

基于FDBO+Informer-ECANet的齿轮箱故障诊断分析

李婷婷¹ 贾东²

(1. 郑州职业技术学院 智能制造学院, 郑州 450000)

(2. 辽宁工程技术大学 机械工程学院, 阜新 123000)

摘要:【目的】基于智能优化算法与深度神经网络的齿轮箱故障诊断方法逐渐成为研究热点, 但仍然存在较多问题。为了解决强噪声环境下齿轮故障特征提取难、诊断准确率低的问题, 提出一种基于融合增强型蜣螂优化(Fusion-enhanced Dung Beetle Optimization, FDBO)算法、Informer模型和通道注意力机制(Efficient Channel Attention Network, ECANet)模块的齿轮箱故障诊断方法。【方法】首先, 针对现有蜣螂优化(Dung Beetle Optimization, DBO)算法全局搜索能力不足、易陷入局部最优等问题, 引入融合Fuch混沌映射兼逆反向学习策略、自适应步长策略与凸透镜成像反转策略集成、随机差异变异策略, 提高算法的全局搜索能力; 其次, 基于Informer模型出色的长时间序列处理能力, 高效提取出序列数据中的全局特征与局部特征; 尤其针对包含长时间依赖关系的故障信号, 该模型可展现出极高的分类性能; 再次, 在Informer模型的编辑器中引入ECANet模块, 对Informer提取的特征进行通道级的自适应校准, 提高模型对重要特征的关注度, 以增强特征表达能力、减少噪声干扰; 最后, 通过FDBO算法对Informer-ECANet模型多个超参数进行寻优, 确定最优参数组合, 以增强模型的诊断能力和泛化性能。【结果】试验结果表明, 在无噪声条件下, 所提模型准确率达100%; 在加入-6 dB的高斯白噪声下准确率仍达到94.4%, 验证了所提模型的优越性, 为齿轮箱故障诊断提供了一种新型有效的智能方法。

关键词: 融合增强型蜣螂优化算法; Informer模型; ECANet模块; 随机差异变异策略

中图分类号: TH132.41; TP183 **DOI:** 10.16578/j.issn.1004.2539.2026.03.018

0 引言

齿轮箱是工业设备中的关键部件, 其运行状态直接关系到设备的整体性能和安全性^[1]。然而, 由于齿轮箱工作环境复杂, 常伴随强噪声干扰, 使得故障特征的提取及诊断面临诸多挑战^[2]。尤其是在复杂工况下, 齿轮箱故障特征往往被噪声掩盖, 导致传统诊断方法难以准确捕捉关键信息, 进一步限制了诊断的准确率和稳定性。如何有效提取齿轮箱故障特征, 提升诊断模型在强噪声环境下的鲁棒性和准确性, 成为当前研究领域的重要课题。

随着近年来智能算法和深度学习技术的快速发展, 基于智能优化算法与深度神经网络的齿轮箱故障诊断方法逐渐成为研究热点^[3]。智能优化算法具有

全局搜索能力强、适应性强的特点, 能够用于优化故障诊断模型的超参数配置, 从而提升模型性能。而神经网络凭借强大的特征提取能力, 能够从复杂、非线性的振动信号中提取到有效的特征表达, 实现对故障类型的准确分类。然而, 现有研究仍然存在一些不足: 传统的智能优化算法, 如遗传算法^[4](Genetic Algorithm, GA)、粒子群优化(Particle Swarm Optimization, PSO)算法^[5]等往往在高维搜索空间中表现出搜索效率低、易陷入局部最优等问题, 难以充分挖掘模型的最优参数组合。刘晨宇等^[6]借助Swin Transformer模型优秀的学习分类能力, 使用层次化构建方法, 来增强网络的感知能力, 但该方法在处理强噪声信号时, 难以实现对风电齿轮箱的有效运维; 火久元等^[7]提出的空洞卷积神经网络

收稿日期: 2025-05-28

基金项目: 河南省高等学校重点科研项目(24B520017, 24A460028)

作者简介: 李婷婷, 女, 1987年生, 河南开封人, 硕士, 讲师; 主要研究方向为电子、机器人、自动化; kaifengliting@163.com。

贾东(通信作者), 男, 1995年生, 黑龙江齐齐哈尔人, 硕士研究生; 主要研究方向为故障诊断; 1332755792@qq.com。

引用格式: 李婷婷, 贾东. 基于FDBO+Informer-ECANet的齿轮箱故障诊断分析[J]. 机械传动, 2026, 50(3): 161-171.

LI Tingting, JIA Dong. Analysis on fault diagnosis of gearbox based on FDBO+Informer-ECANet[J]. Journal of Mechanical Transmission, 2026, 50(3): 161-171.



免费获取

(Atrous Convolutional Neural Network, ACNN)可以对轴承信号进行多尺度特征提取,并且给予故障特征分配更多的权重,但在数据预处理方面优化不足,同时还需要消耗较大的计算资源。

针对上述问题,本文提出一种基于融合增强型蜣螂优化(Fusion-enhanced Dung Beetle Optimization, FDBO)算法、Informer模型及通道注意力机制(Efficient Channel Attention Network, ECANet)的齿轮箱故障诊断方法。为克服现有蜣螂优化(Dung Beetle Optimization, DBO)算法在全局搜索能力和避免局部最优方面的不足,通过引入混沌映射与逆反向学习、自适应步长、凸透镜成像以及随机差异变异策略,增强了其全局搜索能力与稳定性;同时,Informer模型在长序列数据处理领域具有显著优势,尤其在处理含长时间依赖关系的故障信号分类任务时,能够有效提升模型的整体性能。为进一步提升特征关注与噪声抑制能力,在Informer中引入了ECANet模块,不仅优化了特征表达,也显著提高了诊断准确率。此外,为了使Informer-ECANet模型在复杂工况下仍能保持高效的诊断能力与较强的泛化性能,引入FDBO算法对其超参数进行优化。

1 理论基础

1.1 Informer模型

Informer是改进的Transformer模型^[8-9],总体结构由编码器和解码器组成,如图1所示,其有3个显著优势。

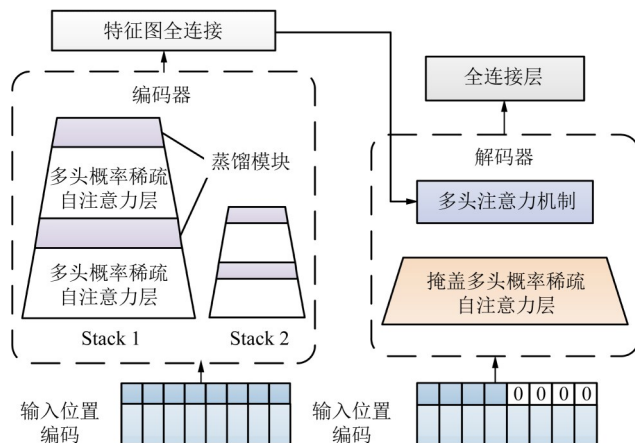


图1 Informer整体结构

Fig. 1 Overall structure of the Informer

1) Informer模型采用一种多尺度时间编码器和解码器的结构。这种设计使模型能够同时考虑不同时间尺度上的信息,从而更好地捕捉时间序列中的长期依赖和短期变化,提高特征提取精度。

2) 与传统的自注意力机制不同,Informer模型采用一种概率稀疏注意力机制。该机制能够根据序列长度自动调整注意力范围,使模型在处理长序列时更加高效,避免了传统自注意力机制在处理长序列时面临的计算量大、内存占用高等问题。

3) Informer模型采用一种新的掩码机制,可以在训练过程中自动处理序列中的缺失值。这种机制使得模型在面临实际数据时,即使存在缺失值,也能保持较高的性能。

Informer模型的核心是自注意力机制,通过加权重和计算序列中每个元素。首先,将时间序列数据转化为文本形式,捕捉长期依赖关系;然后,采用编码器-解码器结构,使用编码器提取关键特征,利用解码器预测下一个时间步的数据。此外,跨时间步的交互层进一步增强了时间步之间的依赖关系,提升了特征提取的准确性。

本文提出的诊断模型主要依靠Informer的编码器实现齿轮箱的故障特征提取。由图1可知,Informer编码器主要由2个相同的Stack组构成。改进Stack的结构示意图如图2所示。Stack由编码层和改进蒸馏层组成。其中,编码层对输入的时间序列数据进行编码,以提取出关键的特征信息。每个编码层均由多头自注意力机制和前馈网络组成。

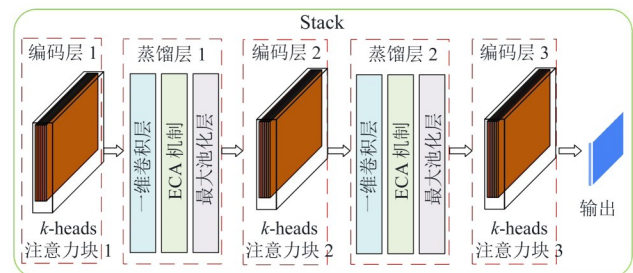


图2 改进Stack结构示意图

Fig. 2 Schematic diagram of the improved Stack structure

编码层的多头自注意力机制能够捕获不同位置之间的依赖关系,通过掩蔽防止信息泄漏,并使用多个注意力头从不同角度提取特征。为减少冗余信息并提升模型泛化能力,概率稀疏自注意力机制专门引入了稀疏约束;同时,为增强非线性表达效果,每层自注意力运算后都会接入前馈神经网络。

改进后的蒸馏层采用一维卷积、ECA机制与ELU激活函数,并借助最大池化层将输入长度减半,其层数相较于编码层减少一层。从第 j 层到 $j+1$ 层的蒸馏操作为

$$\chi_{j+1} = f_{\text{MaxPool}} \{ f_{\text{ELU}} [f_{\text{Conv1d}} ([\chi_j]_{AB})] \} \quad (1)$$

式中, f_{MaxPool} 表示最大池化操作; f_{ELU} 为激活函数,其

计算式为

$$f_{\text{ELU}}(x) = \begin{cases} e^x - 1, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

f_{Conv1d} 为一维卷积操作; $[\cdot]_{AB}$ 表示多头概率稀疏自注意力操作和注意力块其他重要的操作。

1.2 ECA 模块

通道注意力可以衡量各通道的重要性, 但其忽略了空间信息的作用。所以, 本文将ECA机制^[10]引入Informer的编码器蒸馏层中, 以便更充分地提取空间信息的关键特征。为实现跨通道交互, ECA模块采用避免降维的策略, 最终助力模型整体性能得到提升。ECA模块使用全局平均池化将特征图转换为特征向量, 并用一维卷积代替全连接层, 卷积核大小 K 决定局部跨通道交互范围。本文提出使用通道维数 C 的函数自适应地表示卷积核大小, 具体计算过程可表示为

$$K = \varphi(C) = \left\lfloor \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (3)$$

式中, $\varphi(\cdot)$ 表示映射关系; 下标 odd 表示最近的奇数; 变量 γ 与 b 均为超参数, 分别取值为2和1。

2 基于FDBO 算法

2.1 融合Fuch混沌映射兼逆反向学习策略

2.1.1 融合Fuch混沌映射

种群初始化在DBO算法^[11]中通常采用随机生成, 但容易导致种群分布不均, 减缓算法的迭代收敛速度。为解决该问题, 本文在传统初始化方法基础上引入混沌映射机制。常见的混沌映射方法有Tent映射、Chebyshev映射和Logistic映射, 这些方法虽广泛应用于种群初始化, 但存在种群重叠现象, 限制了优化性能。

为克服这一局限, 本文提出一种全新的Fuch混沌映射方法。与传统方法相比, Fuch方法生成的种群分布更加均匀、随机, 降低了对初始值的依赖, 显著提升了算法的全局搜索能力与优化效率。其表达式为

$$x_{i+1} = \cos(1/x_i^2) \quad (4)$$

式中, x_{i+1} 为经过混沌映射之后的种群个体; x_i 为混沌映射之前的个体。混沌的状态范围为 $(-1, 1)$ 。

为了体现本文混沌映射的随机性, 用自适应函数计算待优化的基准函数 $f(x)$, 其适应度值 F_{fitness} 计算式为

$$F_{\text{fitness}} = |f(x) - f_{\text{opt}}| \quad (5)$$

式中, x 为当前个体解; f_{opt} 为函数理论最小值。

采用种群数目为100个, 迭代次数选择为1000, 对传统的DBO算法引入Tent、Circle、Fuch、Logistic、Sine混沌映射进行对比, 其运行迭代结果如图3所示。




图3 不同混沌映射迭代结果

Fig. 3 Iterative results of different chaotic mappings

分析图3可知, 与其他混沌映射方法相比, 本文引入的Fuch混沌映射在优化过程中所能达到的适应度值最小。这表明, 其优化效率显著提升, 能够更有效地引导搜索, 快速收敛至全局最优解。该结果验证了Fuch混沌映射在全局搜索能力和适应性方面的优势, 为优化问题提供了高效的解决方案。

2.1.2 引入逆反向学习策略

本文在引入Fuch混沌映射的基础上, 加入逆反向学习策略以提升算法性能。该策略通过模拟蜚螂觅食中的反向思维机制扩展搜索空间, 避免陷入局部最优。逆反向学习策略突破了直接向最优解靠拢的限制, 通过逆向思维探索潜在解, 种群多样性与全局搜索能力得到显著提升, 也使该算法具备了更广泛的寻优能力。逆反向学习策略的数学实现及其优化性能提升机制可表示为

$$O_{P_i} = K(P_{\text{min}} + P_{\text{max}}) - P_i \quad (6)$$

式中, O_{P_i} 为对应于每个初始解 P_i 的逆解; 卷积核大小 K 取 $(0, 1)$ 范围内的随机值; P_{max} 和 P_{min} 分别为初始解中的最大值和最小值。

2.2 自适应步长策略与凸透镜成像反转策略集成

传统DBO算法因随机策略导致蜚螂觅食阶段缺乏自适应能力, 全局搜索能力较弱, 易陷入局部最优。为此, 本文提出一种动态选择策略, 在一定概率下交替采用自适应步长和凸透镜成像反转策略, 更新目标位置。迭代初期, 大步长能够扩展搜索范围, 提升全局搜索能力; 迭代后期, 小步长能够增强局部搜索, 避免陷入局部最优。凸透镜成像反转策略通过空间反转机制引导搜索跳出局部区域, 可进一步提升全局探索能力。动态选择策略有效平衡

了全局与局部搜索，显著提高了算法的优化性能。该策略主要由线性递减的自适应步进控制因子 α_0 决定，其计算式为

$$\alpha_0 = \cos \left[\frac{\pi}{3} \times \left(1 + \frac{t}{T} \right) \right] \quad (7)$$

式中， t 为当前的迭代次数； T 为种群的总迭代次数。 α_0 是能够随着迭代次数进行自适应变化的。

为进一步增强种群的多样性，提高算法跳出局部最优的可能性，引入一种凸透镜成像反转策略来对蜣螂种群进行扰动，设凸透镜策略自定义参数为 P_j^* ，其计算式为

$$P_j^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j}{2k} - \frac{P_j}{k} \quad (8)$$

式中， a_j 和 b_j 分别表示初始化参数为种群的搜索空间的上下边界 u_b 和 l_b ； k 为比例系数，需在Sphere函数中进行测试选取。为方便比较算法性能，选取不同的参数进行测试，结果如图4所示。




图4 比例系数参数对比图

Fig. 4 Comparison diagram of proportional coefficient parameters

由图4可知， $k=2$ 时，能够更好地实现探索与开发阶段的平衡。

目标位置更新采用随机步进策略还是凸透镜成像学习策略，主要由选择概率 P_s 决定。其计算式为

$$P_s = -\exp(1 - \frac{t}{T})^{10} \quad (9)$$

当 $P_s \geq 0.5$ 时，采用凸透镜成像反转策略进行位置更新；当 $P_s < 0.5$ 时，采用随机步进策略进行位置更新。其最终的步进策略可表示为

$$\begin{cases} P_i^{t+1} = \alpha_0 \times P_{gbest}^t + C_1 \times (P_i^t - L_i^b) + \\ C_2 \times (P_i^t - U_i^b), P_s < 0.5 \\ P_i^{t+1} = \frac{L_i^b + U_i^b}{2} + \frac{L_i^b + U_i^b}{2k} - \frac{P_i^t}{k}, P_s \geq 0.5 \end{cases} \quad (10)$$

式中， C_1 和 C_2 均为比例系数； P_{gbest}^t 为迭代最佳个体； U_i^b 和 L_i^b 分别为蜣螂觅食区的上、下边界。

2.3 引入随机差异变异策略

蜣螂偷窃行为的位置更新以个体当前最优值为基准，易导致种群多样性下降，陷入局部最优，降低收敛效率。为解决该问题，本文引入随机差异变异策略，通过在位置更新中加入随机扰动，增强种群多样性，避免早熟收敛。该策略提升了全局搜索能力，优化了整体性能。随机差异变异策略的数学实现为

$$P(t+1) = r_1 \times [P^* - P(t)] + r_2 \times [P'(t) - P(t)] \quad (11)$$

式中， $P(t+1)$ 为通过随机差异突变获得的新个体； r_1 和 r_2 均为 $[0, 1]$ 范围内的随机值； P^* 为当前最佳个体位置； $P'(t)$ 为从种群中随机选择的个体位置。

2.4 函数测试

为验证本文算法的性能，将其与DBO、GA、蚁群优化(Ant Colony Optimization, ACO)算法和差分进化算法(Differential Evolution Algorithm, DE)进行了对比试验。测试选取单模态、多模态和复合基准函数，即 $F_1(x)$ 、 $F_{10}(x)$ 、 $F_{14}(x)$ 和 $F_{22}(x)$ ，对应的测试分别为F1、F10、F14和F22，迭代次数为1000，每种算法独立运行30次以减少随机误差。对比结果如图5所示，测试函数信息如表1所示。其中， c_i 为测试函数中的常数系数。

表1 测试函数

Tab. 1 Test functions

函数类别	维度	范围	理论最小值
$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$F_{10}(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)] + 20 + e$	30	$[-32, 32]$	0
$F_{14}(x) = [\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_j)^6}]^{-1}$	2	$[-65, 65]$	1
$F_{22}(x) = -\sum_{i=1}^7 [(X - a_i)^T + c_i]^{-1}$	4	$[0, 10]$	-1

在F1测试中，FDBO算法约200次迭代即可达到最优值，收敛速度远超GA和ACO，最终误差接近 10^{-200} ，展现出卓越的求解精度。在F10测试中，FDBO在约300次迭代内将误差降至 10^{-5} 以下，优于DE和ACO，表现出更强的极值捕获能力。在复杂的F14测试中，FDBO在100次迭代后收敛，误差降至

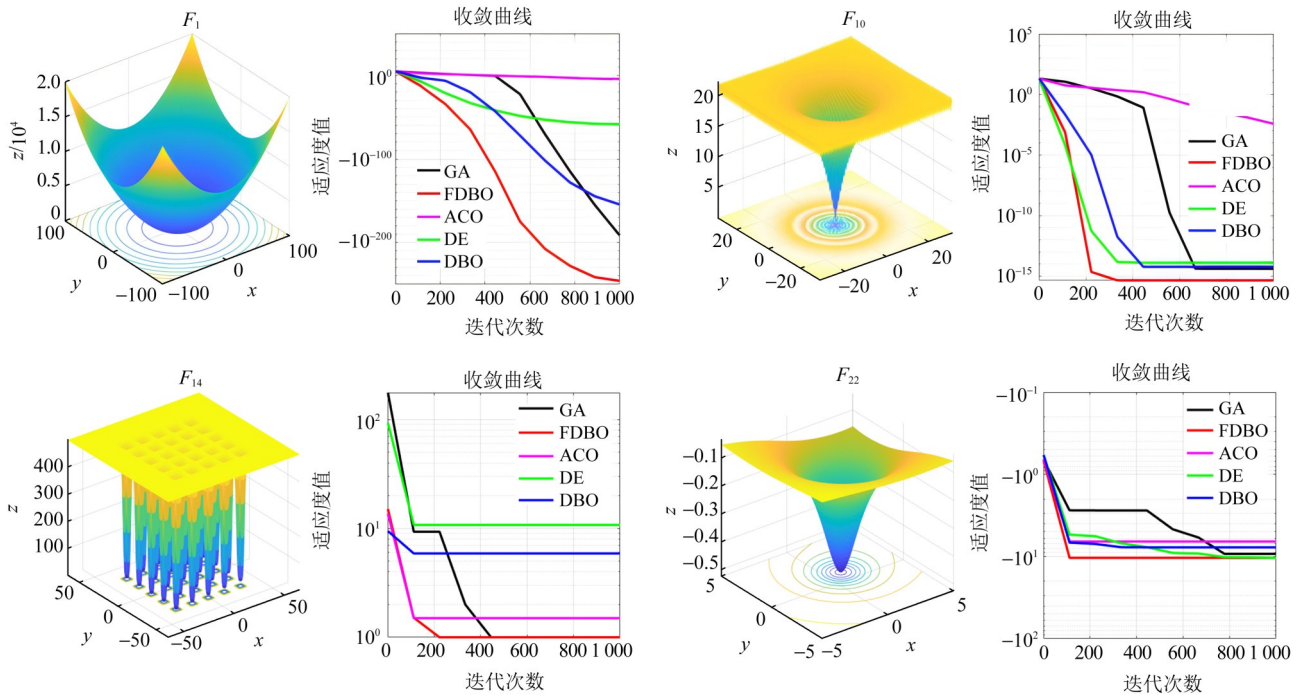


图5 函数对比测试

Fig. 5 Comparison test of the function

10^{-12} , 显著优于GA(10^{-6})和ACO(10^{-7})。在F22测试中, FDBO在150次迭代内达最优解, 误差降至 10^{-15} , 远胜GA和ACO的 10^{-5} 与 10^{-8} 。FDBO在多种测试函数中均展现出快速收敛性与高解精度, 特别是在复杂多峰和高维问题方面优势显著。

相比传统算法, FDBO可有效避免局部最优, 提升全局搜索能力, 尤其在复杂多峰和高维基准函数中表现更为优异。其性能优势源于对解空间的高效探索与开发能力。

2.5 单一策略敏感性试验

为验证本文算法的单一策略的有效性, 进行单一策略敏感性试验。将采用Fuch混沌映射兼逆反向学习策略的DBO算法定义为S1; 将采用自适应步长策略与凸透镜成像反转策略集成的DBO算法定义为S2; 将采用随机差异变异策略的DBO算法定义为S3。将以上3个策略与本文的FDBO算法进行对比。定义消融因子 γ 以定量评估缺失策略的重要程度, 其计算式为

$$\gamma = \frac{f_{si}}{f_{FDBO}} \quad (12)$$

式中, f_{si} 和 f_{FDBO} 分别为不完全改进DBO与FDBO的最佳适应度平均值。 γ 越大, 对照算法在寻优性能上的表现会更差, 从侧面说明了所缺失的策略在改善原始算法性能方面发挥的效果也越突出。

采用 IEEE Congress on Evolutionary Computation

2005基准测试函数集进行测试, 测试的种群数目为100, 最大迭代次数为100。进行消融试验的结果如表2所示, 选取函数 F_1 、 F_2 、 F_3 、 F_{14} 、 F_{15} 进行测试。

表2 测试数据

Tab. 2 Test data

函数	算法类型		
	S1	S2	S3
F_1	1.23	1.22	1.08
F_2	1.01	1.54	1.84
F_3	1.03	1.02	1.23
F_{14}	1.11	1.16	1.13
F_{15}	1.03	1.30	1.00

γ 大于1, 表明改进算法各个部分对于算法寻优存在积极的影响作用。从上述试验结果可以看出, Fuch混沌映射兼逆反向学习策略对于大多数测试函数都起到了正面作用, 证明了改进算法的有效性。

2.6 算法运行时间验证分析

为验证算法的时间复杂度与实用性, 进行算法的时间验证分析。首先, 对单一策略的时间进行测试分析; 其次, 对比分析了主流算法的运行时间。为直观地体现算法的运行时间, 采用了直方图的形式, 分别如图6、图7所示。具体数值如表3所示。

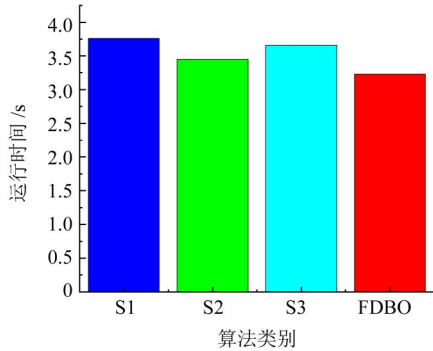


图6 时间运行图(一)

Fig. 6 Diagram of the time operation (I)

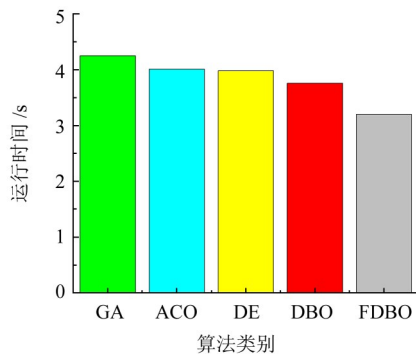


图7 时间运行图(二)

Fig. 7 Diagram of the time operation (II)

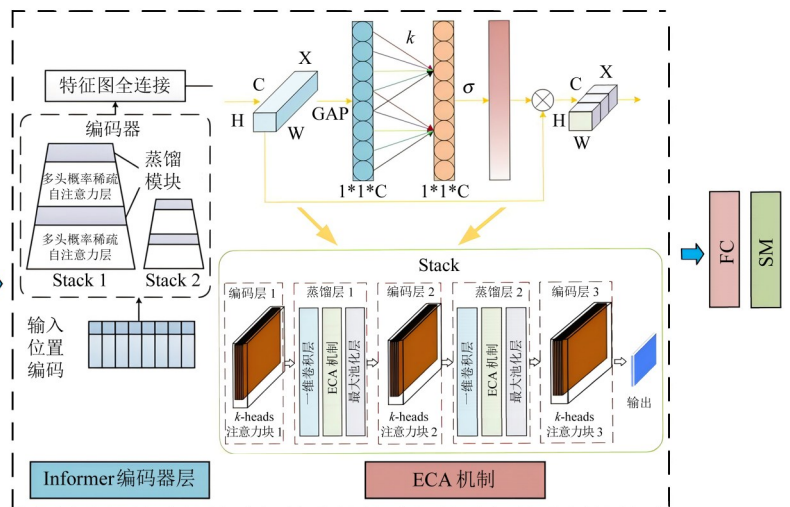
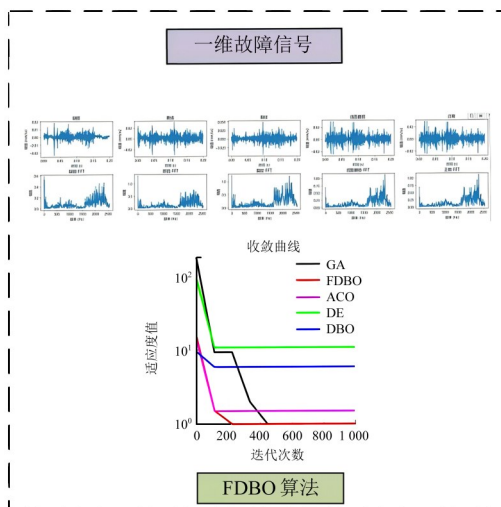


图8 模型结构图

Fig. 8 Diagram of the model structure

3.2 诊断流程

基于 FDBO+Informer-ECA Net 的齿轮箱故障诊断模型流程步骤如下:

- 1) 数据预处理。利用快速傅里叶变换将时域转化成频域,生成频谱图。
- 2) 频谱图像样本按一定比例划分为训练集、验证集和测试集。
- 3) 将训练集样本输入网络模型进行训练,同时用 FDBO 算法对模型超参数进行寻优,并且用验证集样本进行模型验证。

表3 测试数据
Tab. 3 Test data

算法类别	时间/s
S1	3.74
S2	3.32
S3	3.65
GA	4.25

3 诊断方法

3.1 模型结构

本文提出一种基于 FDBO+Informer-ECA Net 的齿轮箱故障诊断方法,图 8 为该诊断模型的整体结构图,共包含 3 个部分,即 FDBO 算法、Informer 编码器层和 ECA 机制。利用 FDBO 算法对模型多个超参数进行寻优,如学习率、隐藏层维度、注意力头数、编码器层数等,这些参数对模型性能有显著影响;运用 Informer 中的编码器实现齿轮箱的故障特征提取;同时,利用 ECA 机制对特征关键部分进行自适应校准;最终,通过全连接层和 Softmax 对故障进行分类。

- 4) 将测试集样本输入训练好的模型,用以输出故障诊断结果。

4 试验与分析

4.1 试验设计及搭建

为了验证本文方法的有效性,搭建故障诊断试验台,采集原始故障信号进行验证。试验模拟平台如图 9 所示。试验设备主要由电动机、行星齿轮箱、数据采集卡、加速度传感器组成。将 DH5908N 数据采集器作为采集平台,利用加速度传感器检测振动

信号, 传感器型号为DH1B103压阻式加速度传感器。利用动态信号采集分析系统(Dynamic Signal Acquisition and Analysis System, DHDAS)软件进行数据显示及储存, 采集了缺损、断齿、裂纹、齿面磨损、正常共5种状态的数据。



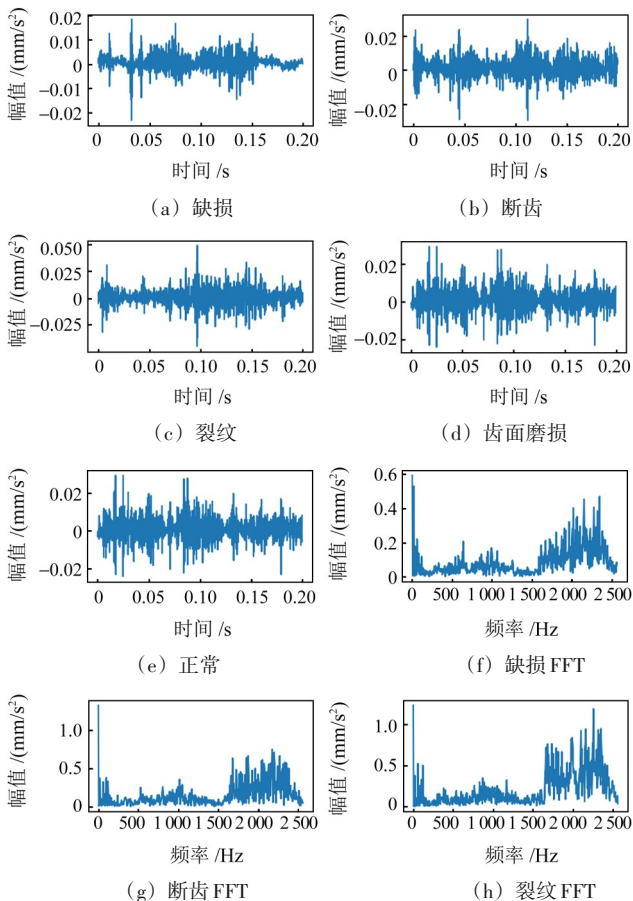


图9 试验模拟平台

Fig. 9 Platform of the test simulation

本文基于东南大学齿轮箱开源数据集^[12]进行试验验证, 采用非重叠采样策略对试验数据进行预处理。采样频率设置为64 kHz, 每个样本长度固定为1 024个数据点; 在零重叠率条件下, 从5个不同故障类别中各提取800个样本, 构建了包含4 000个样本的数据集。为保障模型评估的有效性, 将数据集按4:1:1比例划分为训练集、验证集和测试集。通过对原始振动信号进行快速傅里叶变换(Fast Fourier Transform, FFT)处理, 成功将时域信号转换为频域特征表示, 其数据特征分布如图10所示。



(i) 齿面磨损 FFT (j) 正常 FFT

图10 5种齿轮状态的原始信号和频谱图

Fig. 10 Original signals and spectrograms of five gear conditions

4.2 模型训练

对模型进行训练, 获取最优模型。本文所用模型训练集和验证集的损失值、准确率变化曲线分别如图11、图12所示。




图11 损失变化曲线

Fig. 11 Curves of the loss variation




图12 准确率变化曲线

Fig. 12 Curves of the accuracy variation

由图11可知, 训练损失和验证损失均随训练轮次增加显著下降, 尤其在前10轮内下降较快, 表明模型初期快速学习了训练数据的特征; 在30轮后, 训练损失趋于平稳并接近0, 说明模型在训练集上的拟合程度高。验证损失同样在前10轮内迅速下降, 显示预测性能明显提升; 尽管在30轮后验证损失略有波动, 但整体保持低值并呈现收敛趋势。两者在数值上的差异极小, 30轮后几乎重合, 模型在训练集与验证集上的表现一致, 未出现过拟合或欠拟合现象。表明模型已经训练完成和收敛成功。

由图12可知, 训练准确率与验证准确率均随训练轮次的增加而逐步提升, 反映出模型分类性能的

持续优化。最终的验证准确率与训练准确率非常接近，表明模型具备较强的泛化能力，未出现显著的过拟合现象。此外，训练和验证准确率均接近1.0，这表明模型在分类任务中的性能表现卓越，几乎能正确分类所有样本。上述结果表明，模型在训练与验证阶段均展现出较强的学习能力和良好的泛化性能。

4.3 t-SNE可视化

t-SNE可视化是一种常用的降维技术，其核心作用是将高维度数据映射到二维或三维的低维度空间中，从而实现对高维数据的直观呈现与分析。将本文模型提取的特征进行可视化，结果如图13、图14所示。




图13 未训练特征分布

Fig. 13 Distribution of the untrained feature




图14 训练后特征分布

Fig. 14 Feature distribution after training

图13和图14中， x 、 y 轴均为t-SNE降维后的两个特征维度，无量纲。对比两图可以看出，经过本模型学习之后，不同种类的数据之间的区分度明显增加，这证明了本模型具有较好的鲁棒性。

4.4 模型的故障分类量化

为了更精确地量化和可视化故障诊断模型在分类准确性方面的表现，运用了混淆矩阵进行全面评估。图15所示为故障诊断模型的5种分类输出的混淆矩阵。

坐标轴按顺序分别为缺损、断齿、裂纹、齿面

磨损、正常这5种类别。从这5个分类中可以看到，总共有800个样本，而每一类别的样本数量都有160个。由图15可知，故障诊断模型5个分类的准确率都达到了100%，这证明了该模型在故障诊断方面具有极强的准确性。




图15 故障分类混淆矩阵

Fig. 15 Confusion matrix of the fault classification

4.5 消融试验

为了验证模型各部分的有效性，将本文模型进行部分模块拆分，构成2种消融模型。

模型1：在原始模型的基础上去除ECA模块，不使用ECA模块构建模型。

模型2：在原始模型的基础上去除多策略改进DBO算法，不使用多策略改进DBO算法构建模型。

图16所示为本文模型与其他消融模型的准确率对比，表4所示为其具体数值。




图16 消融试验结果直方图

Fig. 16 Histogram of ablation test results

表4 消融试验结果数据

Tab. 4 Result data of the ablation test 单位: %

模型类别	本文模型	模型1	模型2
4次试验数据	100	96.2	98.5
	99.8	94.5	97.2
	100	95.0	96.9
	100	94.7	98.6
准确率平均值	99.9	95.3	97.8

结果表明, 在相同条件下, 本文模型的准确率均优于消融模型。相较于模型1与模型2, 本文模型诊断的准确率提高了4.6个百分点和2.1个百分点, 从而验证了本文模型可以更好地提高诊断准确率。

4.6 计算效率对比分析

针对现有方法存在的计算量大等问题, 本文从训练时间与推理速度两个方面, 对比了FDBO+Informer-ECANet、改进的注意力机制卷积神经网络(Improved Attention Mechanism Convolutional Neural Network, IAMCNN)^[13]、STFT-2D CNN-SVM^[14]与CWT-Swin Transformer^[15]的性能差异。所有试验在相同硬件环境(NVIDIA RTX 3090 GPU, 24 GB显存, PyTorch 1.12框架)下进行, 数据集采用第4.1节所述配置。

表5所示为各模型在训练集上的平均单轮训练时间及单样本推理时间。本文模型单轮训练时间为128 s, 显著低于CWT-Swin Transformer(215 s), 较IAMCNN(92 s)略高, 但结合其更高的准确率(100%), 体现出更优的精度-效率平衡。推理速度方面, 本文模型单样本处理耗时仅3.2 ms, 较CWT-Swin Transformer(5.8 ms)提升44.8%, 满足实时诊断需求。效率提升主要源于Informer的概率稀疏注意力机制, 通过动态剪枝冗余计算, 减少了计算量。

表5 模型计算效率对比

Tab. 5 Comparison of the model computational efficiency

模型	训练时间/s	单样本推理时间/ms
IAMCNN	92	2.5
STFT-2D CNN-SVM	105	3.0
CWT-Swin Transformer	215	5.8
本文模型	128	3.2

4.7 强噪声环境下的诊断性能验证

4.7.1 强噪声环境下模型准确率对比

在齿轮箱实际运行环境中, 常伴随复杂噪声干扰。为验证本文模型在强噪声条件下的优越性, 通过在原始振动信号中叠加不同强度高斯白噪声^[16]以模拟实际工况, 分别在每种信噪比下进行1次试验, 以验证本文模型的抗噪能力。信噪比(Signal-to-Noise Ratio, SNR)为信号功率与噪声功率的比值, 记作 R_{SNR} , 其表达式为

$$R_{SNR} = 10 \log_{10} \left(\frac{S}{N} \right) \quad (13)$$

式中, S 为信号的功率; N 为噪声的功率。

信噪比越小, 噪声的干扰能力越强。具体设置

为-12 dB、-9 dB、-6 dB、-3 dB和0 dB, 涵盖从极强噪声到弱噪声的典型场景。高斯白噪声具有均匀的功率谱密度特性, 能够有效模拟工业环境中随机分布的背景噪声。

不同噪声强度下各模型分类准确率对比试验结果如表6所示, 本文所用模型是FDBO+Informer-ECANet。由表6可知, 随着SNR降低, 所有模型的准确率均呈现下降趋势, 但本文所用模型表现出更强的抗噪能力。例如, 在-6 dB噪声下, 本文模型准确率为94.4%, 显著高于IAMCNN(89%)和CWT-Swin Transformer(92.1%); 即使在-12 dB的极端噪声条件下, 本文模型仍保持89.7%的准确率, 验证了其鲁棒性。进一步分析发现, ECANet模块采用通道级特征校准有效抑制了噪声干扰, 而改进DBO算法优化的超参数组合增强了模型对噪声特征的泛化能力。

表6 不同信噪比下的模型分类准确率

Tab. 6 Model classification accuracy under different signal-to-noise ratios

信噪比/dB	准确率/%			
	IAMCNN	STFT-2D CNN-SVM	CWT-Swin Transformer	本文模型
0	93.5	95.1	96.8	98.9
-3	91.2	93.4	94.5	96.7
-6	89.0	91.4	92.1	94.4
-9	85.6	88.3	89.7	92.1
-12	81.4	84.2	85.5	89.7

4.7.2 强噪声环境下故障诊断模型性能对比

本文选取加入-6 dB高斯白噪声的条件进行对比。对比试验的准确率和损失率分别如图17、图18所示。可以看到, 与其他3种模型相比, 图18中的FDBO+Informer-ECANet测试集的准确率均在第10次迭代中就已经达到了90%, 可见本文模型的收敛速度较快, 且模型分类准确率有较大提高。

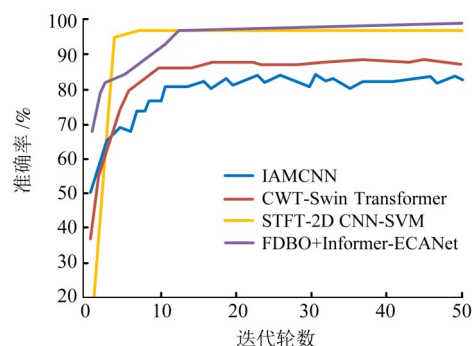


图17 准确率对比图

Fig. 17 Comparison chart of the accuracy

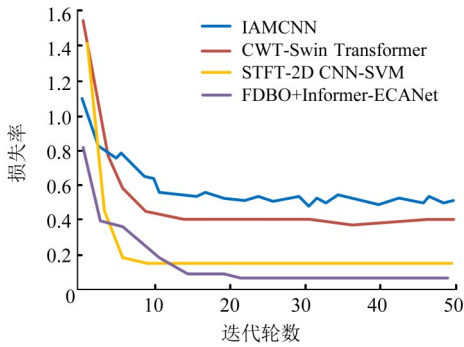


图 18 损失率对比图

Fig. 18 Comparison chart of the loss rate

与 IAMCNN、STFT-2D CNN-SVM 和 CWT-Swin Transformer 相比，FDBO+Informer-ECANet 的平均损失值下降速度明显更快，而且最终的损失率都低于上述对比模型，证明本研究所提 FDBO+Informer-ECANet 模型具有较强的鲁棒性。

5 结论

针对强噪声环境下齿轮箱故障特征提取难、诊断准确率低等问题，提出一种基于 FDBO+Informer-ECANet 的齿轮箱故障诊断方法。通过试验验证和对比分析，得出以下结论：

1) 引入融合 Fuch 混沌映射兼逆反向学习策略、自适应步长与凸透镜成像策略集成以及随机差异变异策略，显著提升了算法的全局搜索能力和收敛效率。试验结果表明，改进后的 FDBO 算法在单模态、多模态及复合基准函数测试中均表现出优异的性能，能够快速收敛至全局最优解，为模型超参数优化提供了高效的支持。

2) 通过 Informer 模型的多尺度时间编码器和概率稀疏注意力机制，可有效解决传统 Transformer 模型在处理长序列数据时计算量大、内存占用高的问题。该模型能够同时捕捉时间序列中的长期依赖和短期变化，显著提高故障特征提取的精度，尤其在强噪声环境下仍能保持较高的分类性能。

3) 在 Informer 模型中引入 ECANet 模块，采用通道级的自适应校准，有效增强了模型对关键特征的关注度，也减少了噪声干扰。消融试验表明，加入 ECANet 模块后，模型的诊断准确率提升了 4.6 个百分点，验证了其在噪声抑制和特征增强方面的有效性。

参 考 文 献

[1] 万安平,杨洁,王景霖,等. 基于深度学习的航空发动机齿轮故障诊断[J]. 振动、测试与诊断,2022,42(6):1062-1067.
WAN Anping, YANG Jie, WANG Jinglin, et al. Fault diagnosis of

aeroengine gear based on deep learning[J]. Journal of Vibration, Measurement & Diagnosis,2022,42(6):1062-1067.

- [2] 高贵兵,王俊深,岳文辉,等. 基于脆弱性的制造设备故障智能诊断与维护[J]. 机械工程学报,2020,56(23):141-149.
GAO Guibing, WANG Junshen, YUE Wenhui, et al. Fault diagnosis and maintain of manufacturing equipment based on vulnerability[J]. Journal of Mechanical Engineering, 2020, 56(23):141-149.
- [3] 李彦夫,韩特. 基于深度学习的工业装备 PHM 研究综述[J]. 振动、测试与诊断,2022,42(5):835-847.
LI Yanfu, HAN Te. Deep learning based industrial equipment prognostics and health management: a review[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(5):835-847.
- [4] FEI Y F, QIN S Z, LIAO W J, et al. Graph neural network-assisted evolutionary algorithm for rapid optimization design of shear-wall structures [J]. Advanced Engineering Informatics, 2025, 65: 103129.
- [5] ZHANG Y D, WANG S H, JI G L. A comprehensive survey on particle swarm optimization algorithm and its applications[J]. Mathematical Problems in Engineering, 2015, 2015(1):931256.
- [6] 刘晨宇,李志农,熊鹏伟,等. 融合路径聚合网络的 Swin Transformer 的故障诊断方法研究[J]. 振动与冲击, 2024, 43(18): 258-266.
LIU Chenyu, LI Zhinong, XIONG Pengwei, et al. Fault diagnosis method based on Swin Transformer with path aggregation networks [J]. Journal of Vibration and Shock, 2024, 43(18):258-266.
- [7] 火久元,李昕,常琛,等. 基于 ACNN-LFSwin Transformer 的双通道滚动轴承故障诊断方法[J/OL]. 计算机工程: 1-15(2025-01-06) [2025-05-28]. <https://doi.org/10.19678/j.issn.1000-3428.0070297>.
HUO Jiuyuan, LI Xin, CHANG Chen, et al. Dual-channel rolling bearing fault diagnosis method based on ACNN-LFSwin Transformer [J/OL]. Computer Engineering: 1-15 (2025-01-06) [2025-05-28]. <https://doi.org/10.19678/j.issn.1000-3428.0070297>.
- [8] 宋俊杰,陈翀,王涛,等. 基于半监督学习 Informer 算法的工业机器人故障诊断方法[J]. 机电工程技术, 2024, 53(2):24-28.
SONG Junjie, CHEN Chong, WANG Tao, et al. Informer-based semi supervised learning for fault diagnosis of industrial robot[J]. Mechanical & Electrical Engineering Technology, 2024, 53(2):24-28.
- [9] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12):11106-11115.
- [10] WANG Q L, WU B G, ZHU P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2020:11534-11542.
- [11] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7):7305-7336.
- [12] HAN H R, WANG H, LIU Z L, et al. Intelligent vibration signal

- denoising method based on non-local fully convolutional neural network for rolling bearings [J]. *ISA Transactions*, 2022, 122: 13-23.
- [13] 邵浙梁, 戚知宽, 周邵萍. 基于改进注意力机制的CNN的齿轮箱故障诊断[J]. *华东理工大学学报(自然科学版)*, 2024, 50(6): 920-928.
SHAO Zheliang, QI Zhikuan, ZHOU Shaoping. Gearbox fault diagnosis based on CNN with improved attention mechanism [J]. *Journal of East China University of Science and Technology (Natural Science Edition)*, 2024, 50(6): 920-928.
- [14] 谢锋云, 汪淦, 王玲岚, 等. STFT结合2D CNN-SVM的齿轮箱故障诊断方法[J]. *噪声与振动控制*, 2024, 44(4): 103-109.
XIE Fengyun, WANG Gan, WANG Linglan, et al. Fault diagnosis method of gearbox based on STFT and 2DCNN-SVM [J]. *Noise and Vibration Control*, 2024, 44(4): 103-109.
- [15] 周舟, 陈捷, 吴明明. 基于CWT和优化Swin Transformer的风电齿轮箱故障诊断方法[J]. *振动与冲击*, 2024, 43(15): 200-208.
ZHOU Zhou, CHEN Jie, WU Mingming. Fault diagnosis method for wind power gearbox based on wavelet transform and optimized Swin Transformer [J]. *Journal of Vibration and Shock*, 2024, 43(15): 200-208.
- [16] 张锐, 刘婷婷, 王燕, 等. 基于FBSE-ESEWT的齿轮故障诊断方法[J]. *电子测量与仪器学报*, 2025, 39(4): 234-246.
ZHANG Rui, LIU Tingting, WANG Yan, et al. Gear fault diagnosis method based on FBSE-ESEWT [J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(4): 234-246.

Analysis on fault diagnosis of gearbox based on FDBO+Informer-ECANet

LI Tingting¹ JIA Dong²

(1. College of Intelligent Manufacturing, Zhengzhou Technical College, Zhengzhou 450000, China)

(2. School of Mechanical Engineering, Liaoning University of Engineering and Technology, Fuxin 123000, China)

Abstract: [Objective] The fault diagnosis method for gearboxes based on intelligent optimization algorithms and deep neural networks has gradually become a research hotspot, but there are still many problems. To address the challenges of fault feature extraction and low diagnostic accuracy for gearboxes under strong noise environments, a novel gearbox fault diagnosis method was proposed based on a fusion-enhanced dung beetle optimization (FDBO) algorithm, the Informer model, and the efficient channel attention network (ECANet) module. [Methods] Firstly, to overcome the limitations of the conventional dung beetle optimization (DBO) algorithm, such as insufficient global search capability and tendency to fall into local optima, a fusion strategy integrating Fuch chaotic mapping combined with inverse learning, an adaptive step size strategy, convex lens imaging, and a stochastic differential mutation strategy was introduced, significantly enhancing the algorithm's global search performance. Secondly, benefiting from its excellent long-term time series processing capability, the Informer model was enabled to efficiently extract global features and local features from sequence data; especially for fault signals involving long-term dependencies, the model was able to demonstrate extremely high classification performance. Thirdly, an ECANet module was incorporated into the encoder of the Informer model to perform channel-wise adaptive calibration of extracted features, enhancing the model's attention to critical features, strengthening feature representation, and reducing noise interference. Finally, the FDBO algorithm was employed to optimize multiple hyperparameters of the Informer-ECANet model, determining the optimal parameter combination to improve the diagnostic accuracy and generalization capability of the model. [Results] Test results demonstrate that the proposed method achieves an accuracy of 100% under noise-free conditions, and maintains a high accuracy of 94.4% even when subjected to Gaussian white noise at a -6 dB signal-to-noise ratio, thereby validating the superior performance and robustness of the model. This study provides an effective intelligent approach for gearbox fault diagnosis under challenging noisy environment.

Key words: Fusion-enhanced dung beetle optimization algorithm; Informer model; ECANet module; Stochastic differential variation strategy

(编辑: 刘欢欢)