

基于SVM的液压机械驱动齿轮组故障诊断研究^{*}王宽田¹ 姚江云² 唐永忠¹ 梁世华³

(1. 桂林电子科技大学海洋工程学院 北海 536000; 2. 柳州工学院信息科学与工程学院 柳州 545000;

3. 桂林理工大学计算机科学与工程学院 桂林 541004)

摘要: 针对液压机械驱动齿轮组故障诊断结果精准度不佳、可靠性差等问题,本文提出基于SVM的液压机械驱动齿轮组故障诊断研究。采集了液压机械驱动齿轮组振动信号,构建液压机械驱动齿轮组故障信号分离模型;运用低秩算法分离液压机械驱动齿轮箱振源信号,设计齿轮组故障信号约束条件,完成液压机械驱动齿轮组分类;根据分类结果,采用SDAE模型提取液压机械驱动齿轮组故障特征,并将提取结果输入到支持向量机内训练,其最终输出结果就是最佳诊断结果,实现基于SVM的液压机械驱动齿轮组故障诊断研究。实验结果表明,通过该方法开展故障检测及故障诊断测试,本文方法下分类错误率不超过3.5%,验证了该方法的可行性高。

关键词: SVM; 液压机械驱动齿轮组; 故障分类; SDAE模型; 信号分离

中图分类号: TH165; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.46025

Research on fault diagnosis of hydraulic mechanical drive gear set
based on SVMWang Kuantian¹ Yao Jiangyun² Tang Yongzhong¹ Liang Shihua³(1. Ocean Engineering College, Guilin University of Electronic Technology, Beihai 536000, China;
2. School of Information Science and Engineering, Liuzhou Institute of Technology, Liuzhou 545000, China;
3. School of Computer Science and Engineering, Guilin University of Technology, Guilin 541004, China)

Abstract: This paper addresses the challenges of poor accuracy and reliability in fault diagnosis for hydraulic mechanical drive gear sets by proposing a research approach based on Support Vector Machines (SVM). The study begins by collecting vibration signals from the hydraulic mechanical drive gear group and constructing a fault signal separation model. Utilizing a low-rank algorithm, the research separates the vibration source signals of the hydraulic mechanical drive gearbox. Constraint conditions are designed for gear group fault signals to facilitate their classification. Based on these classification results, the SDAE model is employed to extract fault features from the hydraulic mechanical drive gear group. The extracted features are then input into the SVM for training, with the final output being the optimal diagnostic result. This approach achieves fault diagnosis of the hydraulic mechanical drive gear group based on SVM. Experimental results demonstrate that the classification error rate of this method does not exceed 3.5%, confirming its high feasibility.

Keywords: SVM; rotating machinery gear set; fault classification; SDAE model; signal separation

0 引言

液压机械在运行期间基本一半以上的故障都是由齿轮箱的齿轮组造成^[1-2],齿轮组故障多数为局部故障、点蚀、磨损、断齿等。如果旋转机械在复杂环境下运行,齿轮组就会处于封闭状态密闭运行。这种情况即使齿轮组出现异常也不容易被发现,还会造成生产运输存有延迟、生产效率低

问题,严重的还会导致出现事故损失及伤亡。所以为了可以监控液压机械驱动齿轮组的运行状态,需要对液压机械齿轮组开展故障诊断研究。

庞新宇等^[3]将格拉姆角场-卷积神经网络方法引入液压机械驱动齿轮组故障诊断中,获取液压机械驱动齿轮组振动信号,形成2D图像,再从图像中提取齿轮箱特征,对其优化后输入到卷积神经网络模型内,为防止出现故障诊

断精度低的问题,结合网络参数构建出最优模型组合,再利用该模型对输入的特征识别,从而完成齿轮组的故障诊断研究,此方法能够有效缩短故障诊断耗时,但是信号转换结果不佳,存在故障诊断可靠性低的问题。权振亚等^[4]将局部特征尺度分解方法引入齿轮故障诊断中,采集液压机械驱动齿轮组故障数据,对采集结果进行预处理后从中取得齿轮分量;根据分解结果采用符号熵对不同区域下的故障信号计算,并将计算结果作为齿轮故障特征参数,通过构建自适应神经模糊推理系统神经网络(adaptive neuro-fuzzy inference system neural network classifier, ANNC)分类器,将特征参数输入到分类器内,从中诊断出齿轮的故障,实现齿轮故障诊断,此方法能够准确对齿轮故障特征进行分类,但是分解结果不完善,存在故障诊断与实际结果误差大的问题。陈仁祥等^[5]通过构建深度置信网络对液压机械驱动齿轮组故障进行诊断,将机械齿轮组故障数据作为网络输入,并对该信号实施分级表示,获取齿轮的分布式特征,以此构建深度信念网络(deep belief network, DBN)模型,通过对信号的标记结果调整模型权重,以此完成对齿轮箱从源域到目标域的样本识别,实现齿轮箱故障最终诊断。此方法能够简化齿轮箱故障诊断过程,提升故障诊断效率。但是调整结果存有误差,存在故障诊断可行性低的问题。

Zhang等^[6]提出基于注意力的双尺度特征融合胶囊网络的液压机械驱动齿轮组故障智能诊断方法,采集液压机械驱动齿轮组的振动、温度等传感器数据,并进行预处理和特征提取。构建结合注意力机制的双尺度特征融合胶囊网络,从多个信号源中提取特征并进行融合。使用提取的数据集对模型进行训练及优化,以提高故障诊断的准确性和鲁棒性。但是此方法真实故障样本往往比正常样本少,存在样本不平衡问题。Zhang等^[7]提出了一种基于短时傅立叶变换和卷积神经网络的滚动轴承智能故障诊断方法。通过短时傅里叶变换(short time fourier transform, STFT)将一维振动信号转换为时频图像。然后,将时频图像输入到短时傅里叶变换卷积神经网络(short-time fourier transform convolutional neural network, STFT-CNN)模型中,采用了堆叠的双卷积层来提高模型的非线性表达能力。然而,该方法主要基于时频图谱进行诊断,未能有效解决样本与类别一对一关系的问题,这也可能限制了诊断性能的进一步提升。

为了解决上述方法中存在的问题,提出基于支持向量机(support vector machine, SVM)的液压机械驱动齿轮组故障诊断研究,运用低秩算法分离旋转机械的齿轮箱振源信号,设计齿轮组故障信号约束条件,对液压机械驱动齿轮组进行分类,有效提升了液压机械驱动齿轮组故障诊断效果。

1 液压机械驱动齿轮组振动信号采集及去噪

1.1 液压机械驱动齿轮组振动信号采集

将旋转机械出现故障的位置作为故障类型,并对故障

区域的原始数据进行采集,分别采用振动传感器、扭力传感器对旋转机械的数据组获取,以此采集到液压机械驱动齿轮组原始信号数据集,其采集结果用下式定义:

$$\begin{cases} y_i \in \{y_1, y_2, y_3\}, i = 1, 2, \dots, 3l \\ D = \{D_1 \cup D_2\} \\ D_1 = \{(x_i, y_i)\}, i = 1, 2, \dots, 3l \\ D_2 = \{(x'_i, y_i)\}, i = 1, 2, \dots, 3l \end{cases} \quad (1)$$

式中: y_i 为故障类型, $y_i \in \{y_1, y_2, y_3\}$; y_1 为裂纹故障, y_2 为缺齿故障, y_3 为断齿故障, x_i 为振动传感器测量输出, x'_i 为扭力传感器测量输出, D 为采集的原始信号数据集。

1.2 液压机械驱动齿轮组噪声信号分离

在具有稀疏性的未知信号在不确定线性系统中,即欠采样情况下可以有唯一且稳定的解,当液压机械驱动齿轮组信号矩阵的列或行具有相似性时,此时表明矩阵的秩具有稀疏性,通过降低秩值来化知信号的复杂度,本文使用的低秩约束是一种的低秩算法,旋转机械的齿轮箱在正常状态运行下,旋转机械或机械内部产生的信号通常具备低秩性,这种低秩性可以对振动信号分离特征进行约束,达到克服现有分离方法存在的不确定性问题。首先采集的液压机械驱动齿轮组原始信号,验证液压机械驱动齿轮组振动信号原始信号的噪声数据是否满足高斯分布,构建低秩约束下的振源信号分离模型^[8],其构建结果如下:

$$\begin{cases} \underset{L, N}{\operatorname{argmin}} \operatorname{rank}(L) + \beta \times \operatorname{kur}(N) \\ s. t. D = L + N \end{cases} \quad (2)$$

式中: D 为观测矩阵, N 为噪声项, L 为低秩矩阵, rank 为秩函数, β 为折中因子, $\operatorname{kur}(N)$ 为峰度函数。

由于方程(2)属于较复杂多项式,所以采用凸松弛对方程(2)转化,定义如下:

$$\begin{cases} \underset{L, N}{\operatorname{argmin}} \|L\| + \beta \times \operatorname{kur}(N) \\ s. t. D = L + N \end{cases} \quad (3)$$

式中: $\|L\|$ 为核范数。

为了可以分离出低秩约束下液压机械驱动齿轮组的多个振动源,在构建的模型基础上对其修正,组成多低秩约束的分离模型:

$$\begin{cases} \underset{L, N}{\operatorname{argmin}} \sum_{i=1}^n \lambda_i \|L_i\| + \beta \times \operatorname{kur}(N) \\ s. t. x = \sum_{i=1}^n L_i + N \end{cases} \quad (4)$$

式中: l_i 为有序数组, n 为待分离数量, λ 为低秩矩阵权重。

设置有一组长度为 m 的液压机械驱动齿轮组振动信号,即 $x(t)$, 利用低秩矩阵 L_i 获取。设定 w 代表分块算子,通过 w 可以实现 $x(t)$ 到二维矩阵 L_i 的变换。

由不同转速下齿轮组产生特征频率,分析模数、齿数、分度圆直径等的齿轮组设计参数,根据液压机械系统的应用场景和要求,设计齿轮组故障信号低秩约束条件如式(5)所示:

$$\frac{p_i \lambda_i f_s}{f_{sourcei}} > o_i \quad (5)$$

式中: o_i 为阵列长度, p_i 为阵列数量, f_s 为采样频率, $f_{sourcei}$ 为振源信号特征频率。结合上述约束对分离模型进行求解, 完成齿轮组故障信号进行分类, 以便确认不同类型的故障, 如齿面磨损、齿侧间隙变化、颤振等。不同的故障类型在振动频谱和特征频率上有不同的信号特征, 通过分类可以更精准地识别故障类型。

根据计算结果, 利用 w 对低秩约束下液压机械驱动齿轮组信号分块, 如图 1 所示。

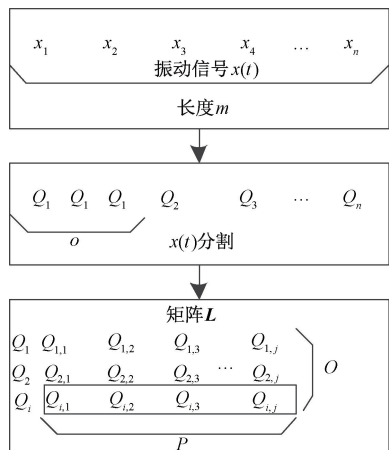


图 1 液压机械驱动齿轮组分块算子计算

Fig. 1 Calculation of block operators for hydraulic mechanical drive gear components

根据图 1 分块结果, 利用拉格朗日乘子法解决旋转机械出现的凸优化问题, 以此对分块后的液压机械驱动齿轮组振源信号求解。那么建立的增强拉格朗日函数为:

$$La(l_i, N, Y, \mu_k) = \sum_{i=1}^n \lambda_i \|L_i\| + \beta kur(N) + \langle Y, x - \sum_{i=1}^k L_i - N \rangle \quad (6)$$

式中: La 为增强拉格朗日函数, Y 为拉格朗日乘子, μ_k 为迭代步长, $\langle \rangle$ 为内积运算。

基于构建结果, 采用交替方向乘子法对各个低秩矩阵核范数最小值优化及噪声项最小峰度迭代, 其迭代过程为:

$$\begin{cases} l_{i,k+1} = \arg \left\{ \frac{\lambda_i}{\mu_k} \|L_i\| + \frac{1}{2} \right\} x - \sum_{j=1}^{i-1} l_{j,k+1} - \\ l_i - \sum_{j=i+1}^n l_{j,k} - N_k \\ 1/2 \|x - \sum_{j=1}^q l_{j,k} - N + 1/\mu_k\| \end{cases} \quad (7)$$

式中: j 为系数。

采用奇异值分解及软阈值对上述方程求解, 定义为:

$$\begin{cases} [U_i, S_i, V_i] = SVD(w(T_{i,k}, o_i, p_i)) \\ l_{i,k+1} = w(U_i S_{\lambda_i/\mu_k} [S_i] V_i^T)^{-1} \end{cases} \quad (8)$$

式中: SVD 为奇异值分解算子, $S_{\lambda_i/\mu_k} [S_i]$ 为正直参数, S_{λ_i/μ_k} 为软阈值收缩操作符, w 为分块算子逆运算, U_i 为奇异值, V 为随机参数。

依据求解结果, 对低秩约束下液压机械驱动齿轮组振源信号实施分离, 使液压机械驱动齿轮振源信号的故障诊断结果更佳, 分离流程如下图 2 所示。

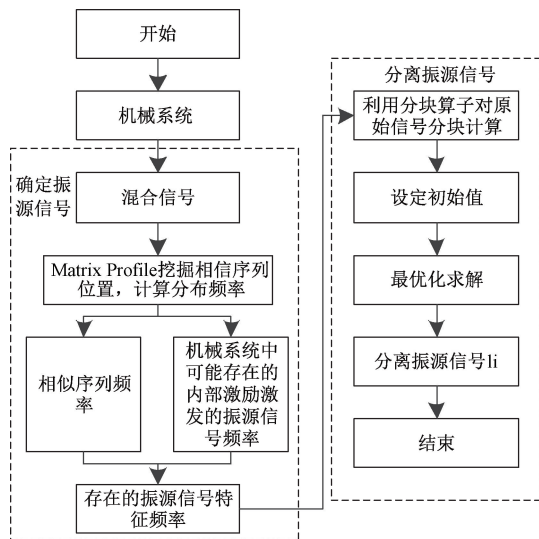


图 2 分离流程

Fig. 2 Separation process

2 基于 SVM 的液压机械驱动齿轮组故障诊断

低秩约束下液压机械驱动齿轮组振源信号的分离对液压机械驱动齿轮组故障诊断的研究具有重要意义, 基于分离结果大大的提升了液压机械驱动齿轮组的分类效果。

2.1 液压机械驱动齿轮组故障特征提取

对低秩约束下液压机械驱动齿轮组振源信号分离后, 利用堆叠去噪自编码器 (stacked denoising autoencoder, SDAE) 模型提取液压机械驱动齿轮组故障特征^[9], 再将提取结果输入到构建的 SVM 分类器中训练, 其结果就是最终诊断结果。

将优化准则引入到 SDAE 模型内, 便于提取出更加有效的液压机械驱动齿轮故障特征。

1) 最小稀疏性

液压机械驱动齿轮故障特征稀疏性可有效表现出齿轮组潜存特点, 完美表示出齿轮组本质故障特征, 定义为:

$$f_1(S) = \sum_{j=1}^D KL(\rho \parallel \hat{\rho}_j) \quad (9)$$

式中: ρ 为稀疏参数, $KL(\rho \parallel \hat{\rho}_j)$ 为相对熵, $\hat{\rho}_j$ 为平均激活度, j 为隐含层数量, $f_1(S)$ 为稀疏度, D 为隐含层节点数。

当 $f_1(S)$ 的取值越小时, 说明提取的液压机械驱动齿轮故障特征稀疏度就越小, 因而对 $f_1(S)$ 归一化处理, 令 $f_1(S) \in [0, 1]$ 。

2)最低分类错误率 90

为降低液压机械驱动齿轮组故障诊断错误率,需要令错误率保持最低,因而用方程表达式定义为:

$$f_2(S) = 1 - s/M \quad (10)$$

式中: s 为正确诊断样本, M 为样本尺寸。

基于以上优化目标,构建 SDAE 故障特征提取模型,其目标函数定义为:

$$\begin{cases} \min F(S) \\ F(S) = \{f_1(S), f_2(S)\} \end{cases} \quad (11)$$

基于构建结果,利用该模型提取低秩约束下液压机械驱动齿轮组故障特征,其提取流程如下所示:

输入:液压机械驱动齿轮组振源信号频谱 X 、标签 y 。

(1)设置各类参数,确定种群邻居;

(2)计算旋转机械决策向量 d 的目标函数值,从而计算出该种群的最小目标值;

(3)从种群内挑选出两个邻居,实施交叉操作后更新种群邻居及最小目标值;

(4)若达到最大迭代次数则结束,反之继续进行步骤 3;

(5)获取多个最佳 MO-SADE,从中提取出液压机械驱动齿轮组多样性故障特征。

输出:液压机械驱动齿轮组多样性故障特征。

2.2 基于 SVM 的液压机械驱动齿轮组故障诊断

假设干净的低秩矩阵 $L \in R^{m \times n}$ 被稀疏误差矩阵 $S \in R^{m \times n}$ 污染,那么液压机械驱动齿轮组故障退化模型:

$$D = L + S \quad (12)$$

其中, $D \in R^{m \times n}$ 是观测数据矩阵,是已知的;低秩矩阵 L 和稀疏误差矩阵 S 都是未知的,最终目的是恢复出低秩矩阵 L 。这个问题的表述提出一个概念性的解决方案:找到能够产生使已知数据的秩最低的矩阵 L , 约束条件是误差矩阵 S 是稀疏的,即 $\|S\|_0 \leq k$ 。

要寻找最佳低秩矩阵,可以利用最小化观测矩阵和低秩矩阵的均方误差:

$$\min_L \|L - D\|_{FS}^2, t. \quad rank(L) = r \quad (13)$$

其中, $\|\cdot\|_F$ 是弗罗贝尼乌斯范数, $rank(L)$ 表示矩阵的秩, r 是期望得到的秩。

将期望得到的秩 r , 输入到 SVM 内训练^[10-12], 实现最终诊断。

设置液压机械驱动齿轮组样本集内支持向量机定义: (x_i, y_i) , 其中, x_i 为类属性, y_i 为类标记。映射 SVM 从低维空间到高维空间^[13-14], 取得最佳超平面:

$$f(x) = \sum_{i=1}^n y_i a_i K(x, x_i) + b \quad (14)$$

式中: a_i 为拉格朗日乘子, $K(x, x_i)$ 为核函数, b 为偏置。

其中高斯径向核函数表述为:

$$K(x, x_i) = \exp \left[-\frac{(x, x_i)^2}{2\sigma^2} \right] \quad (15)$$

式中: σ 为方差, 即 $g = 1/2\sigma^2$, g 为核函数参数。

根据以上结果,实现支持向量机的构建,并基于支持向量机对液压机械驱动齿轮组实施故障诊断,其诊断流程如下所示:

1)采集多故障情况下的齿轮组振动信号;

2)对采集结果进行分离处理,获取低秩约束下液压机械驱动齿轮组振源信号,提升故障诊断效果;

3)提取液压机械驱动齿轮组故障特征,并将其划分成训练样本及测试样本;

4)将训练样本输入到构建的 SVM 支持向量机内,经训练后实现故障诊断^[15]。

依据上述故障诊断流程,实现低秩约束下液压机械驱动齿轮组故障诊断研究。

3 实验与分析

3.1 实验环境

为了验证基于 SVM 的液压机械驱动齿轮组故障诊断方法研究的整体有效性,需要对该方法开展实验对比测试。本次实验设定所有液压机械齿轮组均为健康齿轮,而 3 个液压机械齿轮组则呈现出不同的健康状态,具体如表 1 所示。

表 1 齿轮数据描述

Table 1 Gear data description

类别标号	故障类型
1	输入级齿轮断
2	输入级齿轮齿面胶合剥落
3	中间级齿轮齿面胶合剥落
4	输出级齿轮齿面胶合剥落及断齿
5	输出级齿轮缺齿
6	输入级齿轮齿根裂纹
7	中间级齿轮齿根裂纹
8	输出级齿轮齿根裂纹
9	输入级齿轮断齿加中间级齿轮齿面胶合剥落
10	健康

为测试基于 SVM 的液压机械驱动齿轮组的故障诊断效果,本次实验采用美国 Spectra Quest 公司的液压机械驱动齿轮组动力传动故障诊断实验台作为本次测试环境,具体如图 3 所示。

如图可知,实验台中由一个电机、一个扭矩传感器、一个减速器、一个致动器构成。将扭矩传感器安装在液压机械驱动齿轮组轴承支座处。通过测量轴承支座处的扭矩变化,可以间接监测齿轮组的工作状况。将减速器安装在驱动电机和液压机械之间的连接部位,用于改变电机输出的转速和扭矩。将致动器安装在与齿轮组关键传动部件紧密相连的位置,以直接驱动关键部件的运动。将传感器连接



图 3 测试环境

Fig. 3 Test environment

到数据采集设备,确保传感器正常工作并能够稳定地采集信号,将温度传感器安装在齿轮箱或液压系统关键部位,以监测温度异常情况。安装声音传感器在机械部件周围,以捕获液压机械运行时产生的声音信号。具体实验步骤如下:

1)对液压机械驱动齿轮组施加不同类型的故障,如齿轮故障、轴承故障等,模拟真实工况下的故障情况。

2)对采集到的数据进行预处理,包括噪声去除、滤波等操作。

3)分析传感器数据,提取特征,为后续故障诊断模型的建立提供支持。

通过以上关键步骤,研究者可以在实验中准确采集液压机械驱动齿轮组的相关数据,并模拟不同故障情况,为故障诊断方法的研究提供可靠的实验依据。

根据实验环境,利用 ZonicBook/618E 测试仪及加速传感器对齿轮箱齿轮组的水平径向、垂直径向、轴向 3 个方面开展振动信号采集,设置采样频率为 5 000 Hz,根据采样结果获取采样点数 8 500 个。

本文采用通过在实验室或实际工厂场景中搭建液压机械驱动齿轮组测试台,利用传感器采集振动、温度、声音等信号数据。通过模拟不同的工况和故障状态,收集到具有代表性的数据作为实验样本集。具体通过对 5 种故障类型每种类型分别提取 40 组由特征指标组成的特征向量,共计 200 组特征向量。每种故障类型任意选取 20 组作为训练样本进行模式训练故障分类,得到每种故障特征向量的聚类中心,然后对 200 组故障信号的特征向量进行故障识别与诊断的测试,并循环上述过程 5 次,分别计算 5 次训练分类以及测试诊断的准确率。其中训练的故障特征向量与测试的故障特征向量均采用上述所提的方法进行提取得到的。

3.2 实验指标

通过分类错误率以及故障诊断结果准确性性能指标进行评估训练完成后的模型对测试数据的测试效果。其中故

障诊断的分类错误率公式表示为:

$$A_i = 1 - \frac{N_{pi}}{N_{Ai}} \times 100\% \tag{16}$$

其中, A_i 为第 i 类故障诊断的分类错误率; N_{pi} 为第 i 类故障测试数据诊断正确的数量; N_{Ai} 为第 i 类故障测试数据的总数量。

3.3 实验结果分析

根据上述设置的实验环境,提取采集信号的齿轮特征,从中选取 1 000 个齿轮特征作为故障检测数据,采用采用基于 SVM 的液压机械驱动齿轮组故障诊断方法研究(方法 1)、改进卷积神经网络方法(方法 2)、局部特征尺度分解方法(方法 3)分别对特征数据进行故障检测,检测结果如表 2 所示。

表 2 三种方法的分类错误率测试

Table 2 Classification error rate test of three methods

特征数据/个	方法 1	方法 2	方法 3
100	1.2	2.3	3.2
200	1.3	2.6	3.6
300	1.5	2.7	3.9
400	1.7	2.9	4.1
500	2.1	3.3	4.3
600	2.2	3.5	4.6
700	2.6	3.8	4.7
800	2.9	4.0	5.2
900	3.1	4.3	5.6
1 000	3.5	4.5	5.8

分析表 2 中的数据发现,随着齿轮特征数据的不断提升,3 种方法所呈现的故障检测结果均不相同。从整体上看,方法 1 的故障检测结果明显优于方法 2 和方法 3,验证了方法 1 的故障检测性能最优。

设置的实验环境可以进行多种工况诊断,针对这一情况设立 3 种故障工况,并对液压机械驱动齿轮组在设立的工作况情况下进行故障诊断。3 种故障类型实物图如图 4 所示。

在正常、缺齿、裂纹 3 种工况下分别采集液压机械驱动齿轮组振动信号,同时每种状态下所采集的样本量为 50 组,分别抽取 30 组用作训练样本,剩余 20 组为样本。根据采集结果提取液压机械驱动齿轮组振动信号特征向量,将每种工况下的 20 组特征向量输入到支持向量机中进行故障识别。设置 $y = 1$ 为正常齿轮; $y = 2$ 为缺齿; $y = 3$ 为裂纹。根据设置结果,采用 3 种方法分别对 3 种工况下的测试样本开展故障诊断性能测试,并将诊断结果与实际结果对比,结果如表 3 所示。




图4 齿轮故障类型实物图
Fig. 4 Physical picture of gear fault types

表3 故障诊断效果测试

Table 3 Fault diagnosis effect test

测试样本	实际分类结果	方法1	方法2	方法3
10	10	10	7	8
20	20	20	18	16
30	30	30	28	25
40	39	40	33	36
50	50	50	40	42
60	60	60	51	54

分析表3中的数据发现,3种方法的测试结果与实际结果对比时,所呈现出的诊断性能皆不相同。测试样本个数为10时,方法1与实际结果一致,方法2中有3个样本点出现偏离,方法3中有2个样本点出现偏离;

测试样本个数为40时,方法1中有1个样本点出现偏离,方法2中有7个样本点出现偏离,方法3中有4个样本点出现偏离,整合上述表1结果,说明方法1的故障诊断结果准确性较强、诊断方法的可行性较高。

综上所述,方法1的故障检测性能及故障诊断效果最佳,这是因为方法1对采集的低秩约束下液压机械驱动齿轮组信号开展了振源信号分离,大大的提升了液压机械驱

动齿轮组的分类效果,增强了方法1的分类准确性。

为进一步验证实验性能,在CWRU(西储大学)轴承数据中心抽取1 000条数据进行实验分析,分析结果如表4所示。

表4 故障诊断效率分析

Table 4 Analysis of fault diagnosis efficiency

迭代次数/次	故障诊断时长/s		
	方法1	方法2	方法3
10	9	19	35
20	8	20	36
30	10	21	35
40	9	22	34
50	8	23	33
60	6	25	32
70	9	24	33
80	10	22	32
90	8	23	35
100	7	24	34

根据上述结果可以看出,方法1的故障诊断时长明显低于对比方法,时间最长仅为10 s,而方法2最高时长达到了25 s,方法3的最高时长达到了36 s,由此说明,本文方法的故障诊断效率较高。

为了全面验证液压系统在多样化工作条件下的运行情况,实验环境拟不同的工作负载,有恒定负载、正弦负载、斜坡负载与脉冲负载4种,3种方法进行故障类型诊断测试,结果如图5所示。




图5 齿轮故障诊断

Fig. 5 Gear fault diagnosis

根据图 5 可以看出,在不同负载环境下,本文方法将对比方法的诊断精度更高,仅有 2 个误差,而方法 2 存在 9 个误差,方法 3 存在 7 个误差,由此说明本文方法在不同工况下的诊断精度较优,具有实用性。

4 结 论

液压机械驱动齿轮组的运行磨损会降低工业生产效率,针对这一问题,提出基于 SVM 的液压机械驱动齿轮组故障诊断研究。该方法采集了液压机械驱动齿轮组振动信号,并对液压机械驱动齿轮组开展振源信号分离,达到提升分类效果的目的;根据处理结果,利用 SDAE 模型提取液压机械驱动齿轮组故障特征,并将输入到 SVM 分类器中训练,其训练结果就是最终诊断结果。该方法在液压机械驱动齿轮组故障诊断方法中发挥着重要作用,在今后有着长远的发展前景。

参考文献

- [1] 王洋,杨立. 旋转机械红外智能状态监测与故障诊断[J]. 光学精密工程, 2022, 30(16): 1905-1914.
WANG Y, YANG L. Infrared intelligent condition monitoring and fault diagnosis of rotating machinery[J]. Optics and Precision Engineering, 2022, 30 (16): 1905-1914.
- [2] 石明宽,赵荣珍. 基于局部质心均值最小距离鉴别投影的旋转机械故障数据降维分析研究[J]. 振动工程学报, 2021, 34(2): 421-430.
SHI M K, ZHAO R ZH. Dimensional reduction analysis of rotating machinery fault data based on local centroid mean minimum-distance discriminant projection[J]. Journal of Vibration Engineering, 2021, 34(2): 421-430.
- [3] 庞新宇,全钰,魏子涵. 一种 GAF-CNN 行星齿轮箱故障诊断方法[J]. 北京理工大学学报, 2020, 40(11): 1161-1167.
PANG X Y, TONG Y, WEI Z H. A fault diagnosis method for planetary gearbox based on GAF-CNN[J]. Transactions of Beijing Institute of Technology, 2020, 40(11): 1161-1167.
- [4] 权振亚,沈丽虹,赵富强. 基于内禀尺度分量符号熵和 ANNC 的齿轮故障诊断方法[J]. 机械强度, 2020, 42(1): 29-35.
QUAN ZH Y, SHEN L H, ZHAO F Q. Gear fault diagnosis method based on intrinsic scale components symbol entropy and ANNC[J]. Journal of Mechanical Strength, 2020, 42(1): 29-35.
- [5] 陈仁祥,杨星,胡小林,等. 深度置信网络迁移学习的行星齿轮箱故障诊断方法[J]. 振动与冲击, 2021, 40(1): 127-133.
CHEN R X, YANG X, HU X L, et al. Planetary gearbox fault diagnosis method based on deep belief network transfer learning[J]. Journal of Vibration and Shock, 2021, 40(1): 127-133.
- [6] ZHANG Q Y, LI J M, DING W M, et al. Mechanical fault intelligent diagnosis using attention-based dual-scale feature fusion capsule network[J]. Measurement, 2023, 207: 112345.
- [7] ZHANG Q, DENG L F. An intelligent fault diagnosis method of rolling bearings based on short-time fourier transform and convolutional neural network[J]. Journal of Failure Analysis and Prevention, 2023, 2 (23): 795-811.
- [8] 王文益,邵宇识. 基于改进单天线投影算法的广播式自动相关监视信号分离[J]. 电子与信息学报, 2020, 42(11): 2720-2726.
WANG W Y, SHAO Y SH. Signal separation for automatic dependent surveillance-broadcast using improved single antenna project algorithm[J]. Journal of Electronics & Information Technology, 2020, 42(11): 2720-2726.
- [9] 崔佳,郭瑞东,张卓然,等. 基于改进 DBN 的发电机旋转整流器故障特征提取技术[J]. 中国电机工程学报, 2020, 40(7): 2369-2376.
CUI J, GUO R D, ZHANG ZH R, et al. Generator rotating rectifier fault feature extraction technique based on improved DBN[J]. Proceedings of the CSEE, 2020, 40(7): 2369-2376.
- [10] 方涛,钱晔,郭灿杰,等. 基于天牛须搜索优化支持向量机的变压器故障诊断研究[J]. 电力系统保护与控制, 2020, 48(20): 90-96.
FANG T, QIAN Y, GUO C J, et al. Research on transformer fault diagnosis based on a beetle antennae search optimized support vector machine[J]. Power System Protection and Control, 2020, 48(20): 90-96.
- [11] 熊燕,邹自明,程加堂,等. 一种自适应 CS 算法及其在风电齿轮箱故障诊断中的应用[J]. 机械传动, 2023, 47(1): 132-137.
XIONG Y, ZOU Z M, CHENG J T, et al. A self-adaptive CS algorithm and its application in fault diagnosis of wind turbine gearboxes[J]. Journal of Mechanical Transmission, 2023, 47(1): 132-137.

- [12] 蔡超志,白金鑫,池耀磊,等. 基于 CEEMDAN 自适应小波降噪与卷积神经网络的齿轮箱故障诊断研究[J]. 机床与液压, 2022, 50(24):10.
- CAI CH ZH, BAI J X, CHI Y L, et al. Research on gearbox fault diagnosis based on CEEMDAN adaptive wavelet noise reduction and convolution neural network[J]. Machine Tool & Hydraulics, 2022, 50(24):10.
- [13] 李路云,王海瑞. 基于 GAF-Alexnet-ELM 的齿轮箱故障诊断方法[J]. 农业装备与车辆工程, 2023, 61(5):81-86.
- LI L Y, WANG H R. Fault diagnosis method of gearbox based on GAF-Alexnet-ELM[J]. Agricultural Equipment & Vehicle Engineering, 2023, 61(5): 81-86.
- [14] 刘晓悦,张泽明,赵立国,等. 基于 CEEMDAN 样本熵和 SSA-ELM 的风机齿轮箱故障诊断[J]. 组合机床与自动化加工技术, 2022(9):126-130.
- LIU X Y, ZHANG Z M, ZHAO L G, et al. Fault diagnosis of wind turbine gearbox based on CEEMDAN sample entropy and SSA-ELM [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(9):126-130.
- [15] 高素杰,巫世晶,周建华,等. 基于 LMD 排列熵和 BP 神经网络的行星齿轮箱故障诊断方法[J]. 机械传动, 2022, 46(10):10-16.
- GAO S J, WU SH J, ZHOU J H, et al. Fault diagnosis method of planetary gearboxes based on LMD permutation entropy and BP neural network[J]. Journal of Mechanical Transmission, 2022, 46(10): 10-16.

作者简介

王宽田,博士,高级信息系统项目管理师/高级实验师,主要研究方向为先进智能制造技术。

E-mail:411879705@qq.com

姚江云(通信作者),硕士研究生,副教授,主要研究方向为智能控制技术。

E-mail:469849257@qq.com