺点。另一方面, HKELM具有强大的学习能力和泛化性能, 可预防模型发生过拟合现象。

NGO^[14]算法模拟了自然界中北方苍鹰的捕食行

为, 具有结构简单、收敛速度快等优点, 在优化模型参数方面表现优异。文献[15]将NGO算法用于优化变分模态分解(variational mode decomposition, VMD)的参数, 通过对实验数据集进行故障诊断, 结果表明NGO算法具有较强的参数寻优能力。但NGO算法在运行过程中也容易出现陷入局部最优等缺点。为解决此问题, 本文提出一种将Tent混沌映射、混合正弦余弦算法和Levy飞行策略引入到NGO算法中, 构造一种新的北方苍鹰优化(improved NGO, INGO)模型。为了进一步提高故障诊断模型的诊断精度, 本文利用INGO优化HKELM核函数中的加权系数等参数, 提出一种新的基于INGO-HKELM方法的行星齿轮箱故障诊断模型。

综上, 本文提出了一种基于HKELM的行星齿轮箱故障诊断新技术。首先针对行星齿轮箱原始信号存在噪声和虚假分量问题, 对其进行去噪、分解和重构, 增强了信号特征表达的能力。其次, 基于INGO-HKELM方法构建了系统的故障诊断模型, 有效的提高了故障诊断精度。最后通过仿真实验与其他故障诊断模型相比较, 验证了本文所提方法的有效性和优越性。

2 理论知识介绍

2.1 Savitzky-Golay滤波

针对行星齿轮箱信号存在较多不同频率的噪声问题, 本文采用SG滤波进行信号去噪。Savitzky-Golay (SG)滤波利用局部最小二乘多项式逼近方法来平滑信号, 具有计算量小、能更好地保留原始信号的宽度和峰值、同时降低不同频率的噪声等优点。同时, 在滤波的执行过程中, 使用最小平方准则来获得最小误差和最佳拟合值^[16]。

设 $\{x(n)\}$ 表示原始信号的一组样本。通过选择以 $n=0$ 为中心的 $2M+1$ 个样本, 可以构造一个 n 阶多项式来拟合这组数据, 即

$$f(n) = \sum_{k=0}^j c_k n^k, \quad (1)$$

其中处理后的数据和原始数据之间的误差为

$$E = \sum_{n=-M}^M (f(n) - x(n))^2, \quad (2)$$

进一步解为

$$\begin{cases} f(n)|_{n=0} = 0!c_{j0} = d_{j0}, \\ \frac{df(n)}{dn}|_{n=0} = 1!c_{j1} = d_{j1}, \\ \vdots \\ \frac{d^j f(n)}{dn^j}|_{n=0} = j!c_{jj} = d_{jj}, \end{cases} \quad (3)$$

式中 d_{j0} 为原始数据的有限脉冲响应 (finite impulse response, FIR) 滤波器。此时, SG平滑公式为

$$Y^* = \frac{z_n}{H} \sum_{n=-M}^M x(n+j), \quad (4)$$

式中: Y^* 为时间序列数据的拟合值, $\frac{z_n}{H}$ 为平滑系数.

2.2 时变滤波经验模态分解

2.2.1 TVF-EMD定义

行星齿轮箱原始信号经去噪后含噪信号被有效减少,但信号故障特征不明显问题仍需进一步处理. TVF-EMD的引入可以解决这一难题.

TVF-EMD的过程可分为3个阶段: 1) 找出局部截止频率; 2) 筛选输入信号; 3) 判断信号是否满足停止标准. 每个阶段具体实施过程如下:

1) 找出局部截止频率.

步骤1 利用希尔伯特变换计算输入信号 $X(t)$ 的瞬时振幅 $A(t)$ 和瞬时频率 $B(t)$, 即

$$A(t) = \sqrt{X(t)^2 + \tilde{X}(t)^2}, \quad (5)$$

$$B(t) = \frac{d(\arctan \frac{\tilde{X}(t)}{X(t)})}{dt}, \quad (6)$$

式中 $\tilde{X}(t)$ 为 $X(t)$ 的希尔伯特变换;

步骤2 计算 $A(t)$ 的局部极大值和极小值并对其进行插值, 分别得到瞬时均值 $\beta_1(t)$, $\beta_2(t)$ 和包络 $a_1(t)$, $a_2(t)$;

步骤3 计算 $A(t)$ 的局部极大值和极小值的瞬时频率插值 $\mu_1(t)$, $\mu_2(t)$ 和瞬时频率分量, 即

$$\varphi'_1(t) = \frac{\mu_1(t)}{2(a_1^2(t) - a_1(t)a_2(t))} + \frac{\mu_2(t)}{2(a_1^2(t) + a_1(t)a_2(t))}, \quad (7)$$

$$\varphi'_2(t) = \frac{\mu_1(t)}{2(a_2^2(t) - a_1(t)a_2(t))} + \frac{\mu_2(t)}{2(a_2^2(t) + a_1(t)a_2(t))}; \quad (8)$$

步骤4 计算如下局部截止频率:

$$\varphi'(t) = \frac{\varphi'_1(t) + \varphi'_2(t)}{2}; \quad (9)$$

步骤5 在频率峰值之间进行插值, 以重新调整局部截止频率.

2) 基于时变滤波筛选输入信号, 以获得局部均值函数.

步骤1 计算信号 $k(t) = \cos[\int \varphi'(t)dt]$. 此时, $k(t)$ 的极值点由构造TVF的节点给出;

步骤2 用B样条插值逼近 $X(t)$.

3) 计算信号是否满足停止标准 $\theta(t)$.

$\theta(t)$ 定义如下:

$$\theta(t) = \frac{B_L(t)}{\varphi_a(t)}, \quad (10)$$

式中: $B_L(t)$ 为信号的Loughlin瞬时带宽, $\varphi_a(t)$ 为单个分量的加权平均瞬时频率.

2.2.2 TVF-EMD筛选准则

TVF-EMD处理后的行星齿轮箱信号中存在一些虚假的IMF分量. 为了减少数据运算量, 提高算法运行效率, 本文构建基于方差贡献率、相关性和信息熵的综合评价模型, 相较于传统的相关系数和方差贡献率等准则, 该模型可以更加综合地筛选出较优IMF.

1) 方差贡献率.

$$M_i = \frac{\frac{1}{N} \sum_{k=1}^N (h_{ik})^2 - (\frac{1}{N} \sum_{k=1}^N h_{ik})^2}{\sum_{i=1}^n [\frac{1}{N} \sum_{k=1}^N (h_{ik})^2 - (\frac{1}{N} \sum_{k=1}^N h_{ik})^2]}, \quad (11)$$

式中: h_{ik} 为第 i 个IMF分量, N 为信号的数据编号, l_k 为信号的第 k 个数据点, \bar{l} 为信号的均值, \bar{h}_i 为第 i 个IMF分量的均值.

2) 相关系数.

$$\rho_i = \frac{\sum_{k=1}^N (l_k - \bar{l})(h_{ik} - \bar{h}_i)}{\sqrt{\sum_{k=1}^N (l_k - \bar{l})^2 \sum_{k=1}^N (h_{ik} - \bar{h}_i)^2}}. \quad (12)$$

3) 信息熵.

信息熵在处理不相关的特征数据方面表现优异, 本文通过引入信息熵进一步计算IMF中不相关的特征数据, 使筛选出的IMF更具代表性. 信息熵定义如下:

$$Q(x) = - \sum_{i=1}^N R(Y_i) \log(R(Y_i)), \quad (13)$$

式中: 离散变量 Y 用来表示不确定系统的状态特征, Y_i 是随机事件, Y_i 对应的概率为 P_i , P_i 是随机事件的概率, 并且 $\sum_{i=1}^n P_i = 1$.

将计算出的相关系数、方差贡献率和信息熵进行加权求和, 得到综合筛选指标值 K , 即

$$K = a_1 M_i + a_2 \rho_i + a_3 H(x), \quad (14)$$

式中 a_1 , a_2 和 a_3 分别为IMF分量的方差贡献率、相关系数和信息熵的权重值.

2.3 时间同步平均技术

TSA是一种可以从噪声信号中分离出信号周期性波形的技术^[17], 可以减少模型的数据计算量, 提高其故障诊断效率. TSA根据相位信息对其所划分的不同段上的振动信号进行平均, 并计算分段的总平均值. 具体实现步骤如下:

采样振动信号 $a(k)$ 由特征信号 $b(k)$ 和白噪声 $b_n(k)$ 组成, 即

$$a(k) = b(k) + b_n(k). \quad (15)$$

利用白噪声不相干的原理, 将 S 段信号相加以获得

$$\sum_{s=1}^S a_s(k') = Sb(k') + \sqrt{S}b_n(k'). \quad (16)$$

设输出信号为

$$a'(k') = \frac{1}{S} \sum_{s=1}^S a_s(k'). \quad (17)$$

则上述公式整理可得

$$a'(k') = b(k') + \frac{1}{\sqrt{S}}b_n(k'). \quad (18)$$

2.4 混合内核极限学习机

1) 极限学习机: 与传统具有大量参数的神经网络不同, ELM在运行过程中只需要调整隐藏层节点的数量. 因此, ELM具有更快的运行速度和更好的学习性能, 并且其在故障诊断领域效果良好且得到广泛应用.

ELM的激活函数为 $g(w_i x_i + b_i)$, 其中: w_i 为输入层第 i 个节点的权值; b_i 表示隐藏层第 i 个节点的偏置. 则隐藏层节点的输出矩阵 $H(x)$ 为

$$H(x) = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_m x_1 + b_m) \\ \vdots & & \vdots \\ g(w_1 x_n + b_1) & \cdots & g(w_m x_n + b_m) \end{bmatrix}_{n \times m}. \quad (19)$$

ELM模型表示如下:

$$f(x) = \beta H(x), \quad (20)$$

β 为隐藏层和输出层之间的权重, 其计算公式为

$$\beta = H^\dagger T, \quad (21)$$

式中 T 为训练数据的标签; 令 H 为隐藏层的输出矩阵, H^\dagger 为 H 的Moore-Penrose广义逆矩阵, 即

$$H^\dagger = H^T (HH^T + \frac{1}{C})^{-1}, \quad (22)$$

式中 C 为正则化系数. 进一步可得, ELM的表达式为

$$f(x) = HH^T (HH^T + \frac{1}{C})^{-1} T. \quad (23)$$

然而, ELM隐藏层节点的错误选取会导致算法出现运行结果不稳定等缺陷. 为了解决这些问题, 将核函数 $k(\cdot)$ 引入到ELM中, 得到具有更强稳定性和泛化能力的核极限学习机 (ernel ELM, KELM), 其计算公式如下:

$$f(x) = \begin{bmatrix} k(x, x_1) \\ \vdots \\ k(x, x_N) \end{bmatrix} \left(\frac{1}{C} + HH^T \right)^{-1} T. \quad (24)$$

2) 混合核函数: KELM中多个核函数的组合构成了HKELM. 常见的核函数分为全局核函数和局部核函数. 多项式核函数^[18]作为经典的全局核函数可以较

好地获得远处数据点的全局信息, 而以径向基函数 (radial basis function, RBF)为代表的局部核函数能够有效提取数据点的局部信息.

多项式核函数为

$$K_{\text{Poly}}(x_i, x_j) = (x_i, x_j + c)^d, \quad (25)$$

式中 d 和 c 分别为多项式核的核参数.

RBF核函数为

$$K_{\text{RBF}}(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\delta^2}\right), \quad (26)$$

式中 δ 为RBF核的核参数.

将以上两个核函数组合得到的混合函数公式的表达式如下:

$$K_{\text{hybrid}} = wK_{\text{Poly}}(x_i, x_j) + (1-w)K_{\text{RBF}}(x_i, x_j), \quad (27)$$

式中 w 为权重系数, 且 $w \in [0, 1]$.

2.5 改进的北方苍鹰算法

2.5.1 NGO算法模型

北方苍鹰捕获猎物的两个主要阶段包括: 猎物搜索与识别阶段和追逐与逃跑阶段. NGO根据不同狩猎阶段建立的数学模型如下:

1) 猎物搜索和识别.

北方苍鹰随机选择一个猎物后迅速展开攻击. 为了获得最优攻击区域的信息, 算法采用全局搜索的方法, 位置更新公式如下所示:

$$x_{i,j}^{\text{new}, P_1} = \begin{cases} x_{i,j} + q(p_{i,j} - ex_{i,j}), & F_{P_i} < F_i, \\ x_{i,j} + q(x_{i,j} - p_{i,j}), & F_{P_i} \geq F_i, \end{cases} \quad (28)$$

$$X_i = \begin{cases} X_i^{\text{new}, P_1}, & F_i^{\text{new}, P_1} < F_i, \\ X_i, & F_i^{\text{new}, P_1} \geq F_i, \end{cases} \quad (29)$$

$$P_i = X_k, \quad i = 1, 2, \dots, n, \quad k = 1, 2, \dots, n, \quad (30)$$

式中: P_i 为第 i 只苍鹰对应的猎物所处的位置, $p_{i,j}$ 为第 j 维中第 i 只苍鹰对应的猎物所处的位置, k 为 $[1, n]$ 之间的随机数; F_{P_i} 为算法的适应度值, F_i 为第 i 个适应度函数的解; X_i^{new, P_1} 为第 i 只北方苍鹰的新状态, $x_{i,j}$ 为第 j 维中第 i 只苍鹰的值, $x_{i,j}^{\text{new}, P_1}$ 为第 j 维中第 i 只苍鹰的新解, F_i^{new, P_1} 为新解对应的目标函数值; q 为区间 $[1, 2]$ 中的随机数, e 的值为1或2.

2) 追逐和逃跑行动.

猎物受到攻击后试图逃跑, 在这种情况下, 对苍鹰追逐猎物行为的模拟提高了算法拓展局部搜索空间的能力. 假设猎物在半径为 r 的攻击范围内, 则位置更新数学模型表示为

$$X_{i,j}^{\text{new}, P_2} = x_{i,j} + r(2q - 1)x_{i,j}, \quad (31)$$

$$r = 0.02\left(1 - \frac{t}{T}\right), \quad (32)$$

$$X_i = \begin{cases} X_i^{\text{new}, P_2}, & F_i^{\text{new}, P_2} < F_i, \\ X_i, & F_i^{\text{new}, P_2} \geq F_i, \end{cases} \quad (33)$$

式中: t 和 T 分别为算法迭代次数和最大迭代次数; r 随着迭代次数的增加而减小; X_i^{new, P_2} 为第 i 个苍鹰的新状态, 它的第 j 维为 $x_{i,j}^{\text{new}, P_2}$; F_i^{new, P_2} 为这个阶段目标函数值.

2.5.2 改进的NGO算法

通过以上求解过程, NGO具有较高的收敛精度和较好的稳定性, 但是仍然存在很多局限性:

1) 在初始化种群过程中, 会产生更多随机分布和不均匀的初始解, 容易降低种群的多样性, 导致算法无法找到最优解.

2) 在搜索的时候, 个体苍鹰的每一个维度都在减少, 逐渐缩小了搜索空间, 增加了算法陷入局部空间的概率.

3) 北方苍鹰以很大的速度追逐逃跑的猎物, 导致算法后期搜索速度过快, 使算法陷入局部最优.

针对上述问题, 本文分别采用Tent混沌映射、混合正弦余弦算法和Levy飞行策略对NGO算法进行了改进.

1) Tent混沌映射.

混沌映射用于增强初始解的遍历性和均匀性, 提高算法的全局搜索能力. 因此, 本文使用Tent混沌映射初始化北方苍鹰的种群个体. 其公式描述如下:

$$x_{i+1} = \begin{cases} \frac{x_i}{A}, & 0 \leq x_i < A, \\ \frac{1-x_i}{1-A}, & A \leq x_i < 1, \end{cases} \quad (34)$$

式中 A 为控制参数, 且 $A \in (0, 0.5)$.

2) 混合正弦余弦算法.

正弦余弦算法利用正弦余弦函数的思想来完成对搜索空间的全局探索和局部拓展. 此外, 余弦因子的引入有助于提高算法局部开发能力, 避免算法陷入局部最优风险. 余弦因子数学公式以及改进的苍鹰位置表达式如下:

$$\omega = \cos\left(\pi \frac{t^3}{T^3}\right)(\omega_{\max} - \omega_{\min}) + \omega_{\min}, \quad (35)$$

$$x_{i,j}^{\text{new}, P_3} = \begin{cases} (1-\omega)x_{i,j} + \omega \cdot \sin r_1(r_2 p_{i,j} - x_{i,j}), & F_{P_i} < F_i, \\ (1-\omega)x_{i,j} + \omega \cdot \cos r_1(x_{i,j} - r_2 p_{i,j}), & F_{P_i} \geq F_i, \end{cases} \quad (36)$$

式中: $r_1 \in [0, 2\pi]$, $r_2 \in [0, 2]$.

3) Levy飞行策略.

Levy飞行策略是数学家Levy提出的一种概率分布

模型, 它遵循Levy分布并执行随机搜索操作. 在本研究中, 利用Levy飞行策略更新算法当前最优解, 扩大了苍鹰种群搜索范围, 也有助于算法跳出局部最优解. Levy飞行的计算公式如下:

$$\text{Levy}(\beta) = \frac{\mu}{|\lambda|^{\frac{1}{\beta}}}, \quad (37)$$

式中: $\beta \in (0, 2)$; μ 和 λ 为方向向量, 分别服从 $N(0, \sigma^2)$ 和 $N(0, 1)$ 分布.

$$\sigma = \left\{ \frac{\Gamma(1+\beta) \sin \frac{\pi\beta}{2}}{\beta \Gamma\left(\frac{1+\beta}{2}\right) \cdot 2^{\frac{\beta-1}{2}}} \right\}^{\frac{1}{\beta}}, \quad (38)$$

式中 $\Gamma(x) = (x-1)!$.

在第1阶段, 利用Levy飞行策略更新的苍鹰位置表示如下:

$$X_i = \begin{cases} X_i^{\text{new}, P_3}, & F_i^{\text{new}, P_3} < F_i, \\ x_{i,j} + x_{i,j} \cdot \text{Levy}(\beta), & F_i^{\text{new}, P_3} \geq F_i. \end{cases} \quad (39)$$

在第2阶段, 利用Levy飞行策略更新的苍鹰位置表示如下:

$$X_i = \begin{cases} x_{i,j} + r(2q-1)x_{i,j}, & F_i^{\text{new}, P_2} < F, \\ x_{i,j} + x_{i,j} \cdot \text{Levy}(\beta), & F_i^{\text{new}, P_2} \geq F_i. \end{cases} \quad (40)$$

2.6 INGO-HKELM

Tent混沌映射用于初始化NGO的种群; 将余弦因子引入到正弦余弦算法中, 构造了混合正弦余弦算法, 并用此混合算法来完成对NGO搜索空间的全局探索和局部拓展; Levy飞行的加入有助于NGO算法跳出局部最优解. 在ELM中加入混合核函数得到HKELM模型, 提高了ELM的泛化性能和学习能力. 最后, 建立了INGO-HKELM模型, 具体实现步骤如下:

步骤 1 初始化苍鹰总数 n 和迭代次数 T ;

步骤 2 Tent混沌映射初始化苍鹰种群;

步骤 3 计算每个苍鹰个体的目标适应值;

步骤 4 使用混合正弦余弦算法, 在其中引入余弦因子, 根据式(36)更新第1阶段的最优解;

步骤 5 确定 j 的值是否等于问题变量 m , 如果是, 则引入Levy飞行策略, 根据等式(39)更新第 i 只苍鹰的位置, 否则 $j = j + 1$, 返回步骤4;

步骤 6 根据式(31)–(32), 更新第2阶段的最优解;

步骤 7 确定 j 的值是否等于问题变量 m , 如果是, 则引入Levy飞行策略, 根据式(40)更新第 i 只苍鹰的位置, 否则 $j = j + 1$, 返回步骤6;

步骤 8 检查算法是否满足最大迭代次数. 如果是, 导出NGO得到的最优解; 否则, 重复步骤4–7;

步骤9 建立基于INGO算法的优化HKELM模型.

2.7 混合诊断模型框架

SG-TVF-EMD-TSA-INGO-HKELM模型的流程图如图1所示, 模型具体实现流程如下:

- 1) 信号处理: a) 收集齿轮箱原始信号作为数据源; b) 使用SG去除原始信号噪声; c) TVF-EMD用于分解

去噪后的信号, 方差贡献率、相关系数和信息熵用于重构IMF分量; d) 使用TSA对重构信号进行去噪.

- 2) 建模: a) 利用Tent混沌映射、混合正弦余弦算法和Levy飞行策略对INGO进行改进; b) 引入混合核函数提高ELM的稳定性, 得到HKELM模型; INGO优化HKELM; c) SG-TVF-EMD-TSA-INGO-HKELM用于诊断齿轮箱故障.

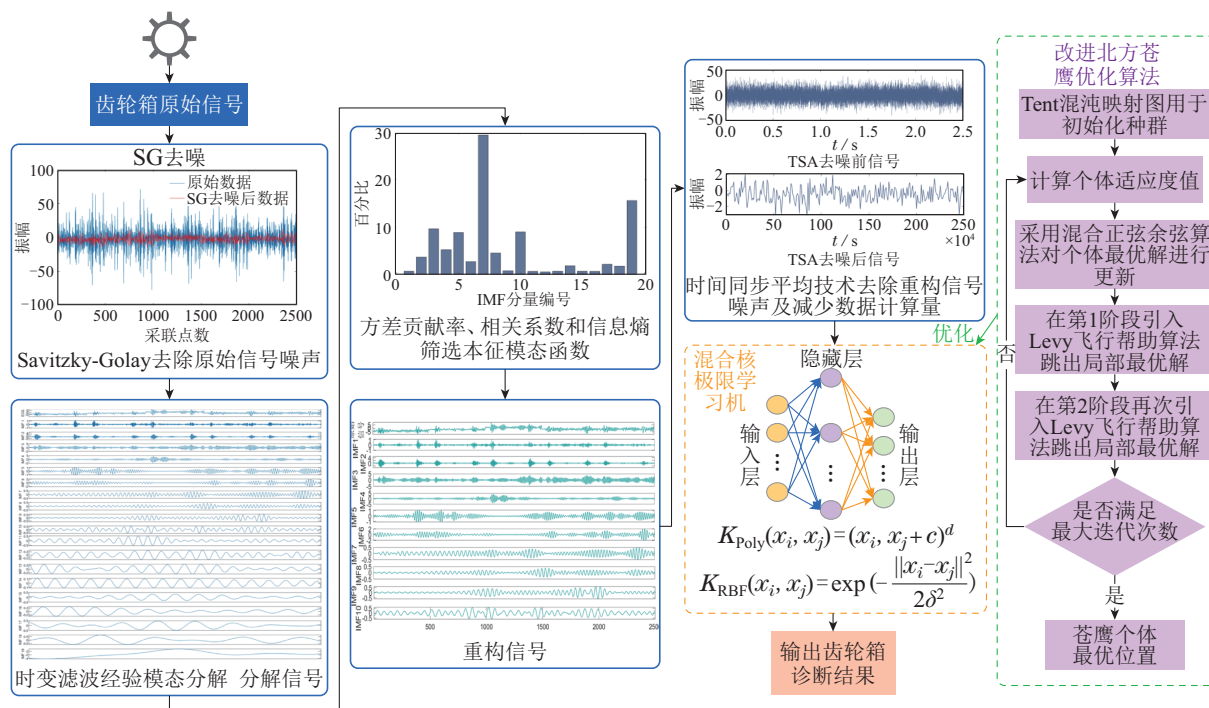


图1 所提模型的流程图

Fig. 1 Flowchat of the proposed model

3 实验分析

3.1 数据描述

- 1) 案例1: 变电流行星齿轮箱数据集.

本案例使用的数据分别是行星齿轮箱实验平台在0.1 A和0.05 A电流条件下采集^[19], 分别用缩写880-1和880-2表示. 其中, 每种负载电流下的数据含有磨损故障、断齿故障、点蚀故障、断齿和磨损故障以及正常5种不同状态, 分别标记为1, 2, 3, 4和5. 数据集由80%的训练集数据和20%的测试集数据组成. 表1列出了本案例齿轮箱数据集的详细描述.

- 2) 案例2: 变工况行星齿轮箱数据集.

为了进一步验证本文所提模型的优越性, 本案例采用东南大学驱动系统动力学模拟器(DDS)不同工况下收集的行星齿轮箱实验数据进行测试^[20]. 数据集分别是行星齿轮箱负载为20Hz-0V和30Hz-2V的两种不同工况下采集, 包括磨损、缺齿、齿根断裂、齿面点蚀以及正常5种状态, 分别被标记为1, 2, 3, 4和5. 数据集前80%的实验值用于训练, 后20%的实验值用于测试.

本案例数据集的详细描述如表2所示.

表1 变电流行星齿轮箱数据

Table 1 Date of variable current planetary gearbox

行星齿轮箱状态	加载电流/A	样本数量	缩写	标签
磨损故障	0.1	240/60	880-1	1
	0.05	260/40	880-2	
断齿故障	0.1	240/60	880-1	2
	0.05	260/40	880-2	
点蚀故障	0.1	260/40	880-1	3
	0.05	260/40	880-2	
断齿和磨损故障	0.1	260/40	880-1	4
	0.05	260/40	880-2	
正常	0.1	260/40	880-1	5
	0.05	260/40	880-2	

3.2 信号预处理

以880-1处的磨损数据为例. 图1中SG去噪图展示了经过SG去噪前后信号的波形分布, 可以看出经过SG处理后, 信号的振幅大大降低且曲线更加平滑, 这说明SG可以有效降低信号中的噪声.

表2 变工况行星齿轮箱数据

Table 2 Data of variable working condition planetary gearbox

齿轮箱状态	试验工况	样本数量	标签
磨损故障	20 Hz-0 V; 30 Hz-2 V	240/60	1
缺齿故障	20 Hz-0 V; 30 Hz-2 V	240/60	2
齿根断裂故障	20 Hz-0 V; 30 Hz-2 V	240/60	3
齿面点蚀故障	20 Hz-0 V; 30 Hz-2 V	240/60	4
正常	20 Hz-0 V; 30 Hz-2 V	240/60	5

采用TVF-EMD技术对降噪后的信号进行分解. 通过分解, SG去噪后的齿轮箱数据被分解成19个IMF分量, 结果如图1所示. 采用方差贡献率、相关系数和信息熵重构IMF, 以减少IMF中虚假分量的存在. 表3列出了每个IMF分量的综合筛选指数值. 可以看出, 不同IMF分量的指数值存在明显差异, 指数值越小说明其含有信号特征越少. 图1中方差贡献率、相关系数和信息熵计算之和图更加直观的展示了不同IMF的指数值的大小. 此外, 从图1中重构信号图可以看出, 在重构19个IMF分量之后, 最终选择了10个分量.

图1中TSA去噪信号图展示了对重构信号进行TSA去噪后的结果, 从图中可以看出经过TSA降噪后信号的白噪声明显下降, 说明该方法去噪效果显著.

表4 不同算法的数据处理结果

Table 4 Data processing results of different algorithms

模型	HKELM	SG-HKELM	SG-EMD-HKELM	SG-TVF-EMD-HKELM	SG-TVF-EMD-TSA-HKELM
880-1 准确率	81.67%	83.33%	86.67%	88.33%	91.67%
880-2 准确率	76.67%	80%	83.33%	85%	86.67%

为了进一步验证INGO-HKELM模型的泛化能力, 将其分别与BP, ELM, GWO-ELM, SSA-ELM, SSA-HKELM, HKELM和NGO-HKELM模型在两种不同案例下共计4组齿轮箱数据上进行实验对比, 所有实验数据都经过SG-TVF-EMD-TSA方法预处理. 本文以故障诊断准确率为模型评价指标, 对不同模型的性能进行测评.

1) 案例1: 变电流行星齿轮箱故障诊断.

以880-1数据为例, 表5分别列出了基于变电流条件下行星齿轮箱数据的本文所提模型和其他7个模型的故障诊断精度. 图2是各个模型的诊断结果图, 横轴为样本数量, 纵轴为故障类型. 由图2和表5可知, BP的准确率最低, 为70%, 而ELM的准确率相较于BP提高了11.76%. GWO-ELM, SSA-ELM和SSA-HKELM的准确率分别为85%, 88.33%和93.33%, 表明对基准模型进行优化是有必要的. HKELM模型的准确率比ELM高出10%, 可见本文用HKELM代替ELM作为基准模型是正确的选择. 另外, NGO-HKELM的故

4 实验结果分析

为了证明本文所提SG-TVF-EMD-TSA算法的优越性, 选择HKELM算法作为对比实验的基准模型, 将其分别与SG, SG-EMD, SG-TVF-EMD和SG-TVF-EMD-TSA不同模型对880-1和880-2的信号数据进行了对比实验, 结果如表4所示. 从表中可以看出, SG-TVF-EMD-TSA算法获得最高的故障诊断率, 说明该算法与其他算法相比具有更好的数据处理性能.

表3 不同IMF分量的综合筛选指数值

Table 3 Comprehensive screening index values of different IMF components

IMF分量	指标值	IMF分量	指标值
IMF1	0.790	IMF11	0.712
IMF2	3.729	IMF12	0.617
IMF3	9.697	IMF13	0.783
IMF4	5.287	IMF14	1.862
IMF5	8.900	IMF15	0.755
IMF6	2.785	IMF16	0.709
IMF7	29.328	IMF17	2.178
IMF8	4.566	IMF18	1.820
IMF9	0.866	IMF19	15.625
IMF10	8.989		

障诊断准确率较HKELM有明显提升, 而其准确率比SSA-HKELM提升了1.67%, 说明INGO-HKELM模型的故障诊断性能整体优于SSA-HKELM, 并且明显提升了HKELM的故障诊断能力. 而INGO-HKELM的故障诊断准确率达到100%, 优于其他对比模型. 由此可知, INGO-HKELM模型可以较好的实现行星齿轮箱的故障诊断.

表5 变电流行星齿轮箱诊断精度

Table 5 Diagnosis results of variable current gearbox

模型	880-1准确率/%	880-2准确率/%
BP	73.33	68.33
ELM	83.33	81.67
GWO-ELM	86.67	85
SSA-ELM	85	80
SSA-HKELM	88.33	88.33
HKELM	86.67	81.67
NGO-HKELM	90	91.67
INGO-HKELM	100	96.67

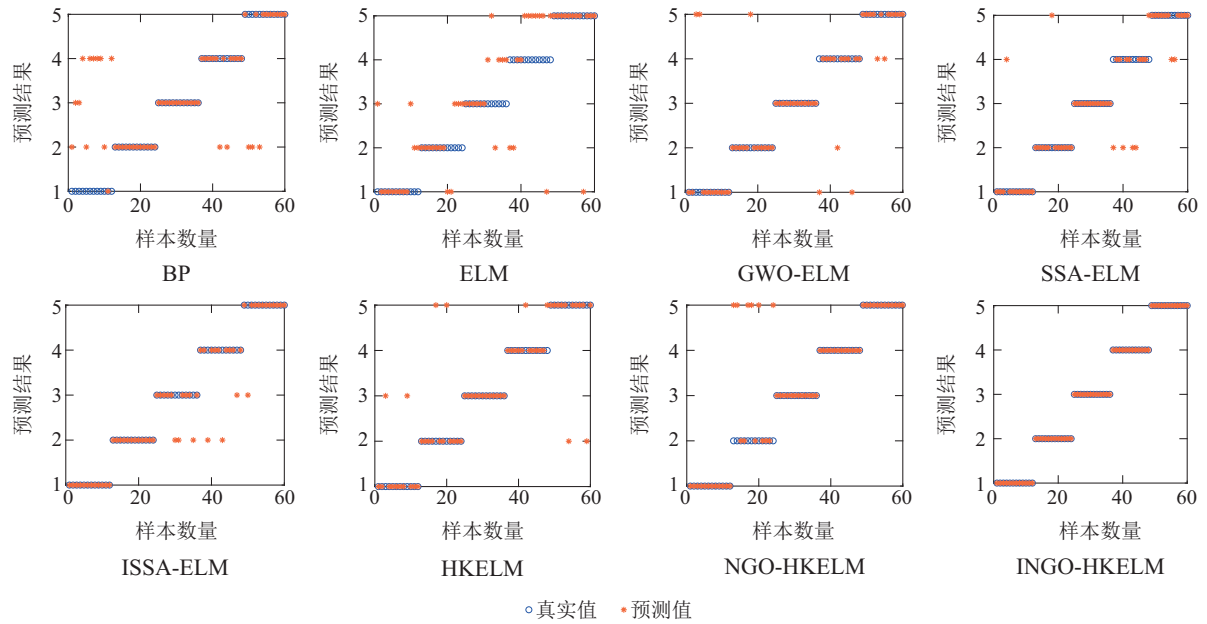


图 2 各个模型故障诊断结果(880-1)

Fig. 2 Fault diagnosis results of each model (880-1)

880-2的测试结果达到了880-1测试结果的相似水平, 其诊断结果如图3所示. 其中, NGO-HKELM模型的故障诊断结果明显优于HKELM和SSA-HKELM模型, 进一步验证了NGO优化算法的优越性, 并且INGO-HKELM模型的诊断精度是最优的. 由以上分析可知, INGO-HKELM模型相较于本文所提到的替代模型, 对行星齿轮箱故障诊断存在明显优势.

2) 案例2: 变工况行星齿轮箱故障诊断.

为了进一步证明本文所提模型的普适性, 本案例使用与变电流行星齿轮箱数据相同的故障诊断模型进行实验. 表6显示了不同模型的故障诊断结果. 由

表6可知, HKELM的诊断准确率相较于传统ELM模型有明显的提升. 并且, 同其他诊断模型相比, NGO-HKELM的诊断准确率仅低于INGO-HKELM, 验证了NGO具有较强的优化能力, 可以提高HKELM模型的稳定性. 此外, 由表6中结果可以了解到, 大多数模型不能很好地进行故障诊断, 这表明实施故障诊断是一项具有挑战性的任务. 然而, 无论何种行星齿轮箱故障类型, INGO-HKELM的诊断准确率都高于其他模型, 其对所有故障的诊断准确率达到100%. 说明INGO-HKELM模型的诊断能力几乎不受复杂环境的影响, 进一步验证了所提出的模型具有较强的普适性.

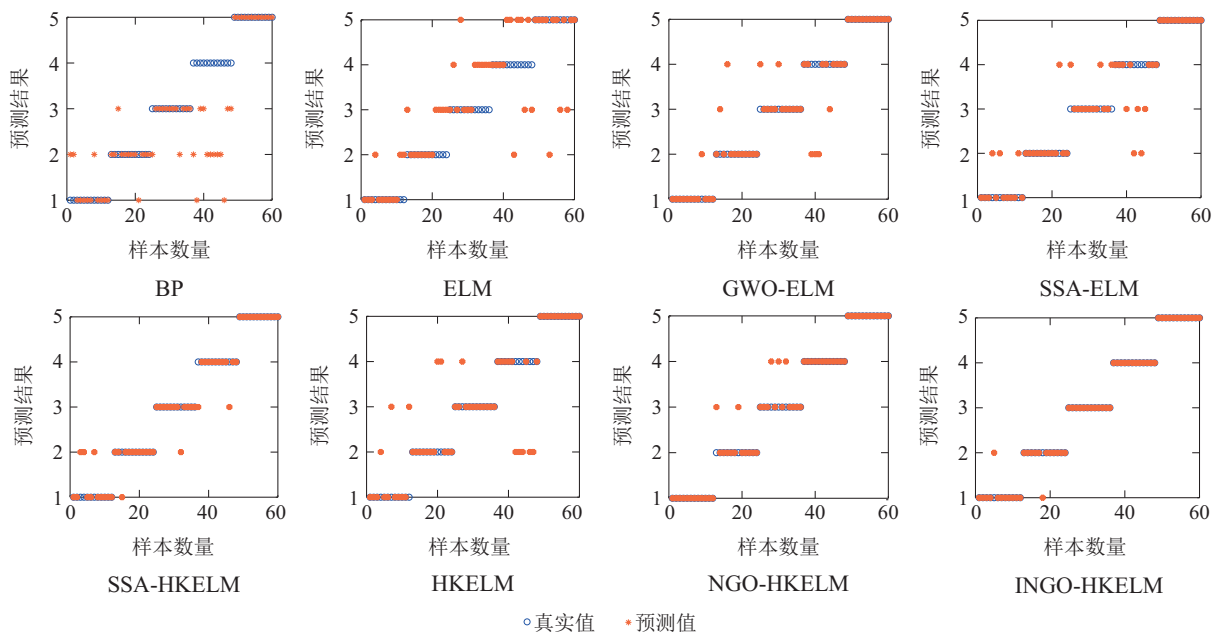


图 3 各个模型故障诊断结果(880-2)

Fig. 3 Fault diagnosis results of each model (880-2)

表6 变工况行星齿轮箱诊断结果

Table 6 Diagnosis result of variable working condition gearbox

模型	20HZ-0V准确率/%	30HZ-2V准确率/%
BP	86.67	76.67
ELM	86.67	80
GWO-ELM	88.33	86.67
SSA-ELM	90	91.67
SSA-HKELM	93.33	95
HKELM	88.33	86.67
NGO-HKELM	96.67	95
INGO-HKELM	100	100

5 结论

本文针对行星齿轮箱的故障诊断问题,提出了一种新的INGO-HKELM的故障诊断模型.首先,通过SG, TVF-EMD, TSA方法将信号去噪、分解和重构融为一体,实现对行星齿轮箱原始信号的有效处理.其次,采用HKELM分类器效果明显好于ELM分类器,且INGO的寻优能力相较NGO有显著提升.最后,通过与多种模型实验对比可知,本文所提出的SG-TVF-EMD-TSA-INGO-HKELM模型具有更优的诊断性能.本文为行星齿轮箱故障诊断提供了一种新的可行方案,具有较高的实际应用价值,并可推广至其他机械设备的故障诊断.

参考文献:

- [1] GONG Wenfeng, CHEN Hui, ZHANG Meiling, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning. *Chinese Journal of Scientific Instrument*, 2020, 41(1): 198 – 208.
(宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法. *仪器仪表学报*, 2020, 41(1): 198 – 208.)
- [2] SHAO H, JIANG H, LIN Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders. *Mechanical Systems and Signal Processing*, 2018, 102: 278 – 297.
- [3] GAO Z, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques—Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757 – 3767.
- [4] QIN Na, JIN Weidong, HUANG Jin, et al. Ensemble empirical mode decomposition and fuzzy entropy in fault feature analysis for highspeed train bogie. *Control Theory & Applications*, 2014, 31(9): 1245 – 1251.
(秦娜, 金炜东, 黄进, 等. 高速列车转向架故障信号的聚合经验模态分解和模糊熵特征分析. *控制理论与应用*, 2014, 31(9): 1245 – 1251.)
- [5] YE X, HU Y, SHEN J, et al. An adaptive optimized TVF-EMD based on a sparsity-impact measure index for bearing incipient fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1 – 11.
- [6] CHAITANYA B K, YADAV A, PAZOKI M. An advanced signal decomposition technique for islanding detection in DG system. *IEEE Systems Journal*, 2021, 15(3): 3220 – 3229.
- [7] LI S, WANG H, SONG L, et al. An adaptive data fusion strategy for fault diagnosis based on the convolutional neural network. *Measurement*, 2020, 165: 108122.
- [8] QIN A, HU Q, LV Y, et al. Concurrent fault diagnosis based on bayesian discriminating analysis and time series analysis with dimensionless parameters. *IEEE Sensors Journal*, 2019, 19(6): 2254 – 2265.
- [9] ZHANG J, ZHANG Q, HE X, et al. Compound-fault diagnosis of rotating machinery: A fused imbalance learning method. *IEEE Transactions on Control Systems Technology*, 2021, 29(4): 1462 – 1474.
- [10] LIU J, XU H Y, PENG X Y, et al. Reliable composite fault diagnosis of hydraulic systems based on linear discriminant analysis and multi-output hybrid kernel extreme learning machine. *Reliability Engineering & System Safety*, 2023, 234: 109178.
- [11] WANG S D, LIU Z B, JIA Z, et al. Incipient fault diagnosis of analog circuit with ensemble HKELM based on fused multi-channel and multi-scale features. *Engineering Applications of Artificial Intelligence*, 2023, 117: 105633.
- [12] HUANG G, SONG S J, GUPTA J N D, et al. Semi-supervised and unsupervised extreme learning machines. *IEEE Transactions on Cybernetics*, 2014, 44(12): 2405 – 2417.
- [13] WANG Chao, WANG Jianhui, GU Shusheng, et al. Improved incremental extreme learning machine based on multi-learning clonal selection algorithm. *Control Theory and Applications*, 2016, 33(3): 368 – 379.
(王超, 王建辉, 顾树生, 等. 基于多层学习克隆选择的改进式增量型超限学习机算法. *控制理论与应用*, 2016, 33(3): 368 – 379.)
- [14] DEGHANI M, HUBALOVSKY S, TROJOVSKY P. Northern goshawk optimization: A new swarm-based algorithm for solving optimization problems. *IEEE Access*, 2021, 9: 162059 – 162080.
- [15] ZHANG Tao, CHEN Yongqi, LIAO Ziyang, et al. A VMD-MRE bearing fault diagnosis method for northern goshawk parameter optimization. *Mechanical Science and Technology*, 2023, DOI: 10.13433/j.cnki.1003-8728.20230226.
(章涛, 陈勇旗, 廖紫洋, 等. 一种北方苍鹰参数优化的VMD-MRE轴承故障诊断方法. *机械科学与技术*, 2023, DOI: 10.13433/j.cnki.1003-8728.20230226.)
- [16] SAVITZKY A, GOLAY M J E. Smoothing and differentiation of data by simplified least squares procedures. *Analytical Chemistry*, 1964, 36(8): 1627 – 1639.
- [17] MCFADDEN P. A revised model for the extraction of periodic waveforms by time domain averaging. *Mechanical Systems and Signal Processing*, 1987, 1: 83 – 95.
- [18] TIAN Z D, LI S J, WANG Y H, et al. Wind power prediction method based on hybrid kernel function support vector machine. *Wind Engineering*, 2018, 42(3): 252 – 264.
- [19] WANG J Y, LI J G, WANG H T, et al. Research on gearbox composite fault diagnosis based on improved local mean decomposition. *International Journal of Dynamics and Control*, 2021, 9: 1411 – 1422.
- [20] SHAO S Y, MCALEER S, YAN R Q, et al. Highly accurate machine fault diagnosis using deep transfer learning. *IEEE Transactions on Industrial Informatics*, 2019, 15(4): 2446 – 2455.

作者简介:

杜董生 教授, 硕士生导师, 目前研究方向为故障诊断与容错控制, E-mail: dshdu@163.com;

王梦姣 硕士研究生, 目前研究方向为智能故障诊断算法, E-mail: mjiaowang@163.com;

冒泽慧 教授, 博士生导师, 目前研究方向为故障诊断与容错控制, E-mail: zehuimao@nuaa.edu.cn;

赵环宇 教授, 硕士生导师, 目前研究方向为多智能体系统, E-mail: hyzhao@163.com.