

基于声信号的离心泵故障诊断研究*

陈 剑^{1,2} 姜 涛¹ 陈 品^{1,2}

(1. 合肥工业大学噪声振动工程研究所 合肥 230009; 2. 安徽省汽车 NVH 技术研究中心 合肥 230009)

摘要:各种原因使得工业现场设备状态监测的首选测量信号是声信号时,提出一种基于声信号的设备状态监测方法显得尤为必要。以某型离心泵为依据对象,对现场采集的声信号提取梅尔倒谱系数(MFCC)作为信号的初始特征,然后计算这些MFCC初始特征的散布熵(DE)值,并通过主成分分析法(PCA)对矩阵进行降维,从而构造特征矩阵。利用蝙蝠优化算法(BA)对支持向量机(SVM)的惩罚系数与核函数参数进行优化,对离心泵的多种故障工况开展诊断,并与多种诊断方法进行比较。实验结果表明,经过BA优化后的模型在诊断准确率上提高了21.7%;在该模型的基础上利用DE对MFCC提取的信号进行深度挖掘,使模型诊断的准确率提高2.05%。

关键词: 离心泵故障诊断; 声信号; 梅尔倒谱散布熵; 蝙蝠优化算法; 支持向量机

中图分类号: TP206; TN912

文献标识码: A

国家标准学科分类代码: 510.4040

Research on fault diagnosis of centrifugal pump based on acoustic signal

Chen Jian^{1,2} Jiang Tao¹ Chen Pin^{1,2}

(1. Institute of Sound and Vibration Research, Hefei University of Technology, Hefei 230009, China;

2. Automotive NVH Engineering & Technology Research Center Anhui Province, Hefei 230009, China)

Abstract: When the preferred measurement signal for equipment condition monitoring in industrial field is acoustic signal for various reasons, it is especially necessary to propose an equipment condition monitoring method based on acoustic signal. In this paper, a certain type of centrifugal pump is taken as the basis object, and the Mel-scale frequency cepstral coefficients(MFCC)are extracted from the acoustic signals collected in the field as the initial features of the signals, then the dispersion entropy(DE)values of these MFCC initial features are calculated, and the matrix is downscaled by principal component analysis(PCA), so as to construct the feature matrix. The penalty coefficients and kernel function parameters of the support vector machine(SVM)are optimized by using the bat algorithm(BA)to carry out diagnosis of various fault conditions of centrifugal pumps and compared with various diagnostic methods. The experimental results show that the model optimized by BA improves the diagnostic accuracy by 21.7%; on the basis of this model, the deep mining of the signals extracted by MFCC using DE improves the diagnostic accuracy of the model by 2.05%.

Keywords: centrifugal pump fault diagnosis; acoustic signal; mel-scale frequency cepstral coefficients dispersion entropy(MFCCDE); bat optimization algorithm; support vector machine

0 引言

离心泵由于其拥有适用范围广、结构简单等特点,在化工行业中得到了广泛的应用。离心泵的异常,小则影

响实际生产效率,大则可能会导致严重事故的发生,危害人们的生命与财产安全^[1-2]。离心泵的故障诊断技术能够提前对故障设备进行识别预警,在故障发生前对故障部件进行维修或替换^[3]。相对于传统故障诊断技术对诊断对象的振动信号进行采集,采用对噪声信号进行采集

分析能够很好地避免实际作业中加速度传感器由于高温、易腐蚀等异常环境而无法安装的问题。声信号的故障诊断方法在化工行业的实际生产中具有重要的研究价值。

在离心泵故障诊断方面,国内外学者做了诸多研究。周云龙等^[4]基于多点噪声分析方法对离心泵的早期故障进行识别,该方法快速、稳定,适用于工业离心泵故障诊断。Araste 等^[5]将离心泵的电气特征作为电机驱动离心泵故障诊断的依据,仅利用电机的电压和电流信号推断离心泵的健康状况,减少了加速度传感器的安装。Chen 等^[6]将机器学习 K 近邻算法(K-nearest neighbor, KNN)的思想引入到传统的马氏距离故障判别中,提出了一种改进的基于马氏距离的 KNN 离心泵故障预测模型,该方法能有效地根据振动信号区分离心泵的具体故障类型。

基于声信号,梅尔倒谱系数已逐渐应用于各类设备的故障诊断。王前等^[7]针对滚动轴承的噪声信号,采用梅尔倒谱对噪声信号的特征进行提取,补偿距离评估(CDET)对所提取特征进行降维,降维后的特征能够准确地识别轴承故障类型。Yan 等^[8]提出一种基于变分模态分解映射梅尔频率倒谱系数和长短期记忆网络的柴油机声学故障诊断方法。狄晓栋等^[9]对 MFCC 进行改进,将传统 MFCC 的特征参数与 GFCC 特征参数进行线性叠加,得到混合参数 MGCC,以此特征进行变压器的故障诊断。

样本熵(sample entropy, SE)、排列熵(permutation entropy, PE)和模糊熵(fuzzy entropy, FE)是常用分析方法,但是它们都是基于时间序列的单一尺度分析方法。文献[10]利用了一种衡量时间序列复杂性和不规则程度的指标——散布熵,对滚动轴承的性能退化进行评估。散布熵克服了排列熵对大规模数据计算缓慢等缺点,并且突变信号对它的影响较小。钱恩丽等^[11]在散布熵的基础上,提出了基于复合多尺度波动散布熵(CMFDE),并用于了单阀早期微弱故障信号的诊断。

前人所做研究在各自领域内取得了一定的建树,但目前在离心泵故障诊断领域中仍存在问题:大多数研究均采用振动信号进行分析诊断,无法满足特定场景的作业;传统 MFCC 和单一的熵值算法对故障信号特征提取不充分;故障诊断模型需要人为进行参数选取等等。

故本文采用 MFCCDE 特征提取方法与自适应参数支持向量机分类器相结合,建立离心泵声信号故障诊断模型。利用声传感器采集不同工况下离心泵泵体处的噪声信号,通过 MFCC 中的预处理、DFT、梅尔滤波、离散余弦变换等一系列操作对原始噪声信号进行特征提取,用 MFCC 参数与其一、二阶差分参数代表原始信号。计算

DE 对 MFCC 提取后的每帧信号的散布熵值,形成 MFCCDE 特征矩阵。由于特征提取后的特征矩阵仍为高维矩阵,为进一步加快后续 SVM 分类速度,决定用主成分分析(principal component analysis, PCA)方法对高维矩阵进行降维,以得到更具有代表性的支持向量机输入矩阵。故障诊断分类器选择基于蝙蝠算法参数优化的支持向量机,BA 对 SVM 中的惩罚系数 c 与核函数 g 进行自适应选取,在全局范围内对超参数进行寻优,以达到更好的分类效果,最终实现声信号的故障诊断。

1 基本原理

1.1 梅尔倒谱系数

MFCC 过程具体可以分为如下 4 个部分^[12]:

1) 音频文件预处理

导入音频文件的预处理一般有预加重、分帧、加窗。高频信号的能量小于低频信号,为避免后续快速傅里叶变换(fast Fourier transform, FFT)中出现数值问题,通常需要先经过预加重对声信号进行处理。预加重函数如下:

$$y(n) = x(n) - \alpha \cdot x(n-1) \quad (1)$$

其中, α 为预加重系数,取值范围一般为 0.95~0.97。

为保证时域信号转化为频域信号的同时保留其时序信息,需要对时域信号进行分帧处理,即将语音信号均分为相同长度,所得语音信号段数为帧数。均分后的一帧语音信号与前后帧交叉的采样点数为帧移。一般帧长设置为 25 ms,帧移设置为 10 ms。

分帧后的信号需要使用窗函数来消除谱泄露的影响,窗函数一般设为 hamming 窗,hamming 窗表达式如下:

$$W(n) = (1 - a) - a \cdot \cos(2 \cdot \pi \cdot \frac{n}{N}) \quad (2)$$

一般情况下 $a = 0.46$, n 的取值范围为 $1 \leq n \leq N$ 。

2) 离散傅里叶变换

将预处理后的每一帧进行离散傅里叶变换。设预处理后的时域信号为 $x(n)$, DFT 变换后的频域信号 $X(k)$ 可表达为:

$$X(k) = \sum_{n=0}^{N-1} s(n) e^{-j2\pi nk/N} \quad (3)$$

其中, k 的取值范围为 $0 \leq k \leq N$ 。

3) 梅尔滤波

计算 $|X(k)|^2$ 得能量谱,再通过 M 个 Mel 滤波器进行滤波,即:

$$Mel(m) = \sum_{k=f(m-1)}^{f(m+1)} H_m(k) \cdot |X(k)|^2 \quad (4)$$

$H_m(k)$ 为第 m 个滤波器的传递函数,表达式为:

$$H_m(k) = \begin{cases} 0 & k < f(m-1) \\ \frac{2(k-f(m-1))}{(f(m+1)-f(m-1))(f(m)-f(m-1))} & f(m-1) \leq k \leq f(m) \\ \frac{2(f(m+1)-k)}{(f(m+1)-f(m-1))(f(m)-f(m-1))} & f(m) \leq k \leq f(m+1) \\ 0 & k > f(m+1) \end{cases} \quad (5)$$

$H_m(k)$ 传递函数的取值范围分别是: $k < f(m-1)$; $f(m-1) \leq k \leq f(m)$; $f(m) \leq k \leq f(m+1)$; $k > f(m+1)$ 。

其中, $f(m)$ 为三角滤波器中心频率, $\sum_{m=0}^{M-1} H_m(k) = 1$ 。

计算各个滤波器输出的对数能量, 即 $E(m) = \lg[\text{Mel}(m)]$, m 的取值范围为 $0 < m < M$ 。

4) 离散余弦变换

离散余弦变换后可得到 MFCC 系数:

$$C(n) = \sum_{m=0}^{M-1} E(m) \cdot \cos\left[\frac{\pi n(m-0.5)}{M}\right] \quad (6)$$

式中: n 的取值范围为 $0 \leq n < M$ 。

经由上述操作后, 所采集声信号可变为 MFCC 特征矩阵, MFCC 特征提取流程如图 1 所示。




图 1 MFCC 特征提取流程

Fig. 1 MFCC feature extraction flow chart

1.2 散布熵理论

散布熵是一种用于衡量非线性时间序列不规则与不确定程度的算法^[13]。对某一长度为 N 的一维时间序列 $x = \{x_1, x_2, \dots, x_N\}$, 散布熵的计算步骤如下:

1) 正态累计分部积分

$$y_n = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^{x_n} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \quad (7)$$

利用式(7)将一维时间序列 x 映射到 $y = \{y_1, y_2, \dots, y_N\}$, $y_i \in (0, 1)$, μ 和 σ^2 分别为时间序列 x 的期望和方差。

2) 线性变换

$$z_n^c = R(c \cdot y_n + 0.5) \quad (8)$$

利用式(8)将 y 进一步映射到 $z = \{z_1, z_2, \dots, z_N\}$, $z_n \in [1, c]$, 其中 R 为取整函数, c 为类别个数, z_n^c 表示第 c 个类别的第 n 个元素。

3) 计算嵌入子序列

$$Z_j^{m,c,d} = \{z_j, z_{j+d}, L, z_{j+(m-1)d}\} \quad (9)$$

其中, $j = 1, 2, \dots, N - (m-1)d$, m 为嵌入维数, d 为时延。

4) 计算散布模式

$$z_i^c = v_0, z_{i+d}^c = v_1, L, z_{i+(m-1)d}^c = v_{m-1} \quad (10)$$

利用式(10)得到 $Z_j^{m,c,d}$ 对应的散布模式为 $\pi_{v_0, v_1, \dots, v_{m-1}}$, 每个 $Z_j^{m,c,d}$ 的散布模式数量为 c^m 。

5) 计算散布模式概率

$$P(\pi_{v_0, v_1, \dots, v_{m-1}}) = \frac{\text{Num}\{\pi_{v_0, v_1, \dots, v_{m-1}}\}}{N - (m-1)d} \quad (11)$$

由式(11)可得每种散布模式 $\pi_{v_0, v_1, \dots, v_{m-1}}$ 的概率, 其中 $\text{Num}\{\pi_{v_0, v_1, \dots, v_{m-1}}\}$ 代表 $Z_j^{m,c,d}$ 映射到每种散布模式 $\pi_{v_0, v_1, \dots, v_{m-1}}$ 的个数, $P(\pi_{v_0, v_1, \dots, v_{m-1}})$ 代表 $Z_j^{m,c,d}$ 映射到每种散布模式 $\pi_{v_0, v_1, \dots, v_{m-1}}$ 的个数除以 $Z_j^{m,c,d}$ 的元素个数。

6) 计算散布熵

根据香农熵定义, 一维时间序列 $x = \{x_1, x_2, \dots, x_N\}$ 的散布熵为:

$$DE(x, m, c, d) = - \sum_{\pi=1}^{c^m} P(\pi_{v_0, v_1, \dots, v_{m-1}}) \cdot \ln(P(\pi_{v_0, v_1, \dots, v_{m-1}})) \quad (12)$$

由于散布熵 $DE(x, m, c, d)$ 的范围在 $[0, \ln(c^m)]$, 需对其进行归一化处理, 即:

$$NDE(x, m, c, d) = \frac{DE(x, m, c, d)}{\ln(c^m)} \quad (13)$$

散布熵 DE 的值越大, 表示时间序列的不规则程度越深, 同理, DE 值越小, 表示时间序列的不规则程度越浅。由式(12)和(13)可知, 散布熵 DE 的值主要受参数嵌入维数 m 、时延 d 、类别个数 c 的影响, 根据对本文所采集的离心泵声信号数据进行分析以及参考文献[14]中散布熵参数的选取, 最终取 $m = 3, d = 1, c = 6$ 。

1.3 主成分分析(PCA)

在实际故障诊断工程中, 经过特征提取后的原始信号仍是高维的, 如果直接将特征向量送入分类器, 则特征向量中大量的冗余与噪声数据会占据大量计算机的存储空间, 进而增加故障诊断所耗费的时间^[15]。PCA 可以减少计算的复杂性, 但又尽量保留特征的分类有效性, 可以对特征进行一定的压缩^[16]。离心泵在信号采集时, 相同工况的短时间周期内可能包含了相同的故障信息, 这将导致大量信息重叠。为避免信息重叠造成的数据冗余, PCA 通过构造原始变量的线性组合来提取主成分, 并且主成分的数量小于原始变量的数量。

1.4 BA 优化 SVM 参数

BA 是通过观察蝙蝠在搜寻猎物及躲避障碍物时的生物特性所开发出的高效生物启发式算法^[17]。算法通过初始化产生随机蝙蝠粒子, 每个粒子赋予一定的速度

与位置。每个粒子都会因为搜索空间的环境变化而对自身的脉冲频率、速度、位置、响度、脉冲发射率等参数不断进行更改迭代。蝙蝠粒子在搜索时的脉冲频率、速度、位置更新公式为:

$$\begin{cases} f_i = f_{\min} + (f_{\max} - f_{\min}) \cdot \beta \\ v_i^{t+1} = v_i^t + (x_i^t - x^*) \cdot f_i \\ x_i^t = x_i^{t-1} + v_i^t \end{cases} \quad (14)$$

其中, f_i 为粒子 i 的脉冲频率; β 为服从均匀分布随机因子, 范围为 $[0, 1]$; v_i^t 为粒子 i 在 t 时刻的速度; 同理 x_i^t 为粒子 i 在 t 时刻的位置; x^* 为全局最优解。

蝙蝠粒子在获得局部最优解后搜索新解的更新公式为:

$$x_{\text{new}} = x_{\text{old}} + \varepsilon \cdot A^t \quad (15)$$

其中, x_{new} 为局部搜索新解; x_{old} 为局部搜索旧解; ε 为范围在 $[-1, 1]$ 的随机数; A^t 为 t 时刻所有蝙蝠粒子的平均响度。

蝙蝠粒子的响度与脉冲发射率的更新公式为:

$$\begin{cases} A_i^{t+1} = \alpha \cdot A_i^t \\ r_i^{t+1} = r_i^0 [1 - \exp(-\gamma \cdot t)] \end{cases} \quad (16)$$

其中, A_i^{t+1} 为粒子 i 在 $t+1$ 时刻的响度; r_i^{t+1} 为粒子 i 在 $t+1$ 时刻的脉冲发射率; r_i^0 为粒子群体中最大的脉冲发射率; α 与 γ 均为变化系数, $\alpha \in (0, 1)$, $\gamma > 0$ 。粒子迭代过程中, $A^t \rightarrow 0$, $r_i^t \rightarrow r_i^0$ 。

SVM 是一种基于统计学理论的机器学习方法, 已广泛应用于故障诊断领域。其基本原理是寻找最优分割超平面以使问题变得线性可分^[18]。若样本线性可分, SVM 通过线性超平面即可完成对数据集的线性分割。而大多数样本都是非线性可分数据, 对于非线性可分数据, SVM 使用核函数将数据映射到高维空间中, 在高维空间中寻找一个超平面, 以实现数据的线性分割。对于数据集中存在离群点, 可以通过加入松弛因子对 SVM 模型进行优化, 也即是引入惩罚因子。

SVM 是一种基于核函数的学习机器, SVM 的泛化能力在很大程度上依赖于所选择的核函数^[19]。核函数的选择直接影响了样本在高维空间中的映射, 进而影响 SVM 对样本的分类。核函数的取值影响样本划分的精细程度, 数值过大易出现分类效果差, 数值过小则会出现过拟合的问题。而惩罚因子的取值决定了离群点对模型的影响, 数值过大易出现过拟合, 数值过小易出现欠拟合^[20]。

2 基于 MFCCDE 与 BA-SVM 的故障诊断方法

本文所提出的离心泵声信号故障诊断方法流程图如

图 2 所示, 具体步骤如下:

1) 对所输入的声信号, 需要先进行归一化操作, 以减少奇异样本对特征提取操作造成影响。同时, 对 MFCCDE 参数进行设置, MFCC 需要设置的参数主要有帧长、帧移、维度与累计贡献率, 其中维度参数的设置会影响特征提取后特征矩阵的维度及特征提取的效果。本文的帧长设置为 25 ms, 帧移设置为 10 ms, 维度设置为 13, 累计贡献率设置为 0.85。DE 需要设置的参数主要有嵌入维数, 时延和类别个数, 时延通常情况取 1, 嵌入维数过大则无法检测信号的细微变化, 过小则无法检测信号的动态变化, 嵌入维数设置为 3, 类别个数设置为 6。

2) 得到特征矩阵后, 为避免信息重叠造成的数据冗余, 通过 PCA 来提取特征矩阵的主成分, 将高维矩阵降至低维, 在保留原有矩阵特征的前提下, 加快了后续运算的速度。在降维的基础上, 将特征矩阵划分为训练集与测试集, 训练集与测试集占比为 4:1。

3) 对 SVM 分类的框架进行搭建。其中, 支持向量机中的惩罚系数 c 与核函数 g 即后续蝙蝠优化算法需要寻优的对象。

4) 对 BA 的默认参数进行设置, 主要参数包含种群大小、迭代次数、频率范围、维度等。生成随机粒子, 通过计算粒子在不断迭代过程中的适应度值, 用于评估蝙蝠个体的优劣程度。最后在输出粒子个体时对粒子进行判断, 其中粒子的输出要求为: 当粒子的适应度值小于设定值或粒子的迭代次数大于设定值时。




图 2 故障诊断方法流程

Fig. 2 Fault diagnosis method flow chart

5)对满足输出条件的粒子,也即寻优后的惩罚系数 c 与核函数 g ,将这两个参数代入 SVM 分类器中,完成对 SVM 分类器的训练。同时将 2) 中划分好的测试集输入进已完成训练的 SVM 分类器中进行分类验证,并计算分类准确率,输出分类结果。

3 实验数据分析


3.1 数据采集

实验对象如图 3 所示。本文设置 6 个通道对实验信号进行采集,声信号 2 路,振动信号 4 路,详见传感器布置如图 4 所示。




图 3 离心泵试验台


Fig. 3 Centrifugal pump bedstand




(a) 正常工况时域图
(a) Time domain diagram of normal condition



(b) 汽蚀工况时域图
(b) Time domain diagram of cavitation condition



(c) 螺栓松动工况时域图
(c) Time domain diagram of bolt loosening condition



(d) 不对中工况时域图
(d) Time domain diagram of misalignment condition

图 5 噪声信号部分时域图

Fig. 5 Noise signal partial time domain diagram




图 4 传感器布置图

Fig. 4 Sensor layout diagram

实验泵在电机额定转速 2 950 rpm/min 下运行,采用 GRAS 传声器对声信号进行采集,信号采样频率设置为 51 200 Hz。离心泵在实际运行过程经常会出现工况统计如下:正常、汽蚀、螺栓松动、不对中。试验中,汽蚀工况通过改变离心泵入口、出口压力获得,螺栓松工况通过松动底座螺栓实现,不对中则通过调整电机与泵体传动轴的偏移量获得。4 种工况下的噪声信号部分时域图如图 5 所示。

3.2 MFCCDE 特征提取

每种工况的噪声信号各选取 20 s,总计 1 024 000 个采样点,每 4 096 个采样点分为 MFCC 特征提取中的

一帧,每种工况各 250 组,总计 1 000 组。将所采集的噪声信号分为训练样本与测试样本,其中训练样本 800 组,测试样本 200 组。MFCC 特征维度设置为 13,帧长为 25 ms,帧移为 10 ms。根据所选参数对每帧信号进行特征提取,每帧可以得到各自对应的特征矩阵。为保留噪声信号原有的动态特征,需要对 MFCC 特征进行两次差分操作,以保留声信号的特点与走向趋势。

散布熵嵌入维数设置为 3,类别个数设置为 6,将 MFCC 提取后的特征作为输入,每帧列向量可计算出一个散布熵值,得到每帧特征矩阵。

经由 MFCCDE 特征提取后的特征序列与原始时域波形对比图如图 6~9 所示。特征提取后的采样点数量相对于原信号明显减少,且能大致表示出不同工况下原本的时域信号,有效地优化了采样点数过多的问题。




图 6 正常工况特征提取前后对比

Fig. 6 Comparison of normal condition before and after feature extraction




图 7 汽蚀工况特征提取前后对比

Fig. 7 Comparison of cavitation condition before and after feature extraction




图 8 螺栓松动工况特征提取前后对比

Fig. 8 Comparison of bolt loosening condition before and after feature extraction




图 9 不对中工况特征提取前后对比

Fig. 9 Comparison of misalignment condition before and after feature extraction

将 MFCCDE 所提取的特征矩阵进行行方向上的降维,即将一段时间序列中的 MFCCDE 特征由一个或少数几个值进行表示。将 4 种工况,总计 1 000 帧特征提取后的噪声信号都进行 PCA 降维,维数可由原来的 39 降至 16,极大减少了数据冗余所造成训练时间过长的问题。则最后形成的数据集大小为 $1\,000 \times 16$ ($250 \times 4 \times 16$),其中训练集大小为 800×16 ($200 \times 4 \times 16$),测试集大小为 200×16 ($50 \times 4 \times 16$)。

将所提取的特征做 t-SNE 可视化处理,以直观地观察在降维的同时是否保留原始信号的特征且具有一定的区分度与辨识度。t-SNE 可视化二维图、三维图如图 10 和 11 所示。特征提取降维后的信号可视化区分度良好,正常工况与故障工况之间区别明显,可以代入后续的 BA-SVM 模型进行分类。

3.3 BA-SVM 诊断分类

经由 MFCCDE 特征提取并降维后的输入 BASVM 分




图 10 t-SNE 可视化二维图

Fig. 10 t-SNE visual two-dimensional diagram




图 11 t-SNE 可视化三维图

Fig. 11 t-SNE visual three-dimensional diagram

类模型中,其中 BA 的基本参数设置如下:种群大小为 20,迭代次数为 50,响度为 0.5,脉冲速率为 0.5,频率范围 $[0,2]$,维度为 2。蝙蝠优化算法通过全局搜索得出 SVM 惩罚系数 c 与核函数 g 的最优解,并导入 SVM 分类器,诊断分类结果如图 12 所示。




图 12 MFCCDE-BASVM 混淆矩阵

Fig. 12 MFCC-DE-BASVM confusion matrix

为验证 MFCCDE-BASVM 模型的诊断优势,本文与 MFCC-SVM、VMD-BASVM、MFCC-BASVM 模型进行比较。确认蝙蝠优化算法的寻优能力,DE 对 MFCC 特征提取的改善能力,与主流特征提取方法 VMD 的诊断能力差异。3 种对比模型诊断混淆矩阵如图 13~15 所示,准确率迭代对比如图 16 所示。为消除模型诊断时出现奇异结果对模型最终的分类准确率造成影响,本文对 4 种模型分别进行 10 次随机诊断,统计其各故障类别的平均诊断准确率,结果如表 1 所示。




图 13 MFCC-SVM 混淆矩阵

Fig. 13 MFCC-SVM confusion matrix




图 14 VMD-BASVM 混淆矩阵

Fig. 14 VMD-BASVM confusion matrix




图 15 MFCC-BASVM 混淆矩阵

Fig. 15 MFCC-BASVM confusion matrix




图 16 准确率迭代曲线对比

Fig. 16 Comparison of accuracy iteration curves

由图 16 与表 1 可以看出,MFCC-SVM 模型因其不包含寻优过程,SVM 参数由人为设定,准确率不随迭代次数增加;VMD-BASVM 模型的准确率略高于 MFCC-BASVM 模型,但收敛的时间较长;MFCCDE-BASVM 模型的准确率略高于 VMD-BASVM 模型,且收敛速度快。蝙蝠优化算法的加入,很大程度上增加了 SVM 的分类准确率,MFCC 的特征提取效果虽然不如 VMD,但通过散布熵对 MFCC 的优化,不仅保留了 MFCC 原本收敛快的优势,同时提高了最终分类的准确率。

MFCC 的特征提取与诊断时间很短,但传统 MFCC 的准确率不如 VMD,经散布熵改进后的 MFCC 在特征提取与诊断时间上略有增加,诊断平均准确率从原来的 94.4% 提升至 96.45%,且特征提取时间短于 VMD。

表 1 各模型分类准确率对比表

Table 1 Comparison of classification accuracy of all models (%)

故障类别	分类准确率(测试集)			
	MFCC-SVM	VMD-BASVM	MFCC-BASVM	MFCC-DE-BASVM
正常	100	96.4	99.6	100
汽蚀	36.8	93.6	92.59	95.8
螺栓松动	90.8	95.6	93.4	95.7
不对中	63.2	99	94.4	94.5
总准确率	72.7	96.15	94.4	96.45

4 结 论

将声信号的梅尔倒谱系数与散布熵相结合,提出梅尔倒谱散布熵特征提取方法。散布熵在原有的基础上,增强了信号 MFCC 特征提取的数据挖掘精度,有效地对离心泵的故障信号进行识别并提取,利用 DE 对 MFCC 进行优化,模型的准确率提高 2.05%。

蝙蝠优化算法能实现支持向量机惩罚系数与核函数的自动选取。经过 BA 优化后的模型在准确率上提高了 21.7%。

参考文献

[1] SINGH V, GANGSAR P, PORWAL R, et al. Artificial intelligence application in fault diagnostics of rotating industrial machines: A state-of-the-art review [J]. Journal of Intelligent Manufacturing, 2021: 1-30.

[2] SUNAL C E, DYU V, VELISAVLJEVIC V. Review of machine learning based fault detection for centrifugal pump induction motors [J]. IEEE Access, 2022, 10: 71344-71355.

[3] ZHANG M, JIANG Z, FENG K. Research on variational mode decomposition in rolling bearings fault diagnosis of the multistage centrifugal pump [J]. Mechanical Systems and Signal Processing, 2017, 93: 460-493.

[4] 周云龙, 吕远征. 基于多点噪声分析的离心泵早期汽蚀故障诊断 [J]. 振动与冲击, 2017, 36(7): 39-44.

ZHOU Y L, LYU Y ZH. Incipient cavitations fault diagnosis for a centrifugal pump based on multi-position noise analysis [J]. Journal of Vibration and Shock, 2017, 36(7): 39-44.

[5] ARASTE Z, SADIGHI A, JAMIMOGHADDAM M. Fault diagnosis of a centrifugal pump using electrical signature analysis and support vector machine [J]. Journal of Vibration Engineering & Technologies, 2022: 1-11.

[6] CHEN Y F, YUAN J, LUO Y, et al. Fault prediction of centrifugal pump based on improved KNN [J]. Shock and Vibration, 2021, 2021: 1-12.

[7] 王前, 王刚, 蒋晗晗, 等. 基于 MFCC 与 CDET 的滚动轴承故障诊断方法研究 [J]. 控制工程, 2019, 26(9): 1682-1686.

WANG Q, WANG G, JIANG H H, et al. Study on fault diagnosis of rolling bearing based on MFCC and CDET [J]. Control Engineering of China, 2019, 26(9): 1682-1686.

[8] YAN H, BAI H, ZHAN X, et al. Combination of VMD mapping MFCC and LSTM: A new acoustic fault diagnosis method of diesel engine [J]. Sensors, 2022, 22(21): 8325.

[9] 狄晓栋, 李震梅, 李宗哲, 等. 基于混合特征 MGCC 的干式变压器故障诊断 [J]. 电子测量技术, 2021, 44(12): 57-62.

DI X D, LI ZHH M, LI Z ZH, et al. Fault diagnosis of dry-type transformer based on combination of MGCC feature parameter [J]. Electronic Measurement Technology, 2021, 44(12): 57-62.

[10] 杨潇谊, 吴建德, 马军. 基于散布熵和余弦欧氏距离的滚动轴承性能退化评估方法 [J]. 电子测量与仪器

- 学报, 2020, 34(7): 15-24.
- YANG X Y, WU J D, MA J. Rolling bearing performance degradation assessment method based on dispersion entropy and cosine Euclidean distance [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(7): 15-24.
- [11] 钱恩丽, 黄国勇, 李锶宇, 等. 基于 CMFDE 的单向阀早期微弱故障诊断方法[J]. 电子测量与仪器学报, 2021, 35(4): 169-176.
- QIAN EN L, HUANG G Y, LI S Y, et al. Method of CMFDE in check valve early weak fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(4): 169-176.
- [12] ZHANG J, JIANG Q, CHANG F. Fault diagnosis method based on MFCC fusion and SVM* [C]. 2018 IEEE International Conference on Information and Automation (ICIA). IEEE, 2018.
- [13] 李从志, 郑近德, 潘海洋, 等. 基于精细复合多尺度散布熵与支持向量机的滚动轴承故障诊断方法[J]. 中国机械工程, 2019, 30(14): 1713-1719, 1726.
- LI C ZH, ZHENG J D, PAN H Y, et al. Fault diagnosis method of rolling bearings based on refined composite multiscale dispersion entropy and support vector machine [J]. China Mechanical Engineering, 2019, 30(14): 1713-1719, 1726.
- [14] WANG Y, SHANG P J. Complexity analysis of time series based on generalized fractional order refined composite multiscale dispersion entropy [J]. International Journal of Bifurcation and Chaos. 2020. DOI: 10.1142/S0218127420502119.
- [15] 梁晴晴, 韩华, 崔晓钰, 等. 基于主元分析-概率神经网络的制冷系统故障诊断[J]. 化工学报, 2016, 67(3): 1022-1031.
- LIANG Q Q, HAN H, CUI X Y, et al. Fault diagnosis for refrigeration system based on PCA-PNN [J]. CIESC Journal, 2016, 67(3): 1022-1031.
- [16] CAO S, HU Z, LUO X, et al. Research on fault diagnosis technology of centrifugal pump blade crack based on PCA and GMM [J]. Measurement, 2020, 173(4): 108558.
- [17] 宣恒农, 苗春玲, 赵冬. 基于蝙蝠算法的系统级故障诊断研究[J]. 计算机工程与科学, 2016, 38(4): 640-647.
- XUAN H N, MIAO CH L, ZHAO D. System-level fault diagnosis based on bat algorithm [J]. Computer Engineering & Science, 2016, 38(4): 640-647.
- [18] 武玉坤, 肖杰, 李伟, 等. 融合渐近性的灰狼优化支持向量机模型[J]. 计算机科学, 2020, 47(2): 37-43.
- WU Y K, XIAO J, LI W, et al. Support vector machine model based on grey wolf optimization fused asymptotic [J]. Computer Science, 2020, 47(2): 37-43.
- [19] 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[J]. 仪器仪表学报, 2020, 41(1): 195-205.
- GONG W F, CHEN H, ZHANG M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.
- [20] 吕明珠, 苏晓明, 陈长征, 等. 改进粒子群算法优化的支持向量机在滚动轴承故障诊断中的应用[J]. 机械与电子, 2019, 37(1): 42-48.
- LYU M ZH, SU X M, CHEN CH ZH, et al. Application of SVM optimized by IPSO in rolling bearing fault diagnosis [J]. Machinery & Electronics, 2019, 37(1): 42-48.

作者简介



陈剑 (通信作者), 现为合肥工业大学教授、博士研究生导师, 主要研究方向为汽车 NVH 与 CAE、机械低噪声设计、机械故障诊断。

E-mail: hfkd8216@126.com

Chen Jian (Corresponding author) is a professor and Ph. D. supervisor at Hefei University of Technology. His main research interests include automobile NVH and CAE, low-noise design of mechanical product and fault diagnosis of machinery.



姜涛, 现为合肥工业大学硕士研究生, 主要研究方向为数字信号处理及故障诊断。

E-mail: jiang_tao0124@163.com

Jiang Tao is a M. Sc. candidate at Hefei University of Technology. His main research interests include digital signal processing and fault diagnosis.