

DOI: 10.13382/j.jemi.B2508091

基于空洞卷积与改进 BKA-LSSVM 的 旋转机械故障诊断

赵小强^{1,2} 齐祥德¹

(1. 兰州理工大学电气工程与信息工程学院 兰州 730050;

2. 兰州理工大学国家级电气与控制工程实验教学中心 兰州 730050)

摘要:轴承和齿轮作为机械传动系统中至关重要的部件,其故障诊断对于保证设备的安全运行具有重要意义。为有效提取旋转机械故障信号特征、解决分类器对提取特征存在较强依赖的问题,提出了一种基于空洞卷积和改进黑翅鸢优化最小二乘支持向量机(BKA-LSSVM)的故障诊断模型。首先利用同步压缩小波变换将一维振动信号转化为具有高分辨率时频表示的二维时频图像;其次构建多尺度级联的空洞卷积模块,利用膨胀率调节机制实现对故障特征的分层级、多粒度提取,有效捕捉不同尺度下的故障模式特征,并将全连接层的结果作为 BKA-LSSVM 分类层的输入,并通过引入非线性增长模型动态调节扰动系数,以及构建随机搜索机制对 BKA 进行改进;最后利用改进后的 BKA 对 LSSVM 的参数进行优化来提高模型的分类精度。在两个数据集上进行验证,实验结果表明,所提模型在样本数为 10 时准确率高于 87%,在信噪比为-4 时准确率高于 95%,验证了所提模型较对比模型具有更强的抗噪能力和泛化性能。

关键词: 旋转机械;故障诊断;空洞卷积;黑翅鸢优化算法;最小二乘支持向量机

中图分类号: TH133.33; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.2020

Fault diagnosis of rotating machinery based on dilated convolution and improved BKA-LSSVM

Zhao Xiaoqiang^{1,2} Qi Xiangde¹

(1. School of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. National Experimental Teaching Center for Electrical and Control Engineering, Lanzhou University of
Technology, Lanzhou 730050, China)

Abstract: Bearings and gears are crucial components in mechanical transmission systems, and their fault diagnosis is of great significance for ensuring the safe operation of equipment. To effectively extract the features of rotating machinery fault signals and solve the problem of strong dependence of classifiers on feature extraction, this paper proposes a fault diagnosis model based on dilated convolution and improved black winged kite optimized least squares support vector machine (BKA-LSSVM). Firstly, the one-dimensional vibration signal is transformed into a two-dimensional time-frequency image with high-resolution time-frequency representation using synchronous compression wavelet transform. Secondly, a multi-scale cascaded dilated convolution module is constructed, and the dilation rate adjustment mechanism is used to achieve hierarchical and multi granularity extraction of fault features, effectively capturing fault mode features at different scales. The results of the fully connected layer are used as inputs to the BKA-LSSVM classification layer, and a nonlinear growth model is introduced to dynamically adjust the disturbance coefficient. A random search mechanism is constructed to improve the BKA. Finally, the improved BKA is used to optimize the parameters of LSSVM to improve the classification accuracy of the model. Validation was conducted on two datasets, and the experimental results showed that the proposed model had an accuracy rate of over 87% when the sample size was 10, and an accuracy rate of over 95% when the signal-to-noise ratio was -4. This validates that the proposed model has stronger noise resistance and generalization performance compared to the comparison model.

Keywords: rotating machinery; fault diagnosis; hollow convolution; black winged kite optimization algorithm; least squares support vector machine

0 引言

旋转机械设备广泛应用于机械制造、航空航天、运输、能源开发和其它领域。旋转机械设备一旦发生故障,会导致设备停机、生产中断,造成生产损失,甚至可能导致设备失控、火灾等重大安全事故,造成人员伤亡和财产损失^[1]。因此,构建一种能够深入揭示旋转机械振动信号与故障模式间复杂关系的算法显得尤为关键。

浅层机器学习是依靠传感器采集的机械运行信号,经信号处理提取故障特征后,进行故障分类识别,在机械故障诊断领域应用广泛。主要算法包括支持向量机(support vector machine, SVM)^[2]、K-近邻算法(K-Nearest Neighbors, KNN)^[3]以及决策树(decision tree, DT)^[4]等。但浅层机器学习用于旋转机械故障识别有一定的局限,存在表达能力差、泛化弱、精度低,难以适应复杂工况等问题。SVM 作为极具代表性且收敛速率优异的分类器,在处理小样本、非线性及高维空间识别等问题时表现出色,具备较强的处理能力和优异的效果。然而, SVM 分类器采用了求解二次规划问题的方法,计算量较大,为了解决这个问题,许多学者提出一系列改进方法,例如 SVM 光分解算法^[5]、邻域算法(neighborhood search, NS)^[6]、最小二乘支持向量机算法(least squares support vector machine, LSSVM)等^[7]。其中 LSSVM 因其实现简单、分类和计算效率高等优点,得到广泛应用。尽管模型在诸多领域展现出潜力,但其分类性能却深受其参数设置的限制,参数的细微差异都会对模型效能产生极大的扰动。因此,许多学者通过引入群智能算法对 LSSVM 的参数实施优化策略,以提高其在故障诊断中的准确性。文献[8]提出一种多策略融合改进北方苍鹰优化算法(northern goshawk optimization, NGO)优化 LSSVM 的滑动电接触失效诊断方法,有效地提高了 LSSVM 的分类性能。文献[9]利用鹈鹕优化算法(pelican optimization algorithm, POA)优化了 LSSVM 多分类器,在变压器电热故障诊断应用中取得了较好的分类结果。上述相关算法是采用传统群智能优化算法对 LSSVM 的参数进行优化,存在着收敛速度慢、调节参数多以及容易陷入局部最优解等缺陷。

鉴于传统群智能算法在优化 LSSVM 参数时存在的不足,本文采用黑翅鸢优化算法(Black-winged Kite Optimization Algorithm, BKA)来对 LSSVM 的参数进行优化。文献[10]将 BKA 与哈里斯鹰优化算法(harris hawks optimization, HHO)、鲸鱼优化算法(whale optimization algorithm, WOA)、麻雀搜索算法(sparrow search algorithm, SSA)在不同测试指标上进行比较,结果表明 BKA 在搜索精度、收敛速度和稳定性方面具有较强的竞

争力,在具有良好的全局区域探索能力的同时避免了局部最优问题。文献[11]构建 SSA-SVM 诊断模型对风力发电机进行故障诊断,文献[12]构建 WOA 对 LSSVM 进行优化来对强噪声下的轴承进行故障诊断,上述方法也印证了 BKA-LSSVM 诊断模型的可行性。

近年来,深度学习技术在机械故障诊断方面得到了广泛的探索和应用,并取得了显著的研究进展。以卷积神经网络(convolutional neural network, CNN)为代表的深度学习方法从原始监测数据中自动学习和提取判别性特征,在旋转机械故障诊断领域中取得了显著的成果。文献[13]提出通过改进神经网络(modified CNN, MCNN)提取电压信号特征,使用 SVM 对电压信号特征进行分类,实现了电力变换器故障的精确检测。文献[14]将多个传感器采集到的多源振动信号输入到卷积神经网络,提出一种多通道输入的齿轮箱故障诊断的方法。文献[15]提出一种基于双通道 CNN 与 SSA-SVM 的滚动轴承故障诊断方法,提高了模型的特征学习能力,在轴承故障诊断中相比其它传统方法有着更高的准确率。上述方法都利用传统卷积神经网络从信号中提取故障特征,存在从信号中提取特征不足以及提取特征过程中需要更大的感受野以充分捕获信号的时间相关性的局限。

针对上述问题,本文提出了一种基于空洞卷积结合 BKA 优化 LSSVM 的故障诊断方法,首先构建混合空洞卷积模块(dilated convolution network, DCN)作为特征的初步提取阶段,然后利用改进的 BKA 优化算法对 LSSVM 进行参数优化,构建 BKA-LSSVM 多分类器进行故障分类。通过在东南大学齿轮箱数据集、WT-行星齿轮箱数据集分别设计跨域、小样本情况和噪声环境 3 种常见的复杂故障任务。实验结果表明该方法在旋转机械故障诊断领域具有显著优势。本文主要贡献总结如下:

(1) 在特征提取阶段构建空洞卷积模块,并通过调整空洞卷积的膨胀率,以适应信号不同尺度的特征,使其对于不同类型和大小的故障具有更好的适应性,提取到的故障特征更加全面。

(2) 通过改进基础 BKA 优化算法,并将其应用于 LSSVM 参数的优化,优化后的 BKA-LSSVM 分类器能够有效提升故障模式分类的准确性,从而增强模型的诊断精度。

1 理论基础

1.1 同步压缩小波变换

传统的小波变换在时频分析中存在一定的局限性,比如时频分辨率不够高、缺乏自适应性等问题。同步压缩本质上是在时频平面上重新排列小波系数,使能量聚集到真实瞬时频率附近,时频表示更加集中,非常适合用

于分析时变非平稳信号^[16]。

假设信号 $f(t) \in L^2(R)$, 则信号的连续小波变换 $WT(a, b)$ 为:

$$WT(a, b) = \int_{-\infty}^{+\infty} f(t) \tilde{\psi}(a, b) dt \quad (1)$$

式中: a, b 分别表示尺度、位移因子; $\psi(a, b) = \psi[(t - b)/a] / \sqrt{|a|}$ 表示小波基函数; $\tilde{\psi}(\cdot)$ 为 $\psi(\cdot)$ 共轭。

通过分析可知, 在小波域中 (a, b) 位置的瞬时频率信息为:

$$\omega_x^{(a, b)} = \frac{-j}{W(a, b)} \frac{\partial}{\partial b} W(a, b) \quad (2)$$

式中: $\omega_x(a, b)$ 为瞬时频率; j 为虚数单位。

对 $\omega_x(a, b)$ 沿尺度 a 方向整合, 归划到频域中 $\omega = \omega_x(a, b)$ 的位置上, 则同步压缩变换定义为:

$$\begin{cases} S_{st}(\omega, b) = \int_{A(b)} W(a, b) a^{-3/2} \delta(W(a, b) - \omega) da \\ A(b) = \{a, W(a, b) \neq 0\} \end{cases} \quad (3)$$

式中: $S_{st}(\omega, b)$ 表示信号 b 的同步压缩函数; ω 表示角频率。

1.2 空洞卷积

空洞卷积由 Chen 等^[17]提出, 与普通的 CNN 和循环神经网络(recurrent neural network, RNN)相比, 空洞卷积支持感受野的指数级扩展, 而不降低特征图的分辨率或增加参数的数量。空洞卷积是在原始卷积的基础上增加了膨胀率, 能将卷积核扩张到膨胀率所约束的尺度中, 并将原卷积核中未被占用的区域填充为 0, 不同膨胀率的空间卷积运算如图 1 所示。




图 1 不同膨胀率的空间卷积运算示意图

Fig. 1 Schematic diagram of dilated convolution operation with different expansion rates

空洞卷积核与原始卷积核的大小关系如式(4)所示。

$$k' = k + (k - 1)(r - 1) \quad (4)$$

式中: k' 示空洞卷积核大小; k 表示原始卷积核大小; r 表示膨胀系数。

空洞卷积感受野与普通卷积感受野的关系如式(5)所示。

$$F_i = (F_{i-1} - 1) \times stride + k_i \quad (5)$$

式中: F_i 表示第 i 层的感受野; F_{i-1} 表示第 $i-1$ 层的感受野; $stride$ 表示步长; k 表示卷积核大小。

采用空洞卷积后, 感受野计算如式(6)所示。

$$\begin{cases} F_i = (F_{i-1} - 1) \times stride + k' = \\ (F_{i-1} - 1) \times stride + k + (k - 1)(r - 1) \end{cases} \quad (6)$$

1.3 BKA 优化算法

BKA 优化算法是一种受自然启发的群智能优化算法, 其灵感来源于黑翅鸢这种动物的生存策略^[18]。BKA 集成了柯西突变策略和领导者策略, 增强了算法的全局搜索能力, 提高了算法的收敛速度, 其基本原理如下:

1) 种群初始化

采用随机初始化, 均匀地分配每只黑翅鸢的位置:

$$X_i = BK_{lb} + rand(BK_{ub} - BK_{lb})j \quad (7)$$

式中: i 为 1 到种群个体数量 pop 之间的整数; BK_{lb} 和 BK_{ub} 分别为第 j 维黑翼鸢的下界和上界; $rand$ 为 $[0, 1]$ 之间随机选取的值。

在初始化过程中, BKA 选择适应度值最好的个体作为初始群体中的 $leader X_L$, 这被认为是黑翼鸢的最优位置。初始领导者 X_L 的数学表示如式(8)所示(以最小值为例)。

$$\begin{cases} f_{best} = \min(f(X_i)) \\ X_L = X(\text{find}(f_{best} == f(X_i))) \end{cases} \quad (8)$$

2) 攻击行为

黑翅鸢在飞行过程中根据风速调整翅膀和尾巴的角度, 静静地悬停观察猎物, 然后迅速俯冲攻击。该策略包括不同的攻击行为, 用于全局探索和搜索。黑翼鸢攻击行为的数学模型如式(9)和式(10)所示。

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n(1 + \sin(r)) \times y_t^{i,j}, p < r \\ y_t^{i,j} + n \times (2r - 1) \times y_t^{i,j}, \text{else} \end{cases} \quad (9)$$

$$n = 0.05 \times e^{-2 \times (\frac{t}{T})^2} \quad (10)$$

式中: $y_t^{i,j}$ 和 $y_{t+1}^{i,j}$ 分别表示第 i 只黑翼鸢在第 j 维和 $(t+1)$ 次迭代步骤中的位置; r 为 $0 \sim 1$ 之间的随机数; p 为 0.9 的常数; T 是迭代的总次数; t 是到目前为止已经完成的迭代次数。

3) 迁徙行为

BKA 算法提出了基于鸟群迁徙的假设: 如果当前种群的适应度值小于随机种群的适应度值, 那么领导者将放弃领导并加入迁徙种群, 这表明它不适合领导种群前进。相反, 如果当前种群的适应度值大于随机种群的适应度值, 则会引导种群到达目的地。黑翼鸢迁徙行为的数学模型如式(11)和(12)所示。

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0, 1) \times (y_t^{i,j} - L_i^j), F_i < F_{r_i} \\ y_t^{i,j} + C(0, 1) \times (L_i^j - m \times y_t^{i,j}), \text{else} \end{cases} \quad (11)$$

$$m = 2 \times \sin(r + \pi/2) \quad (12)$$

式中: L_i^j 表示到目前为止第 t 次迭代的第 j 维黑翼风筝的领先得分者; $y_i^{i,j}$ 和 $y_{i+1}^{i,j}$ 分别表示第 i 只黑翼鸢在第 j 维和 $(t+1)$ 次迭代步骤中的位置; F_i 表示任一黑翼鸢在第 t 次迭代中获得的第 j 维当前位置; $F_{r,i}$ 表示第 t 次迭代中任意黑翼鸢在第 j 维随机位置的适应度值; $C(0,1)$ 代表柯西突变, 如式(13)所示。

$$f(x, \delta, \mu) = \frac{1}{\pi} \frac{1}{x^2 + 1} \quad (13)$$

1.4 LSSVM 算法

最小二乘法是一种通过最小化误差平方和来求解最优拟合函数的方法, 如式(14)所示。

$$\min \sum_{i=1}^n e_i^2 = \min \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 e_i \quad (14)$$

式中: e_i 为误差项; \hat{Y}_i 为预测值; Y_i 为实际值。

SVM 的学习问题可以看作是一个有约束的二次规划(QP)问题^[19]。对于凸二次规划问题, SVM 的训练效率都较低。LSSVM 是 SVM 的扩展^[20], 对误差项进行双范数处理, 将约束条件中的不等式转化为等式, 将误差平方化到目标函数中, 并且该优化问题通过卡鲁什-库恩-塔克条件(KKT)来求解。它可以有效地降低问题求解的复杂度并减少计算时间。LSSVM 的优化函数如式(15)和(16)所示。

$$\min \frac{1}{2} \|\omega\|^2 + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (15)$$

$$\begin{cases} \text{s. t. } y_i(\omega^T \varphi(x_i) + b) - 1 + e_i = 0 \\ i = 1, 2, \dots, n \end{cases} \quad (16)$$

式中: ω 是权重向量; γ 是惩罚因子。

求解式(16), 并引入拉格朗日变换式, 可得:

$$\begin{cases} L(\omega, b, e, a) = \frac{1}{2} \|\omega\|^2 + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 - \\ \sum_{i=1}^n a_i (y_i(\omega^T \varphi(x_i) + b) - 1 + e_i) \end{cases} \quad (17)$$

式中: b 是偏置项; a 是拉格朗日因子; a_i 是元素向量。

计算 ω, b, a, e 的偏导数, 使它们为 0。参数可通过求解线性方程得到。

最后得到分类决策函数如式(18)所示。

$$f(x) = \text{sign} \left(\sum_{i=1}^n a_i y_i K(x, x_i) + b \right) \quad (18)$$

式中: $K(x, x_i)$ 为核函数, 用于将输入向量从低维空间映射到高维空间, 核函数可分为多项式函数、径向基函数(RBF)和 Sigmoid 函数, 其中 RBF 基核函数通用性强, 能处理线性与非线性数据, 具有良好的局部特性, 且在模型训练时收敛速度快, 使其在众多应用场景中备受青睐。因此本文提出的故障分类模型采用 RBF 核函数, 如式(19)所示。

$$K(x, x_i) = \exp \left(- \frac{\|x - x_i\|^2}{2\sigma^2} \right) \quad (19)$$

综上所述, 优化算法需要优化两个参数, 即 RBF 基核函数的参数 σ^2 和惩罚因子 γ 。

2 故障诊断模型

2.1 DCN 模块

对于旋转机械的振动信号, 表现出长相关性特征, 包括轴承固有工作信号、故障冲击激励、以及系统周期信号等多源成分^[21]。不同故障模式的信号在时间序列上表现出独特的依赖关系, 以内圈故障为例, 其信号可能在数十个转频周期内存在微弱但持续的周期性冲击, 但是传统卷积神经网络在处理此类长序列信号时, 因固定卷积核尺寸难以有效捕捉跨周期的特征关联, 导致诊断准确率受限。而空洞卷积通过引入膨胀率参数, 以非连续采样的方式扩大卷积核的有效作用范围, 实现对长序列信号的上下文信息整合, 从而能够高效处理具有长程依赖特性的振动信号样本。但简单堆叠高膨胀率卷积层易引发网格效应, 导致卷积核采样点在特征图上分布不均, 造成局部细节信息丢失和特征不连续性, 尤其在轴承故障信号的边界特征(如冲击信号的起始与结束时刻)提取中表现显著, 难以平衡全局信息捕捉与局部细节提取。此外, 简单空洞卷积对不同尺度特征的融合能力有限, 难以同时兼顾振动信号中的高频细节(如早期故障的微弱冲击)与低频趋势(如转频及其谐波成分)。因此, 设计一种能平衡大感受野、多尺度特征提取与抗网格效应的空洞卷积结构, 是实现旋转机械故障精准诊断的关键。

为解决上述问题, 本文设计了一种混合空洞卷积模块, 其结构如图 2 所示, 并通过以下机制优化空洞卷积结构。

1) 机制 1 首层细节保留机制

将模块首层空洞卷积的膨胀率 r_0 固定为 1, 即等效为标准卷积操作。这一设计确保网络高层特征图的每个像素点, 均可完整利用底层特征图感受野内的全部信息。在轴承振动信号处理中, 底层特征包含故障冲击的关键时刻、瞬时频率变化等重要细节, 若初始采用高膨胀率卷积, 可能导致这些信息遗漏, 进而影响后续特征提取的准确性。标准卷积操作如式(20)所示。

$$y_{i,j} = \sum_{m,n} w_{m,n} \cdot x_{i+m,j+n} r_0 \quad (20)$$

式中: x 为输入特征图; y 为输出特征图; w 为卷积核权重; (i, j) 为输出特征图坐标; (m, n) 为卷积核内坐标。

2) 机制 2 多尺度特征协同提取机制

采用锯齿形膨胀率序列 $r = [r_1, r_2, \dots, r_k]$ 替代单一固定膨胀率, 其中序列元素交替为小膨胀率(如 1, 2)与

大膨胀率(如 3,5)。这种设计通过不同膨胀率的交替卷积,实现多尺度特征的高效提取:

小膨胀率卷积 $r \in \{1,2\}$ 时,卷积核采样点密集,可精准捕捉振动信号中的高频细节与局部结构信息。例如在轴承早期故障诊断中,小膨胀率卷积能有效提取微弱冲击信号的瞬时频率变化、相位偏移等特征。

大膨胀率卷积 $r \in \{3,5\}$ 时,卷积核感受野显著扩大,可跨越较长时间序列,提取信号的宏观趋势与周期模式,如轴承转频及其倍频成分。

通过交替执行不同膨胀率的卷积操作,模块可动态融合从细粒度到粗粒度的特征,避免网格效应导致的边界模糊问题。同时,锯齿形序列的设计使卷积核在局部区域内形成非对称采样模式,增强对复杂信号结构的适应性。

3) 机制 3 非均匀采样约束机制

为进一步增强感受野的不规则性与多样性,避免特征冗余,要求膨胀率序列满足最大公约数约束,如式(21)所示。

$$gcd(r_1, r_2, \dots, r_k) \leq 1 \tag{21}$$

该约束确保卷积核采样点在特征图上的分布尽可能

分散,减少重复计算区域。例如, $r = [1,3,5]$ 时,其公约数为 1,相比 $r = [2,4,6]$ 等序列,能覆盖更广泛的特征区域,有效提升模型对非平稳振动信号的特征提取能力。

根据上述设计策略,初步选用 $r = [1,2,3,1,2,3]$ 、 $[1,2,5,1,2,5]$ 、 $[1,3,5,1,3,5]$ 3 种不同膨胀率的混合空洞卷积模块,并通过实验观察不同膨胀率下的模型诊断效果,重复 10 次实验取平均值,实验结果如表 1 所示,可知,当 $r = [1,2,5,1,2,5]$ 时本文所提模型效果较好,平均准确率为 99.85%,且训练时间较短,因此本文所提模型选择 $r = [1,2,5,1,2,5]$ 的混合空洞卷积模块,如图 2 所示,所提的空洞卷积块结构如图 3 所示,并在空洞卷积块后加入池化层可以降低原始信号中的噪声对特征的影响,为特征提取提供强有力的保障。

表 1 不同膨胀率实验结果

膨胀率 r	准确率/%	训练时间/s
$[1,2,3,1,2,3]$	98.25	162
$[1,2,5,1,2,5]$	99.85	186
$[1,3,5,1,3,5]$	99.12	175

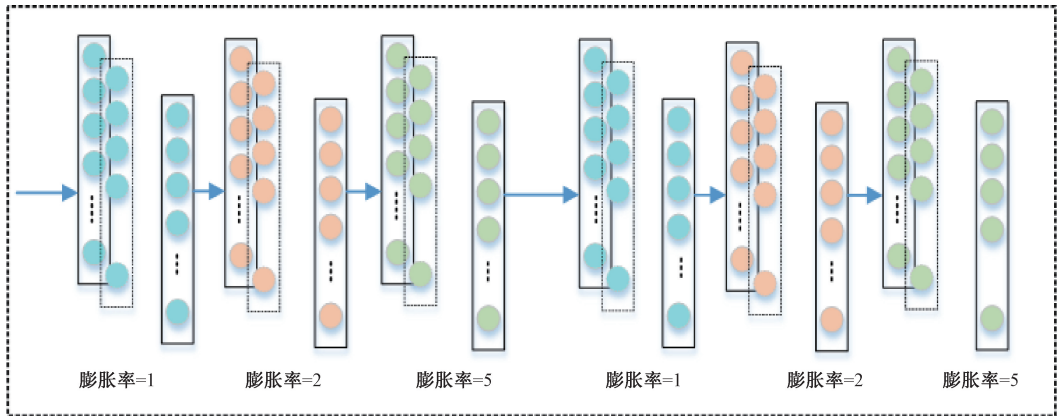


图 2 混合空洞卷积模块
Fig. 2 Mixed hollow convolution module




图 3 空洞卷积块 ($i=1,2,5$)
Fig. 3 Hollow convolutional blocks ($i=1,2,5$)

2.2 改进的黑翅鸢优化算法

BKA 作为一种元启发式算法,其搜索机制存在一定局限性。在迭代进程中,个体的更新和移动方式可能导

致搜索方向逐渐集中于局部较优区域,难以突破该区域去探索更广泛的解空间,且缺乏有效的全局探索引导策略,使得在前期无法全面地遍历整个搜索范围,后期则因

搜索路径相对固定,难以以改变方向去发现其它潜在的更优解区域。针对上述问题本文做了如下改进。

1) 攻击行为部分改进

BKA 算法攻击行为部分存在扰动系数缺乏动态适应性的问题,其扰动系数计算方式简单固定,难以依目标函数特性和迭代阶段灵活调整,导致搜索阶段划分粗糙,易陷局部最优;位置更新模式常规,限制了探索能力与信息利用。因此本文提出了基于 Gompertz 模型扰动系数计算公式^[22],如式(22)所示。

$$n = A \cdot 2^{e^{-(B-Y^t)}} \quad (22)$$

式中: A 、 B 、 Y 为可调节参数。在迭代初期,由于 t 较小, n 相对较小,避免因扰动过大使个体位置更新时远离潜在最优解区域。随着迭代次数增加,通过 A 、 B 、 Y 参数的综合作用,可灵活调整 n 的值,使算法在中期能够根据目标函数情况适当扩大搜索范围或调整搜索精度,在后期逐渐变小,有利于聚焦局部区域进行精细搜索,且不同的参数组合能够适应多种不同特性(如多峰、单峰、高维等)的目标函数。

2) 迁移行为部分改进

BKA 算法的迁移策略较为单一,缺乏有效的机制来突破局部最优解的限制,在搜索过程中个体的移动方式相对固定,难以在不同的搜索区域进行灵活转换,导致对搜索空间的探索不够全面,容易陷入局部最优的困境,且在面对复杂目标函数时,无法根据函数特性动态调整迁移的幅度与方向,适应性较差。针对该问题,在迁移行为部分融合 NGO 算法元素引入随机变量^[23],如式(23)所示。

$$I = \begin{cases} 1, & 1 \leq 1 + R < 1.5 \\ 2, & 1.5 \leq 1 + R < 2 \end{cases} \quad (23)$$

式中: R 是一个服从均匀分布 $U(0,1)$ 的随机变量。

在迁移行为的位置更新公式中, I 的不同取值改变了个体与种群最优位置(XLeader)或者自身位置之间的相对关系。当 $I=2$ 时,相比 $I=1$ 会增加每个个体的位移,使得其进入搜索空间的新区域,这形成了一种随机的、可切换的搜索力度调节机制,能在对当前较优区域深度挖掘($I=1$ 时)与大胆跳出探索更远区域($I=2$ 时)之间灵活切换,打破了固定搜索路径依赖,扩大了整个算法对搜索空间不同区域的探索覆盖范围,使得其能够更加全面的覆盖搜索空间,提升了对复杂搜索空间的探索和利用效率。

为了验证改进 BKA 算法的性能,参考文献[24]的测试函数其进行评估,其中 TF_1 和 TF_4 为单峰测试函数,用于评估优化算法的收敛性能和稳定性; TF_6 和 TF_8 为多峰测试函数,用于评估优化算法的全局搜索能力和避免陷入局部最优解的能力。设定种群数量为 30,最大迭代次数为 500 次。

测试函数收敛曲线对比如图 4 所示,由 TF_1 、 TF_4 函数收敛曲线图可知,相较于基础 BKA 算法,改进后的 BKA 具有更高的收敛精度,寻优能力大幅度增强;由 TF_6 、 TF_8 函数收敛曲线可知,当收敛精度相同时,改进后的 BKA 只需要更少的迭代次数就能够获得最优解。上述测试表明改进的算法具有良好的收敛性能和搜索能力。

2.3 故障诊断模型步骤

基于空洞卷积和优化 LSSVM 的故障诊断模型整体流程如图 5 所示,具体步骤如下。

1) 输入的一维振动信号首先经由小波同步压缩变换(SWT)进行处理,在分解过程中,SWT 自适应地捕捉信号中的不同频率成分和瞬态特征,将一维振动信号分解为多个具有不同时间-频率特性的子信号,再将这些子信号的信息进行整合,构建出呈现不同能量分布的二维时频图像。

2) 将二维时频图像输入到混合空洞卷积模块中,模块中的第一层卷积层开始对图像进行初步特征提取,提取出局部的时间-频率特征;随着图像数据在模块中的流动,不同空洞率的卷积层依次对图像进行处理,空洞率较大的卷积层捕捉长程的时间-频率依赖关系,而空洞率较小的卷积层则对局部细节进行特征提取,并过多层卷积、归一化(BN 层)、以及激活函数层(ReLU),模块逐渐提取出具有高度判别性的故障特征,这些特征不仅包含了不同频率带的能量分布,还包括了频率随时间的变化趋势等信息。

3) 将混合空洞卷积模块输出的全连接层结果作为输入至 BKA-LSSVM 进行模型训练。在训练过程中,训练数据经过 LSSVM 的分类超平面进行类别划分,通过计算损失函数来评估模型的性能。根据改进的 BKA 算法的搜索策略,不断调整 LSSVM 的参数,直到模型收敛,达到最佳的分类效果。

4) 将测试集数据送入训练好的模型进行故障诊断,并输出故障诊断结果。

本文提出的空洞卷积网络结合黑翅鸢优化 LSSVM 方法的结构和初始化参数如表 1 所示,卷积层参数分别为核数量与尺寸,池化层参数分别为池化尺寸与步长。

3 故障诊断实验验证

3.1 实验设置

为全面评估本文所提模型的可行性和有效性,设计了 3 种具有代表性的旋转机械复杂故障任务场景,以确保模型在多种实际应用中的适应性和可靠性,分别是基

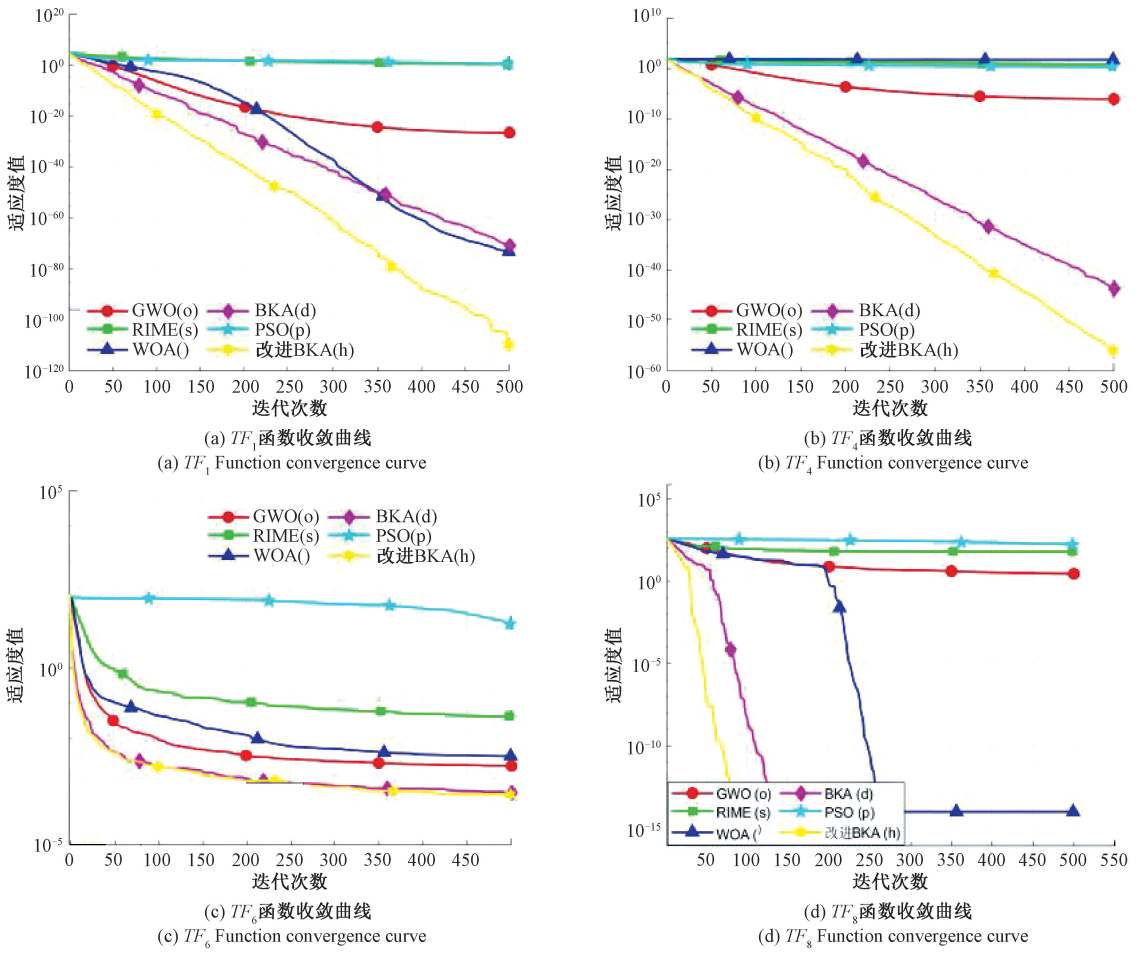


图 4 测试函数收敛曲线对比

Fig. 4 Comparison of convergence curves of test functions

表 2 网络结构参数

Table 2 Network structure parameters

结构名称	卷积核数	卷积核步长	激活函数	膨胀因子	输出形状	参数量
输入层	—	—	—	—	[64,64,3]	—
卷积层 1	16	1	ReLU	1	[64,64,16]	432
池化层 1	—	2	—	—	[32,32,16]	—
卷积层 2	32	1	ReLU	2	[32,32,32]	4 602
卷积层 3	32	1	ReLU	4	[32,32,32]	9 216
池化层 2	—	2	—	—	[16,16,32]	—
卷积层 4	64	1	ReLU	1	[16,16,64]	18 432
卷积层 5	64	1	ReLU	2	[16,16,64]	36 864
卷积层 6	64	1	ReLU	4	[16,16,64]	36 864
全连接层	—	—	—	—	5	160
Softmax 层	—	—	—	—	5	—

于东南大学齿轮箱数据集跨域下的性能验证,基于东南大学齿轮箱数据集小样本情况下的性能验证和基于北京工业大学 WT-行星齿轮箱数据集噪声环境下的性能验证^[25]。

3.2 案例 1: 东南大学齿轮箱数据集

1) 数据描述

实验数据由东南大学动力传动系统动态模拟实验平台提供,图 6 所示为实验平台,该数据集内包含 2 个子数

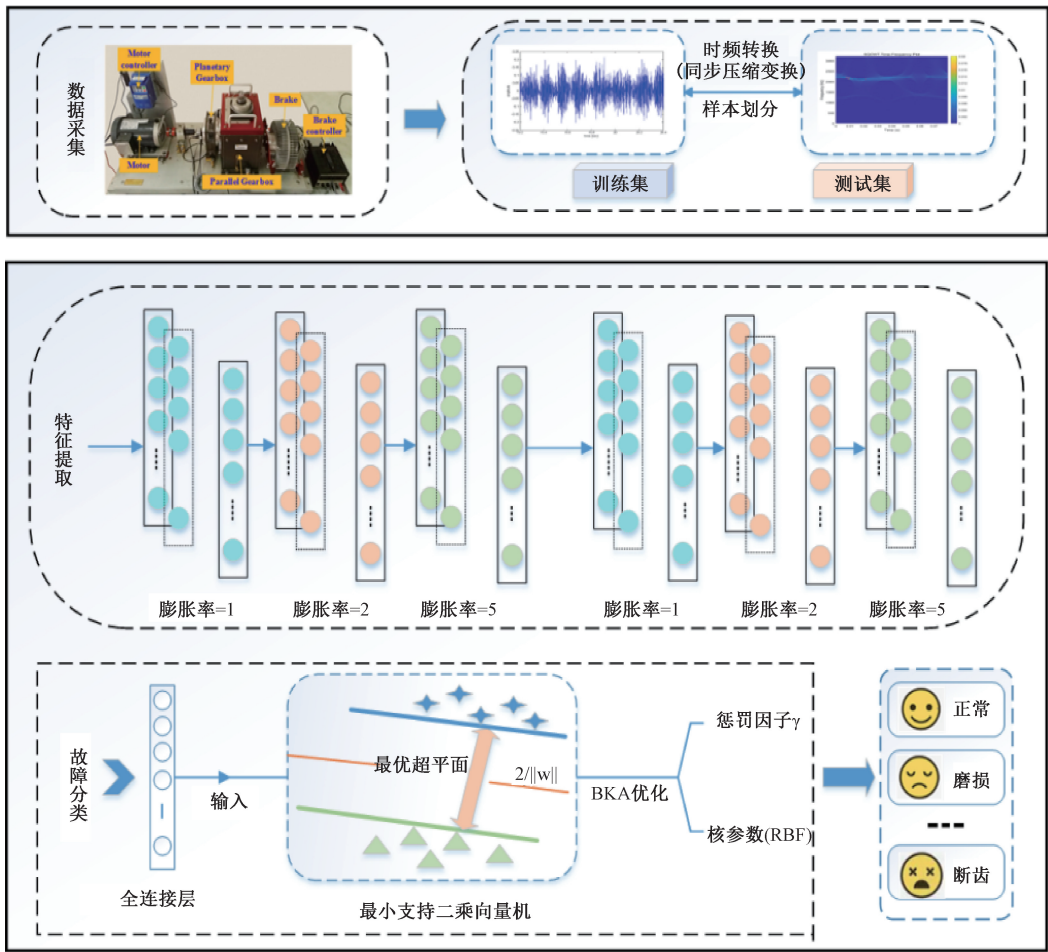


图 5 基于空洞卷积和优化 LSSVM 的故障诊断模型

Fig. 5 Fault diagnosis model based on dilated convolution and optimized LSSVM

数据集,包括轴承数据和齿轮数据^[26]。

样本,总共 1 000 个样本,并按照 7 : 3 比例划分训练集和测试集,具体选取和划分如表 3 所示。




图 6 东南大学模拟实验平台

Fig. 6 Southeast university simulation experiment platform

测试 1 (齿轮数据集), 选取了转速-负载设置在 20 Hz-0 V 工况下, 5 种齿轮类型的实验数据 (状态标记为 1~5), 5 种齿轮类型分别为齿轮断齿、齿轮缺口、齿面磨损、齿根裂纹和正常状态, 每种齿轮故障类型取 200 个

表 3 齿轮故障数据集划分
Table 3 Division of gear fault dataset

类别	训练集	测试集	标签
正常	140	60	1
齿轮断齿	140	60	2
齿轮缺口	140	60	3
齿面磨损	140	60	4
齿根裂纹	140	60	5

测试 2 (轴承数据集), 选取了转速-负载设置在 20 Hz-0 V 工况下, 5 种轴承类型的实验数据 (状态标记为 1~5), 5 种轴承类型分别为滚子故障、内圈故障、外圈故障、复合故障和正常状态, 每种轴承故障类型取 200 个样本, 总共 1 000 个样本, 并按照 7 : 3 比例划分训练集和测试集, 具体选取和划分如表 4 所示。

表 4 轴承故障数据集划分

Table 4 Division of bearing fault dataset

类别	训练集	测试集	标签
正常	140	60	1
滚子故障	140	60	2
内圈故障	140	60	3
外圈故障	140	60	4
复合故障	140	60	5

2) 实验结果及分析

分别使用东南动力传动模拟试验台中采集的轴承数据集和齿轮数据集验证本文所提模型的准确性,并与 MSDCN、MSACNN、WOA-LSSVM、STOA-LSSVM^[27-28] 模型进行对比实验,不同故障诊断模型诊断结果如表 5 所示,本文所提模型故障诊断结果及混淆矩阵分别如图 7 和 8 所示。

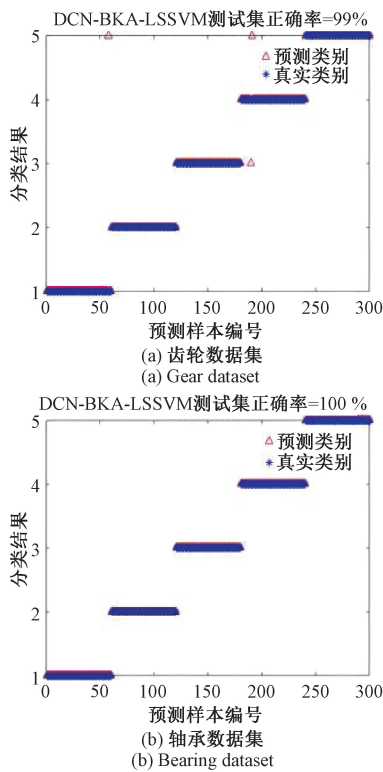


图 7 DCN-BKA-LSSVM 测试分类结果

Fig. 7 DCN-BKA-LSSVM test classification results

表 5 不同故障诊断模型诊断结果

Table 5 Diagnosis results of different fault diagnosis models (%)

模型	齿轮	轴承
MSDCNN	97.6	98.6
MSACNN	98.2	98.5
WOA-LSSVM	96.4	97.2
STOA-LSSVM	96.5	96.8
本文诊断模型	99.0	100.0




图 8 DCN-BKA-LSSVM 测试混淆矩阵

Fig. 8 DCN-BKA-LSSVM test confusion matrix

为了进一步验证本文所提模型的特征提取能力和分类能力,引入了 t-SNE 非线性降维算法将高维复杂的故障数据转换至低维空间之中^[29],t-SNE 可视化如图 9 所示。从图 9 可以清晰地看到,绝大部分的故障数据均成功地实现了聚类,各个聚类簇之间呈现出相对明显的区分度与聚合性。然而,也存在着极少数部分的故障数据出现了错分现象,这可能是由于数据本身存在噪声干扰、特征表达不够充分或者算法在处理某些极端边界情况时存在一定局限性等多种因素所共同导致的。尽管如此,整体的分类结果依然展现出了较高的准确性与可靠性。

3.3 小样本情况下的性能分析

在现代工业生产中,轴承和齿轮作为机械设备的关键部件,其运行状态直接关系到整个系统的稳定性与安全性。然而,实际工况下获取大量标注完整的轴承故障数据存在显著困难。一方面,轴承故障属于低概率事件,难以积累足够数量的故障样本;另一方面,受数据采集成本、设备运行连续性等因素制约,大规模数据采集面临诸多挑战。因此,开展小样本情况下的轴承故障诊断研究具有重要的现实意义。

图 10 所示为不同训练样本量(样本数量分别为 10、20、40)下的诊断结果,清晰地呈现了样本数量对模型性能的影响规律。

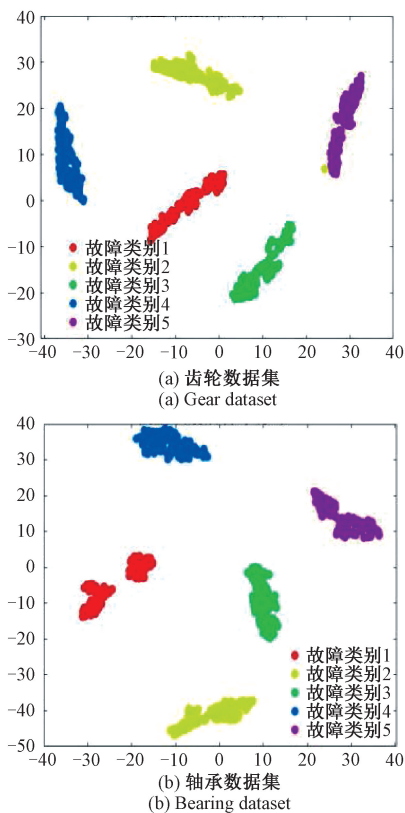


图 9 t-SNE 可视化

Fig. 9 t-SNE visualization

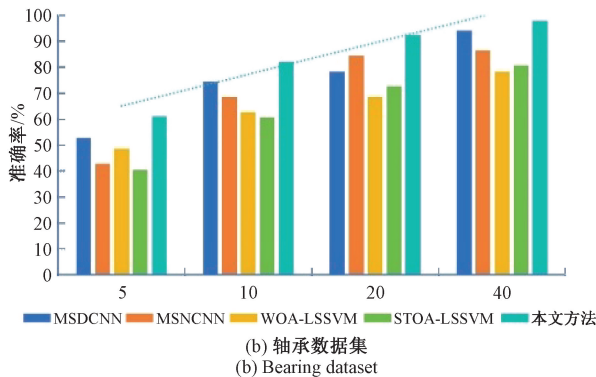
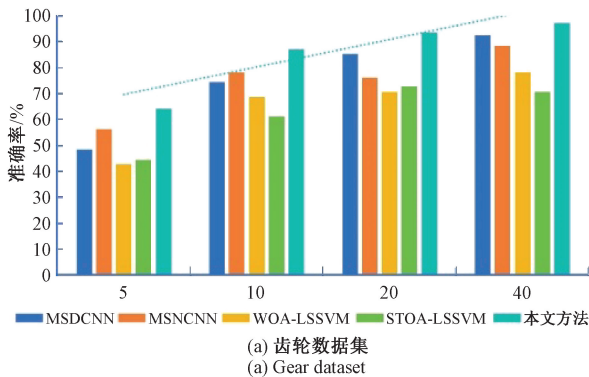


图 10 不同训练样本数量下的诊断结果

Fig. 10 Diagnosis results under different training sample sizes

3.4 WT-行星齿轮箱数据集

1) 数据集描述

WT-行星齿轮箱实验数据由北京工业大学风力发电机传动试验平台提供,如图 13 所示,该试验台由电机、行星齿轮箱、固定轴齿轮箱和加载装置组成,其中行星齿轮箱有 4 个行星齿轮绕一个太阳齿轮旋转^[30]。该试验台模拟了不同转速下太阳齿轮的 5 种工作状态,齿轮健康、齿轮损坏、齿面磨损、齿根断裂和缺齿。实验中选取 20 Hz 转速下的振动数据,每种状态有 200 个样本,共

实验结果表明,随着训练样本数量的减少,分类准确率逐渐下降。当样本不足时,故障信息的缺失使得模型学习到的特征过于简单或无关,从而增加了过拟合的风险,难以获得具有良好泛化能力的诊断模型。与其他四种对比模型相比,本文提出的模型在各种训练样本条件下均表现出了更强的诊断能力。本文所构建的空洞卷积结合优化 LSSVM 模型结合了其高效的特征提取和强大的分类能力,混合空洞卷积模块能够通过逐层自适应地学习原始数据中的时频信息特征,从而提取更加针对性的特征表示,在扩大感受野的同时保持高分辨率,捕捉到更广泛的上下文信息和细节特征;然后采用改进 BKA 对 LSSVM 进行优化,该优化方式显著增强了 LSSVM 的泛化能力,使其能够更好地应对不同分布的数据集,有效减少过拟合,避免了因样本数量少而陷入局部最优解的困境,使得模型降低了对训练样本数量的依赖,提高了模型在样本有限下的故障识别率。为进一步验证本文所提模型在小样本情况下的诊断性能,在不同训练样本下进行混淆矩阵分析,结果如图 11 和 12 所示,可以看到,当每类训练样本数为 10 时,准确率分别为 87.15% 和 82.21%;而当每类训练样本数增加到 40 时,模型能够有效区分各类健康状态数据,在齿轮和轴承数据集上的准确率分别达到了 97.8% 和 98%。充分表明了本文所提模型在小样本故障诊断中具有良好的适用性。

1 000 个样本,并按照 7 : 3 比例划分训练集和测试集,具体选取和划分如表 6 所示。

表 6 齿轮箱故障数据集划分

Table 6 Division of gearbox fault dataset

类别	训练集	测试集	标签
正常	140	60	1
齿轮损坏	140	60	2
齿面磨损	140	60	3
齿根断裂	140	60	4
缺齿	140	60	5

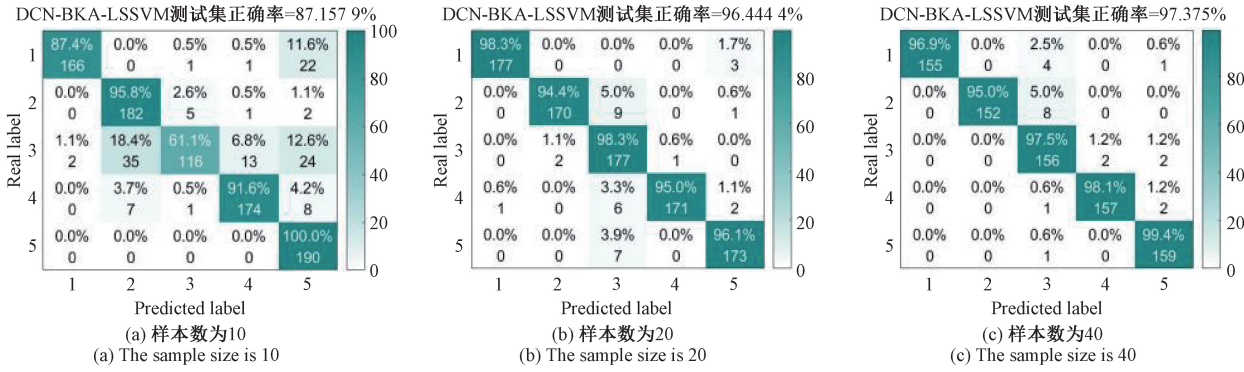


图 11 齿轮数据集上不同训练样本下的混淆矩阵结果

Fig. 11 Confusion matrix results under different training samples on the gear dataset

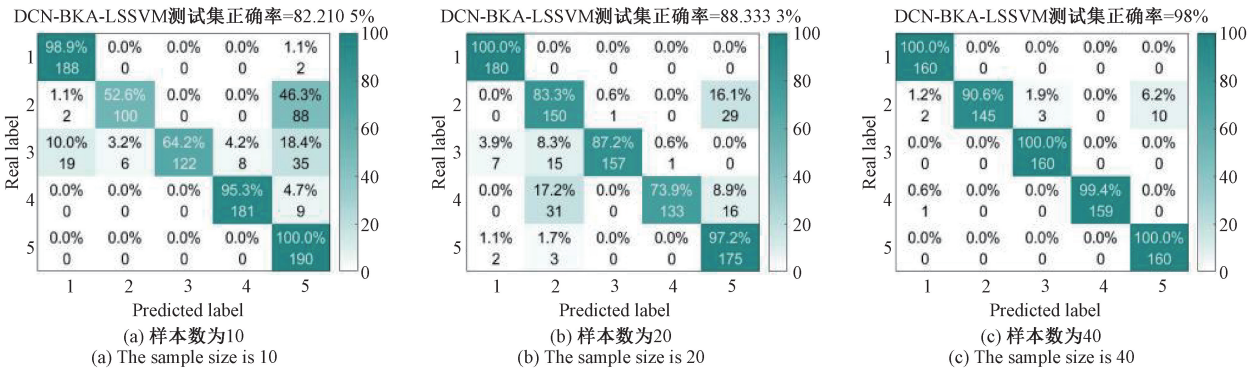


图 12 轴承数据集上不同训练样本下的混淆矩阵结果

Fig. 12 Confusion matrix results under different training samples on the bearing dataset




图 13 电机传动系统试验台

Fig. 13 Motor transmission system test bench

2) 噪声环境下的性能分析

为评估本文所提模型在噪声环境中的诊断能力,本实验采用了 WT-行星齿轮箱数据集,并在其中分别添加了-6、-4、-2、2、4 和 6 dB 的白噪声,以测试模型在不同噪声水平下的抗干扰性能。并将本文所提模型与 MSDCNN、MSACNN、WOA-LSSVM 及 STOA-LSSVM 4 种模型进对比,评估各模型在噪声环境中的稳定性、准确性和故障诊断能力,最终验证本文所提模型在复杂噪声条件下的优越性。

图 14 所示为本文所提模型在未添加噪声的原始数据的测试分类结果,图 15 所示为 6 种不同噪声强度下 (-6~6 dB) 不同模型的分类准确率,可以看出,在相同噪声强度下,本文提出的模型展现出更强的诊断能力,并且随着噪声强度的增加,所有模型的性能都有所下降,但本文模型的准确率波动较小,说明其对噪声的鲁棒性更强,受噪声干扰的程度较低。综合来看,本文所提模型始终保持了最高的测试准确率,突显了其在面对不同噪声干扰时的稳定性和可靠性,能够确保故障状态的准确识别。

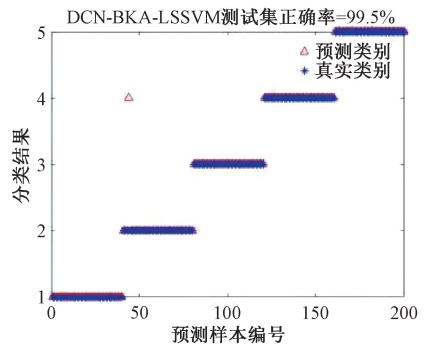


图 14 无噪声下的测试分类结果

Fig. 14 Test classification results without noise




图 15 不同噪声强度下的诊断结果

Fig. 15 Diagnosis results under different noise intensities

3.5 消融实验

为验证模型各组件的有效性及其不同分类器的性能差异,本文设计消融实验并对比多种模型配置,其中小样本测试以训练样本数为 10 进行测试,含噪测试以 -4 dB 的噪声干扰下进行测试,实验结果如表 7 所示。

表 7 不同方法的准确率

Table 7 Accuracy of different methods (%)

特征提取	优化算法	分类器	正常数据准确率	小样本准确率	含噪数据准确率
CNN	—	Softmax	87.6	68.3	78.4
DCN	—	Softmax	96.2	74.4	82.5
DCN	BKA	LSSVM	98.3	80.7	93.6
DCN	改进 BKA	LSSVM	99.5	84.6	95.5

从表 7 可以看出,在正常数据、小样本及含噪数据场景下,DCN 诊断准确率均显著优于 CNN,验证了其多尺度特征提取的优越性,其针对振动信号长程相关性强、多尺度特征交织的特性进行构建,通过首层标准卷积保留底层关键细节,锯齿形膨胀率序列交替捕捉高频冲击与低频趋势,并以最大公约数约束优化采样分布,有效平衡了全局特征捕捉与局部细节提取,克服了 CNN 感受野受限及简单空洞卷积存在的网格效应问题。在分类器选择与优化方面,将 Softmax 替换为 LSSVM 并结合 BKA 后,模型性能得到显著提升。LSSVM 基于结构风险最小化原理,通过将二次规划问题转化为线性方程组求解,并利用核函数实现高维空间映射,相比基于交叉熵损失的 Softmax 分类器,在小样本条件下能有效抑制过拟合现象,在含噪环境中展现出更强的鲁棒性,在小样本场景下诊断准确率从 74.4% 提升至 80.7%,含噪数据环境下从

82.5% 提升至 93.6%。进一步采用改进 BKA 对 LSSVM 参数进行优化后,“DCN+改进 BKA+LSSVM”组合实现了最佳诊断性能,正常数据准确率高达 99.5%,小样本及含噪数据环境下准确率分别达到 84.6% 和 95.5%。这一结果充分验证了特征提取模块(DCN)、优化算法(改进 BKA)与分类器(LSSVM)三者协同优化,能够显著提升旋转机械故障诊断模型在复杂工况下的准确性与鲁棒性。

5 结论

本文提出了一种基于空洞卷积结合优化 LSSVM 的故障诊断模型,该模型的准确性和优越性在 2 个数据集上进行了验证,与其他诊断算法相比,本文所提模型在故障诊断准确性方面具有显著优势,其诊断准确率均高于相比较方法。空洞卷积能够灵活地提取不同尺度的故障特征,结合同步压缩小波变换可提取更具针对性的时频信息特征,提高故障敏感性和判别性,更能全面捕捉故障信息。针对 BKA 算法在搜索阶段划分粗糙,易陷局部最优,且探索能力与信息利用受限的问题,在攻击行为部分提出新的扰动系数计算公式,在迁移行为部分融合 NGO 算法元素引入随机变量的方式对其进行改进,使得 LSSVM 能快速收敛到更优解,增强其对复杂数据的分类处理效率。

参考文献

[1] WANG Q, HUANG R, XIONG J, et al. A survey on fault diagnosis of rotating machinery based on machine learning [J]. Measurement Science and Technology, 2024, 35(10): 102001.

- [2] XUE Y, DOU D, YANG J, et al. Multi-fault diagnosis of rotating machinery based on deep convolution neural network and support vector machine[J]. Measurement, 2020, 156: 107571.
- [3] GUNERKAR R S, JALAN A K, BELGAMWAR S U. et al. Fault diagnosis of rolling element bearing based on artificial neural network [J]. Journal of Mechanical Science and Technology, 2019, 33: 505-511.
- [4] ZHANG H, CHE W, CAO Y, et al. Condition monitoring and fault diagnosis of rotating machinery towards intelligent manufacturing: Review and prospect[J]. Iranian Journal of Science and Technology, Transactions of Mechanical Engineering, 2024,49: 1-34.
- [5] CHEN D D, TIAN Y J, LIU X H, et al. Structural nonparallel support vector machine for pattern recognition[J]. Pattern Recognition, 2016, 60: 296-305.
- [6] JOACHIMS T. Making large-scale SVM learning practical[J]. Technical Reports, 1998, 8(3): 499-526.
- [7] LI Y J, ZHANG W H, XIONG Q, et al. A rolling bearing fault diagnosis strategy based on improved multiscale permutation entropy and least squares SVM[J]. Journal of Mechanical Science and Technology, 2017, 31 (6): 2711-2722.
- [8] 任志玲, 张景智. 多策略融合 LSSVM-NGO 的滑动电接触失效诊断 [J]. 电子测量与仪器学报, 2023, 37(12): 37-47.
- REN ZH L, ZHANG J ZH, et al. Multi-strategy fusion of LSSVM-NGO for sliding electrical contact failure diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2023,37(12): 37-47.
- [9] 陈尧, 周连杰. 基于 KPCA-IPOA-LSSVM 的变压器电热故障诊断 [J/OL]. 南方电网技术, 1-11 [2024-12-26].
- CHEN Y, ZHOU L J, et al. Transformer thermal fault diagnosis based on KPCA-IPOA-LSSVM [J/OL]. Southern Power Grid Technology, 1-11 [2024-12-26].
- [10] TUERXUN W, CHANG X, GUO H Y, et al. Fault diagnosis of wind turbines based on a support vector machine optimized by the sparrow search algorithm[J]. IEEE Access, 2021, 9: 69307-69315.
- [11] LI Z, LUO X, LIU M, et al. Wind power prediction based on EEMD-Tent-SSA-LS-SVM [J]. Energy Reports, 2022, 8: 3234-3243.
- [12] YAN X, HUA X, JIANG D, et al. A novel robust intelligent fault diagnosis method for rolling bearings based on SPAVMD and WOA-LSSVM under noisy conditions[J]. Measurement Science and Technology, 2024, 35(5): 056121.
- [13] 宫文峰, 陈辉, WANG D W, 等. 基于改进 CNN-GAP-SVM 的船舶电力变换器快速故障诊断方法 [J]. 计算机集成制造系统, 2022,28(5): 1370-1384.
- GONG W F, CHEN H, WANG D W, et al. A fast fault diagnosis method for ship power converters based on improved CNN-GAP-SVM [J]. Computer Integrated Manufacturing Systems, 2022, 28 (5): 1370-1384.
- [14] 卢占标, 黄细霞, 姬克, 等. 基于多通道输入 CNN-SVM 的齿轮箱故障诊断 [J]. 传感器与微系统, 2021, 40(6): 138-141.
- LU ZH B, HUANG X X, JI K, et al. Gearbox fault diagnosis based on multi-channel input CNN-SVM [J]. Sensors and Microsystems, 2021, 40 (6): 138-141.
- [15] 唐伯宇, 邵星, 王翠香, 等. 基于双通道 CNN 与 SSA-SVM 的滚动轴承故障诊断 [J]. 控制理论与应用, 2024, 41(9): 1626-1635.
- TANG B Y, SHAO X, WANG C X, et al. Fault diagnosis of rolling bearings based on dual channel CNN and SSA-SVM [J]. Control Theory and Application, 2024, 41 (9): 1626-1635.
- [16] 刘奇, 田辈辈, 冷军发, 等. 基于 SWT 与 IEWT 的齿轮无转速计阶次跟踪 [J]. 机械设计与研究, 2024, 40(2): 151-157.
- LIU Q, TIAN B B, LENG J F, et al. Gear tachometer order tracking based on SWT and IEWT [J]. Mechanical Design and Research, 2024, 40 (2): 151-157.
- [17] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs [J]. ArXiv preprint arXiv: 1412.7062, 2014.
- [18] 李斌, 舒嘉辉, 严灵潇, 等. 改进黑翅鸢算法的 1D-2D-GAF-PCNN-GRU-MSA 弓网电弧检测应用 [J]. 电子测量与仪器学报, 2024, 38(10): 201-211.
- LI B, SHU J H, YAN L X, et al. Application of 1D-2D-GAF-PCNN-GRU-MSA bow wire arc detection with improved black winged kite algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (10): 201-211.
- [19] KUMAR L, SRIPADA S K, SUREKA A, et al. Effective fault prediction model developed using least square support vector machine (LSSVM) [J]. Journal of Systems and Software, 2018, 137: 686-712.
- [20] YAN X, HUA X, JIANG D, et al. A novel robust intelligent fault diagnosis method for rolling bearings based on SPAVMD and WOA-LSSVM under noisy conditions [J]. Measurement Science and Technology, 2024, 35(5): 056121.
- [21] 赵小强, 柴靖轩. 改进卷积胶囊网络的滚动轴承故障

- 诊断方法 [J]. 振动工程学报, 2024, 37 (5): 885-895.
- ZHAO X Q, CHAI J X. Improved convolutional capsule network for fault diagnosis of rolling bearings [J]. Journal of Vibration Engineering, 2024, 37 (5): 885-895.
- [22] 路冰洁, 杜晨秋, 郭芯竹, 等. 温湿度对建筑室内典型霉菌生长影响及其动力学模型 [J]. 中国环境科学, 2023, 43(3): 1368-1377.
- LU B J, DU CH Q, GUO X ZH, et al. The influence of temperature and humidity on the growth of typical indoor mold in buildings and its dynamic model [J]. Chinese Journal of Environmental Science, 2023, 43 (3): 1368-1377.
- [23] 包金山, 杨定坤, 张靖, 等. 基于特征提取与 INGO-SVM 的变压器故障诊断方法 [J]. 电力系统保护与控制, 2024, 52(7): 24-32.
- BAO J SH, YANG D K, ZHANG J, et al. Transformer fault diagnosis method based on feature extraction and INGO-SVM [J]. Power System Protection and Control, 2024, 52(7): 24-32.
- [24] 周建新, 侯自川, 李忠泽. 融合多策略改进的黑翅鸢优化算法 [J]. 电子测量技术, 2024, 47 (22): 104-110.
- ZHOU J X, HOU Z CH, LI ZH Z, et al. Optimization algorithm for black winged kite integrating multiple strategy improvements [J]. Electronic Measurement Technology, 2024, 47(22): 104-110.
- [25] 卢一相, 钱冬生, 竺德, 等. 基于多尺度小波包启发卷积网络的旋转机械故障诊断 [J]. 振动与冲击, 2024, 43(17): 203-213.
- LU Y X, QIAN D SH, ZHU D, et al. Fault diagnosis of rotating machinery based on multi-scale wavelet packet inspired convolutional network [J]. Vibration and Shock, 2024, 43 (17): 203-213.
- [26] 张亚洲, 赵小强, 惠永永, 等. 基于多传感器数据融合的 SA-DACNN 齿轮箱故障诊断方法 [J]. 控制与决策, 2024, 39(11): 3699-3708.
- ZHANG Y ZH, ZHAO X Q, HUI Y Y, et al. SA-DACNN gearbox fault diagnosis method based on multi-sensor data fusion [J]. Control and Decision, 2024, 39(11): 3699-3708.
- [27] 雷春丽, 史佳硕, 马淑珍, 等. 强噪声环境下基于 MSDCNN 的滚动轴承故障诊断方法 [J]. 北京航空航
- 天大学学报, 2025, 51(9): 2906-2915.
- LEI CH L, SHI J SH, MA SH ZH, et al. Fault diagnosis method for rolling bearings based on MSDCNN in strong noise environment [J]. Journal of Beihang University, 2025, 51(9): 2906-2915.
- [28] 蔡赛男, 宋卫星, 班利明, 等. 基于鲸鱼算法优化 LSSVM 的滚动轴承故障诊断 [J]. 控制与决策, 2022, 37(1): 230-236.
- CAI S N, SONG W X, BAN L M, et al. Optimization of LSSVM for rolling bearing fault diagnosis based on whale algorithm [J]. Control and Decision, 2022, 37 (1): 230-236.
- [29] 钟建华, 黄聪, 钟舜聪, 等. 基于 t-SNE 降维方法的滚动轴承剩余寿命预测 [J]. 机械强度, 2024, 46(4): 969-976.
- ZHONG J H, HUANG C, ZHONG SH C, et al. Remaining life prediction of rolling bearings based on t-SNE dimensionality reduction method [J]. Mechanical Strength, 2024, 46 (4): 969-976.
- [30] LIU D, CUI L, CHENG W, et al. A review on deep learning in planetary gearbox health state recognition: Methods, applications, and dataset publication [J]. Measurement Science and Technology, 2023, 35(1): 012002.

作者简介



赵小强 (通信作者), 2006 年于浙江大学获得博士学位, 现为兰州理工大学教授, 主要研究方向为故障诊断、图像处理、数据挖掘等。

E-mail: xqzhao@lut.edu.cn

Zhao Xiaoqiang (Corresponding author) received his Ph. D. degree from Zhejiang University in 2006. He is now a professor at Lanzhou University of Technology. His main research interests include fault diagnosis, image processing, and data mining etc.



齐祥德, 2021 年于兰州理工大学获得学士学位, 现为兰州理工大学硕士研究生, 主要研究方向为故障诊断。

E-mail: 270661737@qq.com

Qi Xiangde received his B. Sc. degree from Lanzhou University of Technology in 2021. Now he is a M. Sc. candidate in Lanzhou University of Technology. His main research interest includes fault diagnosis.