

DOI:10.19651/j.cnki.emt.2517839

基于参数优化 VMD 与宽卷积神经网络的齿轮箱故障诊断^{*}

万佳诚¹ 曾宪文² 李婧超²

(1. 上海电机学院电气学院 上海 201306; 2. 上海电机学院电子信息学院 上海 201306)

摘要: 针对齿轮箱故障诊断中因噪声干扰等因素导致的诊断效果不佳问题,提出一种基于改进的黑翅燕优化算法(GBKA)优化变分模态分解(VMD)和宽卷积神经网络(WDCNN)的故障诊断方法。首先,针对黑翅燕算法(BKA)易陷入局部最优和过早收敛的缺陷,引入遗传算法的基因交叉重组与变异操作对BKA进行改进;其次,利用改进后的GBKA对VMD参数寻优,通过相关系数筛选模态分量并重构信号;最后,将重构信号输入WDCNN模型,实现故障分类。结果表明,在测试函数上,GBKA相比BKA具有更优的寻优性能;在两种工况下,该方法的平均故障分类准确率分别达到99.645%和99.978%,优于其他对比方法,并且在噪声实验中受到噪声的影响较小,验证了所提模型的有效性和稳定性,为齿轮箱故障诊断提供了一种可靠的解决方案。

关键词: 行星齿轮; 故障诊断; 宽卷积神经网络; VMD; GBKA 算法

中图分类号: TH165+.3; TN0 文献标识码: A 国家标准学科分类代码: 460

Fault diagnosis for gearbox based on parameter optimization VMD combined with wide convolutional neural network

Wan Jiacheng¹ Zeng Xianwen² Li Jingchao²

(1. School of Electrical Engineering, Shanghai Dianji University, Shanghai 201306, China;

2. School of Electronic Information, Shanghai Dianji University, Shanghai 201306, China)

Abstract: A fault diagnosis method based on an improved black winged kite optimization algorithm (GBKA) optimized variational mode decomposition (VMD) and wide convolutional neural network (WDCNN) is proposed to address the issue of poor diagnostic performance caused by noise interference and other factors in gearbox fault diagnosis. Firstly, in response to the shortcomings of the black winged kite algorithm (BKA), which is prone to falling into local optima and premature convergence, genetic algorithm's gene crossover recombination and mutation operations are introduced to improve BKA; secondly, using the improved GBKA to optimize VMD parameters, modal components are screened through correlation coefficients and the signal is reconstructed; finally, the reconstructed signal is input into the WDCNN model to achieve fault classification. The results indicate that GBKA has better optimization performance compared to BKA in the test function; under two operating conditions, the average fault classification accuracy of this method reached 99.645% and 99.978%, which is superior to other comparative methods. In addition, it was less affected by noise in the noise experiment, verifying the effectiveness and stability of the proposed model and providing a reliable solution for gearbox fault diagnosis.

Keywords: planetary gear; fault diagnosis; wide convolutional neural network; VMD; GBKA algorithm

0 引言

旋转机组中,齿轮箱作为现代机械设备的重要部件,其安全性能十分重要^[1]。但是在日常生产中齿轮箱由于其高速旋转、高温状态以及高负荷长时间运作下,非常容易出现磨

科技和工业的发展,离不开旋转机组的广泛应用。在

收稿日期:2025-01-07

*基金项目:国家自然科学基金面上项目(62076160)、上海市自然科学基金面上项目(21ZR1424700)、上海市青年科技启明星项目(23QA1403800)资助

损、裂纹、缺齿和断齿等故障,这些故障极易带来巨大的安全隐患和难以估量的经济损失^[2]。因此,对齿轮箱进行有效的故障诊断具有重要意义^[3]。

在故障诊断中,由于旋转机械的振动信号易受到复杂环境和其他设备的噪声干扰,并且其原始信号具有非稳定性、非线性等特点^[4],因此如何有效地从复杂的原始信号中分离故障信号进行故障诊断是近年来研究的热点之一。目前故障诊断常见的信号处理方法有经验模态分解(empirical mode decomposition,EMD)、集合经验模态分解(ensemble empirical mode decomposition,EEMD)、变分模态分解(variational mode decomposition,VMD)等。刘剑生等^[5]采用 EMD 将原始振动信号分解为多个模态分量并提取特征信息。为了解决 EMD 的模态混叠现象,金志浩等^[6]采用 EEMD 将原始信号分解并结合快速谱峭度筛选模态分量并进行信号重构。史书杰等^[7]采用 EEMD 能量熵将 KELM 结合进行轴承故障诊断。但是 EEMD 是通过白噪声辅助分解,其在分解过程中无法完全消除残余噪声。相比 EMD 及其改进方法,由 Dragomiretskiy 等^[8]提出的变分模态分解(VMD),能够有效的改善模态混叠问题,因而被广泛应用。刘秀丽等^[9]将 VMD 与小波降噪结合 SVM 对齿轮箱进行了有效的诊断。刘明昊^[10]等提出了一种基于 VMD 能量熵值的齿轮箱滚动轴承故障诊断。但是由于 VMD 的分解效果取决于分解模态数 K 和惩罚系数 α , K 和 α 是通过学者的实验经验进行设置,这个两个参数设置不当会导致信息丢失或模态冗杂^[11]。而采用优化算法对 VMD 自适应参数寻优是一种有效的解决方法。由 Wang 等^[12]提出的黑翅鸢优化算法(blackwinged kite algorithm,BKA),具有优秀的全局搜索能力,收敛速度快,适用于对 VMD 参数的寻优,但是黑翅鸢和其他优化算法一样,容易陷入局部最优的问题。

而在深度学习方面,SVM、GAN 和 CNN 是常见的故障诊断模型。陈维望等^[13]提出了一种 VMD 混合域特征结合 SVM 的故障诊断模型,但是 SVM 对噪声十分敏感。李可等^[14]提出了基于约束式自编码器一生成对抗网络的故障诊断方法,但故障诊断的精度上仍有待提高。郗涛等^[15]认为,使用支持向量机、生成对抗网络等进行故障诊断,不同的故障之间要有一定的关联程度,很难对故障进行精确地诊断,因此提出了使用 VMD 结合卷积神经网络 CNN 以解决故障之间需要关联性的问题。但是传统的 CNN 模型由于感受野小,仍然会导致模型提取特征能力不足。而 Zhang 等^[16]提出的首层为宽卷积核的网络结构模型(wide convolutional neural network,WDCNN),具有更大的感受野,解决了传统 CNN 在故障诊断中精度不足的问题,并验证了该模型具有良好的特征提取和抗噪性能能力。

综上所述,本文采用融合遗传算法的交叉和变异操作方法对 BKA 进行改进,提高黑翅鸢优化算法对全局最优

解的搜索能力并防止其过早收敛。并且本文提出一种 GBKA-VMD-WDCNN 的信号处理和深度学习相结合的方法,通过改进 BKA 对 VMD 进行参数寻优,并利用 WDCNN 强大的分类能力提高对齿轮箱故障诊断准确率。实验表明本文所提方法具有较高的准确率,具有可行性和有效性。

1 基本原理

1.1 VMD 原理

VMD 是一种通过变分约束条件,自适应地将输入信号分解为 K 个有限带宽的本征模态分量的方法^[17]。其通过将各信号分量进行 Hilbert 变换并调制到对应基带,再通过求解调制信号梯度的 L_2 范数的平方来估计各模态的带宽,使得每个 IMF 的带宽之和最小,同时所有的 IMF 之和等于原始信号。其表达式为:

$$\begin{cases} \min \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ s.t. \sum_k u_k(t) = x(t) \end{cases} \quad (1)$$

式中: ∂_t 为对 t 求偏导, $\delta(t)$ 为狄拉克脉冲函数, $u_k(t)$ 为模态, $x(t)$ 为各模态的累加。

为了得到最优解,引入 Lagrange 乘子 $\lambda(t)$ 以及惩罚因子 α 将约束问题转化为非约束问题,其表达式为:

$$L = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \|x(t) - \sum_k u_k(t)\|_2^2 + \langle \lambda(t), x(t) - \sum_k u_k(t) \rangle \quad (2)$$

式中: L 为拉格朗日函数, $\lambda(t)$ 为 Lagrange 乘子。通过交替方向乘子算法求取鞍点,最终得到 K 个模态分量。其中 VMD 的参数 K 和惩罚因子 α 是分解信号的关键参数。

1.2 黑翅鸢优化算法(BKA)

黑翅鸢优化算法(BKA)是模拟黑翅鸢一系列行为的元启发式优化算法,具有非常高效的寻优能力。黑翅鸢的行为包括攻击行为和迁徙行为,其步骤如下:

1) 攻击行为

黑翅鸢擅长捕食草原小型哺乳动物和昆虫等,黑翅鸢在飞行过程中根据风速调整翅膀和尾部角度,静静盘旋观察猎物,然后迅速俯冲攻击。该攻击策略包括两种不同的攻击方式,用于全局探索和搜索。其表达式为:

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n(1 + \sin(r)) \times y_t^{i,j}, & p < r \\ y_t^{i,j} + n(2r - 1) \times y_t^{i,j}, & \text{其他} \end{cases} \quad (3)$$

$$n = 0.05 \times e^{-2 \times \left(\frac{t}{T} \right)^2} \quad (4)$$

式中: $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别表示第 t 和第 $(t+1)$ 次迭代中第 i 只黑翅鸢在第 j 维中的位置, r 是范围从 $0 \sim 1$ 的随机数, p 是固定值 0.9 , T 是最大迭代次数, t 是当前迭代次数。

2) 迁徙行为:

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0,1) \times (y_t^{i,j} - L_t^j), & F_i < F_{ri} \\ y_t^{i,j} + C(0,1) \times (L_t^j - m \times y_t^{i,j}), & \text{其他} \end{cases} \quad (5)$$

$$m = 2 \times \sin\left(r + \frac{\pi}{2}\right) \quad (6)$$

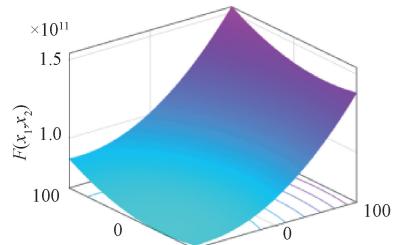
式中: L_t^j 表示在第 t 次迭代的第 j 维中黑翅鸢的领导者。 F_i 表示黑翅鸢在 t 次迭代进程中第 j 维中的位置, F_{ri} 表示在第 t 次迭代中从黑翅鸢获得的第 j 维随机位置的适应度值, $C(0,1)$ 是柯西突变。

1.3 改进的黑翅鸢优化算法(GBKA)

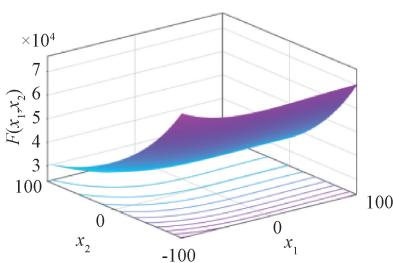
由于原始黑翅鸢在中后期会存在陷入局部最优的问题,本文通过在种群完成一次迭代的末尾融合借鉴了遗传算法的父辈基因交叉和变异策略来增强种群的多样性并提高全局搜索能力。

1) 父辈基因交叉策略

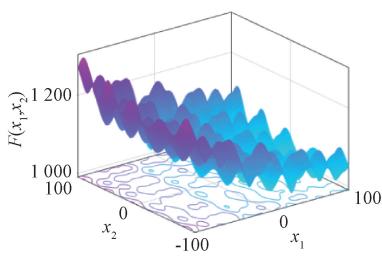
父辈基因交叉策略是利用随机掩码进行父辈基因重组生成两个子代其公式为:



(a) 测试函数1
(a) Test function 1



(c) 测试函数2
(c) Test function 2



(e) 测试函数3
(e) Test function 3

$$M = rand(1, dim) > 0.5 \quad (7)$$

$$\begin{aligned} OS1 &= MX_1 + (1 - M)X_2 \\ OS2 &= MX_2 + (1 - M)X_1 \end{aligned} \quad (8)$$

式中: X_1 和 X_2 是当前种群的随机两个不同的父辈, M 为随机掩码, $OS1$ 和 $OS2$ 为生成的新子代个体。

2) 随机变异策略:

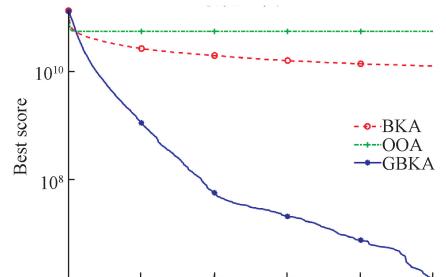
变异策略会随机改变个体的一部分基因,增加种群的多样性,防止陷入局部最优,其公式为:

$$\begin{aligned} mu &= randi([1, dim], 1) \\ X_{k,mu} &= lb_{mu} + (ub_{mu} - lb_{mu}) \times rand \end{aligned} \quad (9)$$

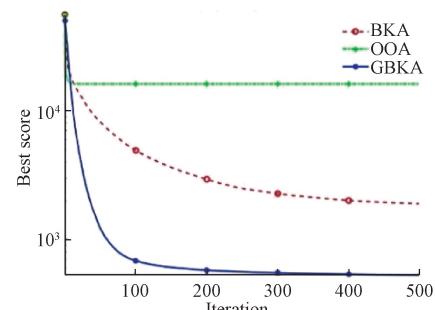
式中: $X_{k,mu}$ 是个体 k 在 mu 维度上随机生成的新的变异个体。

1.4 GBKA 性能测试

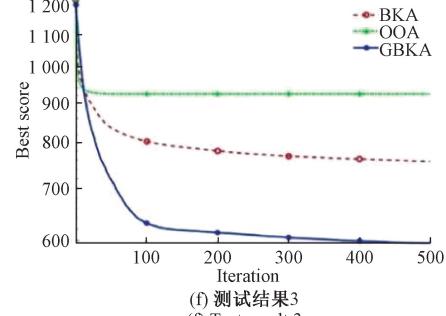
由于篇幅限制,选取 4 个测试函数进行测试,用于验证改进的 GBKA 的优越性,并与原始黑翅鸢算法 BKA、鱼鹰优化算法 OOA 进行对比。本文设置最大迭代次数为 500, 种群大小为 30, 维度为 30, 每个算法运行 50 次, 收敛曲线结果图如图 1(a)~(h) 所示。



(b) 测试结果2
(b) Test result 2



(d) 测试结果2
(d) Test result 2



(f) 测试结果3
(f) Test result 3

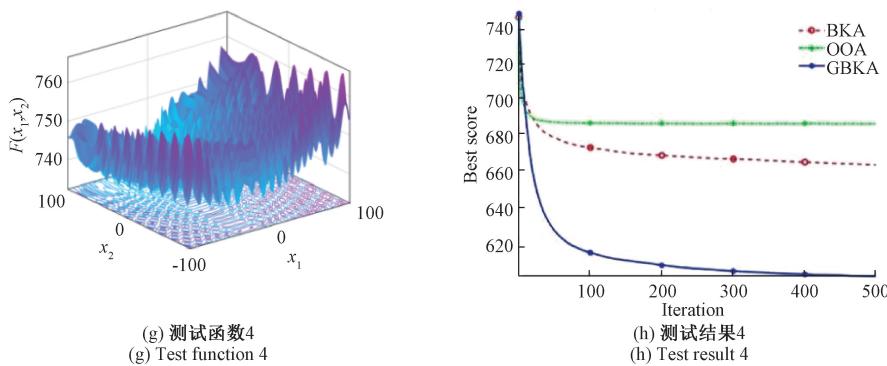


图 1 3 种优化算法在 4 个测试函数上的测试结果

Fig. 1 Test results of three optimization algorithms on four test functions

表 1 不同优化算法在 4 个测试函数上的指标

Table 1 Indicators of different optimization algorithms on four test functions

优化 算法	测试函数 1		测试函数 2		测试函数 3		测试函数 4	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差
OOA	5.668×10^{10}	7.190×10^9	1.617×10^4	2.894×10^3	9.242×10^2	3.389×10^1	6.854×10^2	8.546×10^0
BKA	1.169×10^{10}	1.158×10^{10}	1.892×10^3	2.721×10^3	7.572×10^2	4.883×10^1	6.629×10^2	8.240×10^0
GBKA	3.412×10^6	1.003×10^7	5.254×10^2	3.980×10^1	5.950×10^2	2.513×10^1	6.054×10^2	1.672×10^0

由图 1 以及表 1 可知,相比于 OOA 和 BKA 优化算法,改进的 GBKA 算法在这 4 个测试函数上 50 次运行的平均值和标准差均优于其他两种算法,表明通过融合父辈基因交叉和变异策略,能够增强种群多样性,帮助原始黑翅燕的领导者更容易跳出局部最优解,进而增强了其全局搜索能力,验证了改进黑翅燕算法的有效性。

1.5 WDCNN 模型

首层宽卷积神经网络 WDCNN 是一种当下热门的深度学习分类模型,由于其具有宽卷积核,使得模型能够具有更大的感受野和抗噪声能力,其结构为 5 个卷积层和 5 个最大池化层,这种结构使得该模型具有高稳定性和鲁棒性,其具体参数如表 2 所示。

2 GBKA-VMD-WDCNN 诊断模型

针对齿轮箱故障并提高诊断准确率,本文提出了一种基于 GBKA 优化 VMD 参数结合 WDCNN 的故障诊断模型。该诊断模型流程如下:

- 1) 获取两种不同工况的 5 种不同类型的原始齿轮箱振动信号;
- 2) 通过改进的 GBKA 优化算法对原始齿轮信号进行 VMD 的参数组合 $[K, \alpha]$ 的寻优;
- 3) 使用优化后的参数组合 $[K, \alpha]$ 对不同故障信号进行 VMD 分解;
- 4) 计算 VMD 分解后的所有 IMF 分量的相关系数,筛选出满足需求的模态分量并重构信号;
- 5) 构建 WDCNN 宽卷积神经网络模型;

表 2 WDCNN 结构参数

Table 2 WDCNN structure parameters

网络结构	参数设置
Conv1	核大小: 64×1 ; 步长: 8; 输出: 16
Maxpool1	核大小: 2×2 ; 步长: 1
Conv2	核大小: 3×1 ; 步长: 1; 输出: 32
Maxpool2	核大小: 2×2 ; 步长: 1
Conv3	核大小: 3×1 ; 步长: 1; 输出: 64
Maxpool3	核大小: 2×2 ; 步长: 1
Conv4	核大小: 3×1 ; 步长: 1; 输出: 64
Maxpool4	核大小: 2×2 ; 步长: 1
Conv5	核大小: 3×1 ; 步长: 1; 输出: 64
Maxpool5	核大小: 2×2 ; 步长: 1
Flatten	特征展开
Dense	输入: 100; 输出: 5
Softmax	5

6) 将重构信号划分为训练集、验证集和测试集,输入构建好的 WDCNN 模型进行训练进行测试;

7) 输入故障诊断结果。

GBKA-VMD-WDCNN 故障诊断模型结构流程如图 2 所示。

3 实验验证分析

3.1 实验数据

本文采用东南大学行星齿轮箱数据集进行故障诊断实验^[18]。该齿轮箱数据集共有两种工况: 20 Hz-0 和

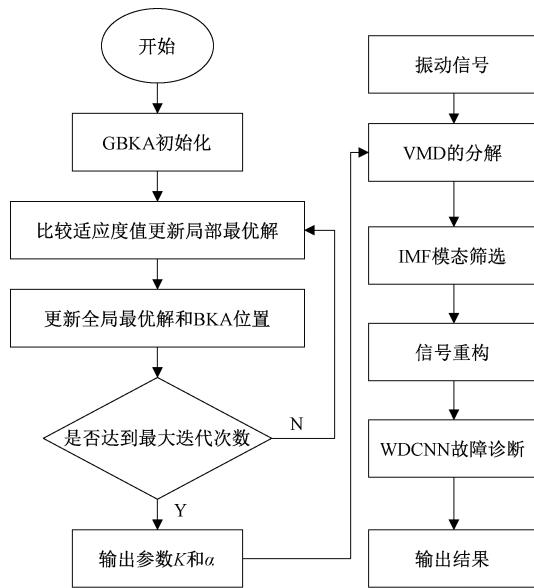


Fig. 2 GBKA-VMD-WDCNN model flowchart

30 Hz-2。本文对工况 20 Hz-0 命名为 A, 工况 30 Hz-2 命名为 B。该齿轮箱数据集有五种类型的齿轮状态, 包括一种健康状态和四种故障类型(断齿、缺齿、齿根裂纹、齿轮表面磨损)。该数据集的采样频率为 5 120 Hz, 每个故障信号长度为 1 048 560 个样本点。对 5 种类型进行标签处理, 如表 3 所示。本文一共采用 4 500 个总样本数, 每种类型 900 个样本, 每个样本包含 2 048 个数据点。划分为训练集 2 700 组, 验证集 900 组和测试集 900 组。

表 3 故障数据信息

Table 3 Fault data information

故障类型	工况 A/B 样本数量	标签
断齿	900	0
健康	900	1
断齿	900	2
根部裂纹	900	3
齿面磨损	900	4

3.2 VMD 分解与重构

本文以 30 Hz-2 工况下表面磨损故障信号为例, 如图 3 所示, 采用 GBKA-VMD 算法对齿轮箱振动数据进行处理, 本文以最小包络熵为适应度函数^[19], 通过 GBKA 算法对 VMD 的两个参数 K 和 α 得到最优的参数组合。其中, 采用 GBKA-VMD 进行寻优时, 种群数量设定为 15, 最大迭代次数设置为 20, K 的寻优范围为 $[3, 10]$, α 的寻优范围为 $[50, 3 000]$ 。经过 GBKA 寻优得到该故障信号下的最佳参数为 $[3 000, 4]$, 根据该参数组合对表面磨损信号进行 VMD 分解, 由于篇幅限制仅展示一个样本长度 2 048 的分解结果如图 4 所示。本文以皮尔逊相关系数作为指标筛选, 皮尔逊相关系数反应了各模态分量与原始信

号之间的相关性, 相关系数越大, 表明越接近原始信号, 计算原始总长度各模态分量的皮尔逊相关系数如表 4 所示。

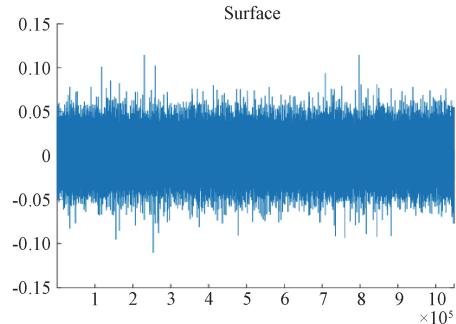


图 3 表面磨损原始故障信号

Fig. 3 Original fault signal of surface wear

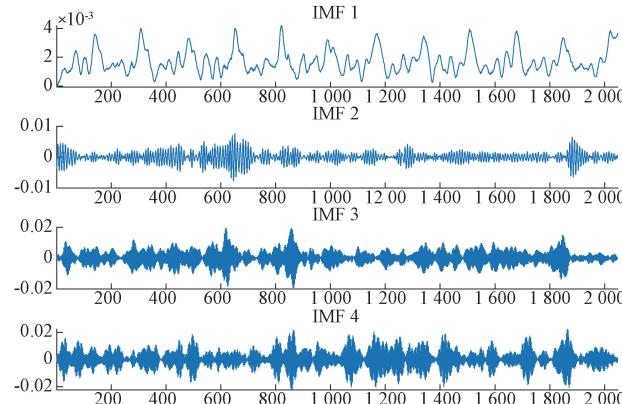


图 4 表面磨损故障 VMD 分解展示图

Fig. 4 VMD decomposition display of surface wear fault

表 4 各模态分量相关系数

Table 4 Correlation coefficients of various modal components

IMF 分量	相关系数
IMF1	0.159 1
IMF2	0.276 0
IMF3	0.624 4
IMF4	0.667 8

由表 4 可知, 在 suface 信号 VMD 分解之后的各模态中, IMF1 和 IMF2 均远小于 0.5, 而 IMF3 和 IMF4 均超过 0.6, 表明 IMF1 和 IMF2 可能存在过多噪声信号或冗杂信号, 而 IMF3 和 IMF4 包含更多的特征信号。因此选择 IMF3 和 IMF4 进行信号重构。

3.3 故障诊断实验

本次实验平台为 Windows 11 系统, 硬件配置为 CPU 为 i7-14700k; GPU 为 GTX-4080。将重构振动信号输入到 WDCNN 模型中进行故障诊断, 并且加入 Dropout 防止模型训练过程中过拟合, 实验中采用 Adam 优化器, 初始学习率为 0.001, batchsize 为 64, 损失函数为 CrossEntropyLoss 函数。本次实验中为了验证 GBKA-

VMD-WDCNN 的优越性和可行性,本次实验对 WDCNN、BKA-VMD-WDCNN 和 GBKA-VMD-CNN 其他 3 种方法进行对比,并对每种方法做 10 次实验防止偶然性,其对比结果如表 5 所示。

表 5 不同故障诊断方法在 A/B 工况上的平均准确率和标准差

Table 5 Average accuracy and standard deviation of different fault diagnosis methods on A/B operating conditions

方法对比	A 平均	A 标	B 平均	B 标
	准确率	准差	准确率	准差
WDCNN	93.788	3.890	92.711	4.063
BKA-VMD-WDCNN	98.279	1.653	98.734	1.287
GBKA-VMD-CNN	86.034	8.469	86.067	8.065
GBKA-VMD-WDCNN	99.645	0.686	99.978	0.046

由表 5 可知,两个不同工况的数据集上的平均准确率中 GBKA-VMD-WDCNN 均是最高的,分别为 99.645% 和 99.978%。本文模型相比于 BKA-VMD-WDCNN 在工况 A 下平均提升了 1.213%,在工况 B 下平均提升了 1.244%,并且标准差均小于 1%,波动性小,表明本文所提模型在两种工况上的稳定性均是最好的;所提方法相比于 GBKA-VMD 结合传统 CNN 模型在该故障数据上的平均准确率有大幅度的提升,进而验证了本文方法在该齿轮箱数据上具有优秀的故障诊断效果。其平均实验准确率结果如图 5 所示,在 A 和 B 工况上均多次达到 100% 的准确率,最高准确率混淆矩阵如图 6~7 所示。

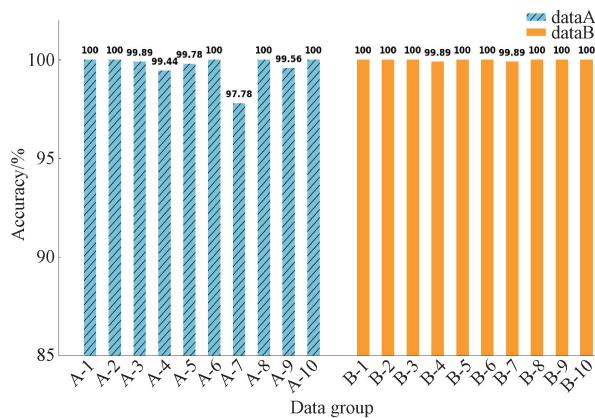


图 5 GBKA-VMD-WDCNN 在工况 A 与 B 上的平均准确率

Fig. 5 The average accuracy of GBKA-VMD-WDCNN under operating conditions A and B

综上可知,GBKA-VMD-CNN 在本文实验条件下的齿

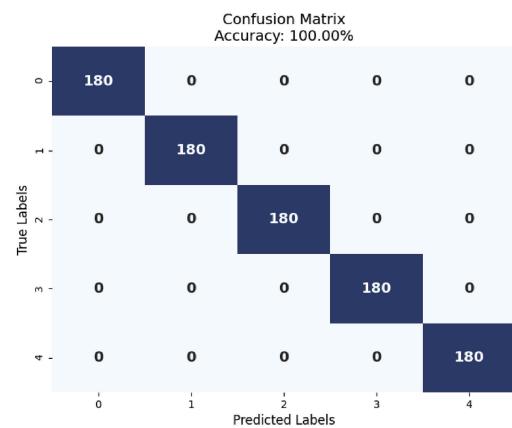


图 6 工况 A 上最高准确率混淆矩阵

Fig. 6 The highest accuracy confusion matrix on operating condition A

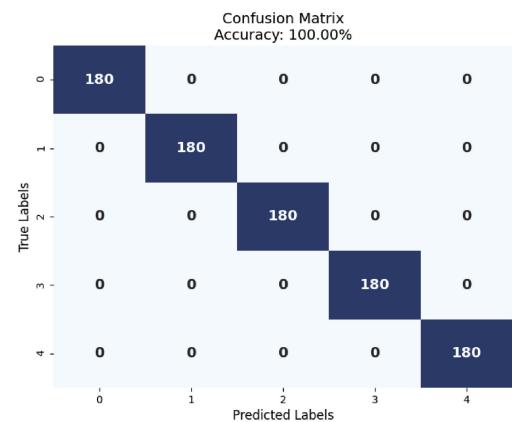


图 7 工况 B 上最高准确率混淆矩阵

Fig. 7 The highest accuracy confusion matrix on operating condition B

轮箱故障诊断中相比于其他方法具有更高的平均准确率,并且实验中多次达到 100% 的诊断效果,证明了该方法具有可行性和稳定性。

3.4 噪声实验

由 3.3 节可知,BKA-VMD-WDCNN 和 GBKA-VMD-WDCNN 这两种故障诊断方法在原始数据集上取得了优秀的效果,但是在实际工业环境中不可避免地存在大量噪声,因此本文对工况 B 的原始数据添加不同信噪比的噪声以模拟实际工业场景的噪声干扰,并对比这两种故障诊断方法在噪声环境下的性能,实验如图 8 所示。

结果表明,这两种故障诊断方法的准确率均随着噪声的增强而不断下降,但是由于 VMD 算法具有去除噪声的效果,使得噪声对整体模型的影响较小,并且 GBKA-VMD-WDCNN 在不同信噪比下仍然领先 BKA-VMD-WDCNN,进一步验证了本文所提方法的有效性和稳定性。

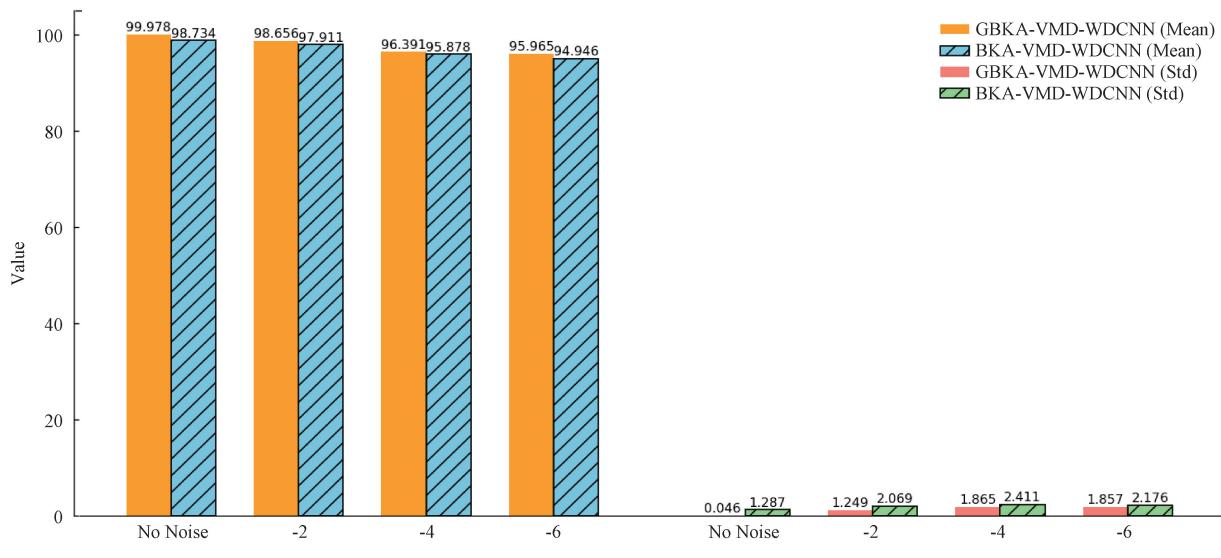


图 8 不同信噪比下的模型对比

Fig. 8 Comparison of models under different signal to noise ratios

4 结 论

本文提出了一种引入遗传算法的父辈基因交叉和变异策略的改进 GBKA 算法, 通过融合这两种策略增加种群的多样性, 提高全局搜索能力, 用以解决原始 BKA 可能存在陷入局部最优的问题, 并为 BKA 优化算法的改进提供了一种新的改进思路和方法; 即通过融合其他算法来提高本算法的性能; 本文还提出了一种基于 GBKA-VMD 结合 WDCNN 的故障诊断模型用以解决当前齿轮箱故障诊断效果不佳的问题。该模型利用 GBKA 对 VMD 进行参数寻优并对信号进行分解和重构, 最后利用宽卷积神经网络 WDCNN 进行故障诊断实验, 证明了本文所提方法的可行性和稳定性, 为齿轮箱故障诊断提供了一种新的思路和方法。

尽管 GBKA 在寻优效果上优异, 但是因为引入了新的策略导致算法更为复杂, 并且本文所提齿轮箱故障诊断模型对设备要求较高, 因此未来会针对在减少 BKA 算法的复杂度上以及对故障诊断模型轻量化进行深入研究。

参考文献

- [1] 董路南, 邓艾东, 范永胜, 等. 基于 VMD 和改进 DenseNet 的滚动轴承故障诊断 [J]. 动力工程学报, 2023, 43(11): 1500-1505, 1522.
- DONG L N, DENG AI D, FAN Y SH, et al. Rolling bearing fault diagnosis based on VMD and improved DenseNet [J]. Journal of Chinese Society of Power Engineering, 2023, 43(11): 1500-1505, 1522.
- [2] 何坤敏, 王霄, 杨靖, 等. 基于 RF 特征优选和 WOA-ELM 的风电齿轮箱故障诊断 [J]. 电子测量技术, 2023, 46(5): 57-64.
- HE K M, WANG X, YANG J, et al. Fault diagnosis

of wind turbine gearbox based on RF feature optimization and WOA-ELM [J]. Electronic Measurement Technology, 2023, 46(5): 57-64.

- [3] 韩延, 李超, 黄庆卿, 等. 小样本下时序注意力边界增强原型网络的齿轮箱故障诊断方法 [J]. 电子测量与仪器学报, 2023, 37(2): 90-98.
- HAN Y, LI CH, HUANG Q Q, et al. Boundary-enhanced prototype network with time-series attention forgearbox fault diagnosis under limited samples [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 90-98.
- [4] 朱哈娜, 刘慧明. 基于改进 VMD 与 GS_SVM 的轴承故障诊断 [J]. 电子测量技术, 2020, 43(21): 71-76.
- ZHU H N, LIU H M. Bearing fault diagnosis based on improved VMD and GS_SVM [J]. Electronic Measurement Technology, 2020, 43(21): 71-76.
- [5] 刘剑生, 王细洋. 基于 EMD 与 BP 神经网络的齿轮故障诊断 [J]. 失效分析与预防, 2020, 15(6): 370-375, 392.
- LIU J SH, WANG X Y. Gear fault diagnosis based on EMD and BP neural network [J]. Failure Analysis and Prevention, 2020, 15(6): 370-375, 392.
- [6] 金志浩, 陈广东, 汪红, 等. 基于 EEMD-FSK 的滚动轴承故障诊断 [J]. 机床与液压, 2023, 51(4): 180-183.
- JIN ZH H, CHEN G D, WANG H, et al. Fault diagnosis of rolling bearing based on EEMD-FSK [J]. Machine Tool & Hydraulics, 2023, 51(4): 180-183.
- [7] 史书杰, 赵凤强, 王波, 等. 基于 EEMD 能量熵和 GJO-KELM 的滚动轴承故障诊断 [J]. 电子测量技术, 2024, 47(6): 116-122.

- [14] SHI SH J, ZHAO F Q, WANG B, et al. Fault diagnosis of rolling bearings based on EEMD energy entropy and GJO-KELM[J]. Electronic Measurement Technology, 2024, 47(6): 116-122.
- [8] DRAGOMIRETSKIY K, ZOSKO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [9] 刘秀丽, 王鸽, 吴国新, 等. VMD 及 PSO 优化 SVM 的行星齿轮箱故障诊断[J]. 电子测量与仪器学报, 2022, 36(1): 54-61.
- LIU X L, WANG G, WU G X, et al. Fault diagnosis method of planetary gear box based on variational modal decomposition and particle swarm optimization support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (1): 54-61.
- [10] 刘明昊, 陆金桂, 张佳坤, 等. 基于 VMD 能量熵值的齿轮箱滚动轴承故障诊断[J]. 煤矿机械, 2023, 44(10): 173-175.
- LIU M H, LU J G, ZHANG J K, et al. Fault diagnosis of gearbox rolling bearing based on VMD energy entropy [J]. Coal Mine Machinery, 2023, 44(10): 173-175.
- [11] 夏焰坤, 寇坚强, 李欣洋. 基于 IWOA-VMD 的永磁同步电机匝间短路故障振动信号去噪方法[J]. 电子测量与仪器学报, 2024, 38(4): 202-216.
- XIA Y K, KOU J Q, LI X Y. Denoising method for vibration signal of inter-turn short circuit fault in PMSM based on IWOA-VMD [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 202-216.
- [12] WANG J, WANG W C, HU X X, et al. Black-winged kite algorithm: a nature-inspired metaheuristic for solving benchmark functions and engineering problems[J]. Artificial Intelligence Review, 2024, 57(4): 98.
- [13] 陈维望, 李军霞, 张伟. 基于 VMD 混合域特征和 SSA-SVM 的滚动轴承故障诊断[J]. 机床与液压, 2022, 50(24): 159-164.
- CHEN W W, LI J X, ZHANG W. Rolling bearing fault diagnosis based on VMD hybrid domain feature and SSA-SVM [J]. Machine Tool & Hydraulics, 2022, 50(24): 159-164.
- [14] 李可, 何坚光, 宿磊, 等. 基于 CAE-GAN 的滚动轴承故障诊断方法[J]. 振动与冲击, 2023, 42(23): 65-70, 86.
- LI K, HE J G, SU L, et al. Fault diagnosis method for rolling bearing based on CAE-GAN[J]. Journal of Vibration and Shock, 2023, 42(23): 65-70, 86.
- [15] 鄒涛, 杨威振. 优化 VMD 与 CNN 在齿轮箱故障诊断应用研究[J]. 机械科学与技术, 2022, 41 (12): 1829-1838.
- XI T, YANG W ZH. Research on gearbox fault diagnosis method based on parameter optimized VMD and CNN[J]. Mechanical Science and Technology for Aerospace Engineering, 2022, 41(12): 1829-1838.
- [16] ZHANG W, PENG G, LI C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. Sensors, 2017, 17(3): 425.
- [17] 江星星, 宋秋昱, 杜贵府, 等. 变分模式分解方法研究与应用综述[J]. 仪器仪表学报, 2023, 44 (1): 55-73.
- JIANG X X, SONG Q Y, DU G F, et al. Review on research and application of variational mode decomposition [J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 55-73.
- [18] SHAO S , MCALEER S , YAN R , et al. Highly accurate machine fault diagnosis using deep transfer learning [J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455.
- [19] 杨森, 王恒迪, 崔永存, 等. 基于改进 AFSA 的参数优化 VMD 和 ELM 的轴承故障诊断[J]. 组合机床与自动化加工技术, 2023(4): 67-70.
- YANG S, WANG H D, CUI Y C, et al. Bearing faultdiagnosis based on paramater optimized VMD with improved AFSA and ELM[J]. Modular Machine Tool & Automatic Manufacturing Technique , 2023(4): 67-70.

作者简介

万佳诚,硕士研究生,主要研究方向为优化算法、信号处理和故障诊断。

E-mail:1694401996@qq.com

曾宪文(通信作者),教授,硕士生导师,主要研究方向为故障诊断和智能系统与应用。

E-mail: zengxw@sdju.edu.cn