

基于多特征提取与灰狼算法优化 SVM 的车内异响识别方法

王若平¹ 陈 严¹ 王 东² 梁博洋² 曾发林¹

¹(江苏大学汽车与交通工程学院 江苏 镇江 212013)

²(中汽研(天津)汽车工程研究院有限公司 天津 300300)

摘要 传统的异响识别方法对测试设备要求较高且易受实验员经验差异影响。针对这种情况,提出一种基于多特征提取与灰狼算法优化支持向量机(Support Vector Machine, SVM)的车内异响识别方法。该方法以采集实验获得的6种车内常见异响作为研究对象,提取短时能量、小波变换优化的梅尔频率倒谱系数(DWT-MFCC)及其一阶差分组成混合特征参数,将灰狼优化算法应用于SVM的参数寻优中,建立异响识别模型并进行识别分类,同时探究选用不同维度的特征或不同算法对识别效果的影响。结果表明,所提取的25维混合特征能有效传达异响信息,该方法在收敛速度与识别准确率方面优势明显,能更好地实现车内异响的识别。

关键词 车内异响识别 短时能量 DWT-MFCC 灰狼优化算法 支持向量机

中图分类号 TP3 U467.3

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.03.007

VEHICLE INTERIOR ABNORMAL NOISE RECOGNITION BASED ON MUTI-FEATURE EXTRACTION AND SVM OPTIMIZED BY GRAY WOLF OPTIMIZATION

Wang Ruoping¹ Chen Yan¹ Wang Dong² Liang Boyang² Zeng Falin¹

¹(School of Automotive and Traffic Engineering, Jiangsu University, Zhenjiang 212013, Jiangsu, China)

²(CATARC(Tianjin)Automotive Engineering Research Institute Co., Ltd., Tianjin 300300, China)

Abstract The traditional method of abnormal noise recognition has high requirements for test equipment and can be easily affected by the experience difference of experimenters. In view of this, a method of vehicle interior abnormal noise recognition is proposed based on multi-feature extraction and SVM optimized by gray wolf optimization. This method took 6 kinds of common abnormal noises obtained in the test as the research object, and extracted short-term energy, Mel frequency cepstral coefficient optimized by wavelet transform (DWT-MFCC) and its first-order difference to form mixed characteristic parameters. Gray wolf optimization was applied to the parameter optimization of SVM to establish a noise recognition model and perform recognition classification. Result shows that the 25 dimensional mixed features extracted by this method can effectively convey abnormal noise information, and this method can better identify abnormal noise because of its obvious advantages in convergence speed and effect.

Keywords Abnormal noise recognition Short-term Energy DWT-MFCC Gray wolf optimization Support vector machine

0 引言

汽车异响作为汽车品质控制的一项重要指标,在汽车 NVH 开发中所受的重视程度越来越高。异响问题直接影响用户的驾乘舒适性,严重时会影响汽车零

部件使用寿命甚至车辆安全^[1]。异响识别是确定异响声源并进行故障诊断改进优化的重要前提。

目前针对车内零部件的异响问题,国内外尚无统一有效的检测手段,主要依靠实验人员主观评判及异响台架测试进行,效率不高且受经验差异影响。随着计算机技术的进步与人工智能的飞速发展,汽车故障

识别分析不断趋向智能化、现代化,为属于故障识别范畴的异响识别技术提供了新思路。现代故障识别技术在汽车发动机、电机、齿轮轴承等部件的诊断领域应用广泛,大多数故障识别方法都是基于振动或者电信号实现的。耿纪洲^[2]对几种典型故障状态下柴油发动机壳体的振动信号进行双谱分析,结合蚁群算法实现发动机典型故障的识别与诊断;Zaman等^[3]利用复 Morlet 小波的一维连续小波变换对异步电机定子电流的时频谱进行分析,电机转子断条故障的识别准确率达到 80%;李双丽等^[4]以滚动轴承为研究对象,采用单节点重构改进小波包能量与包络谱结合的方法,准确有效地提取并判别故障特征。基于振动信号或电信号的汽车故障识别方法主要通过人工选择或规定分析算法,对信号进行预处理与参数提取,寻找隐藏在信号中的故障特征,并通过人工判别或借助智能算法实现故障的分类。此类方法中振动信号或电信号的采集对实验设备的要求较高,成本高昂且效率较低。因此,近年来越来越多的学者侧重于对基于声信号的汽车故障识别方法进行研究,此种非接触条件下采集声音信号并实现智能化的故障识别方法,是声音识别技术在汽车故障诊断领域的创新应用。周宴宇等^[5]采用基于人耳听觉特性的梅尔频率倒谱系数(Mel Frequency Cepstrum Coefficient, MFCC)和线性预测倒谱系数(Linear Prediction Cepstrum Coefficient, LPCC)作为滚动轴承音频信号的特征参数,结合 BP 神经网络实现对轴承典型故障的分类;宋春雷^[6]将 MFCC 作为表征汽车故障声音信号的特征参数,采用 SVM 方法进行识别分类;Glowacz^[7]提出一种基于对数面积比系数与贝叶斯分类器的电动机故障声音信号诊断方法;杨兴国^[8]提取不同发动机故障声音的小波包能量谱和双谱峰值作为特征参数,利用 SVM 进行识别,可以较好地识别出故障的类型。目前基于声信号的汽车故障识别方法大多采用声音识别领域中常用的 MFCC 等声学特征参数,并结合 SVM 或 BP 神经网络等机器学习方法加以实现,相较基于振动信号或电信号的故障识别方法,该方法在故障特征参数的提取和识别模型的选择上有继承与创新,而且声音信号可采用麦克风传感器进行非接触式采集,与传统方法相比更加简单便捷。在目前的汽车故障识别领域,国内外学者对于声信号识别技术的研究仍然较少,尤其缺乏对车内常见零部件异响识别的系统性研究,在提高异响识别分类效率和准确度方面还有待探索。

本文拟提出一种基于多特征提取与灰狼算法优化

SVM 的方法,可快速高效地实现车内异响识别。通过仿真对选用不同维度的特征或不同算法的情况下模型的识别效果进行对比,同时对实验员主观判别异响种类的方法与提取不同特征下灰狼算法优化 SVM 的方法所获得的识别准确率进行对比分析,验证本文方法的可行性。

1 理论基础

1.1 多特征提取

1.1.1 预处理

声音信号的预处理是特征提取算法的基础,对信号进行适当的预处理可以增强特征提取的有效性^[9]。本文车内异响信号的预处理主要包括归一化、预加重、分帧加窗三个步骤。

(1) 归一化。对异响信号进行归一化的目的是减小不同样本之间差异化程度,有利于计算和分析声音信号的频率与特征参数分布^[10]。这里采用对原始数据进行线性变换的方法,使数据映射到 $[-1, 1]$ 幅值范围内。

(2) 预加重。预加重的目的在于有效弥补异响信号传播过程中的能量损耗,使信号的高频细节部分得到补充,便于频谱分析^[11]。预加重一般通过一阶数字滤波器来实现,其计算公式为:

$$H(z) = 1 - \mu z^{-1} \quad (1)$$

式中: $H(z)$ 为预加重传递函数; z 为频率; μ 为预加重常数系数,本文取 0.95。

(3) 分帧加窗。异响信号在宏观上是不平稳的,但是可以利用其短时平稳性(短时范围 10 ms ~ 30 ms),将异响信号分为若干等长的短帧进行研究。同时,需要对分帧过后的信号进行加窗处理,保证每帧信号两端的平滑过渡^[12]。为了避免信号间断,这里取帧长为 23 ms(1 024 采样点),帧移为 12 ms(512 采样点),选择窗函数类型为 hamming。

1.1.2 短时能量参数

短时能量描述的是能量随时间变化的信息,表示声音信号每一帧的能量大小,适用于本文声音采集环境背景噪声小的情况。通过短时能量的变化一定程度上反映了信号在时域上的幅度变化^[13]。其计算公式为:

$$E_i = \sum_n^{N-1} x_i^2(n) \quad (2)$$

式中: E_i 为第 i 帧异响信号 $x_i(n)$ 的短时能量; n 为一帧内的样本点, $n = 0, 1, \dots, N-1$; N 为帧长。

1.1.3 梅尔频率倒谱系数

梅尔频率倒谱系数(Mel Frequency Cepstrum Coefficient, MFCC)是一种能够充分反映人耳感知特性的参数^[14],是在 Mel 标度频率域提取出来的倒谱系数(Mel 频率与实际线性频率转化公式如式(3)所示)。该参数具备较好的抗噪性和鲁棒性,是声音识别领域中最常用的特征。

$$f_{\text{Mel}} = 2595 \lg\left(1 + \frac{f}{700}\right) \quad (3)$$

式中: f_{Mel} 为基于听觉感知的 Mel 频率; f 为实际线性频率,单位为 Hz。

1.1.4 小波变换改进的梅尔频率倒谱系数

小波变换具有多分辨率的特点,其基本思想是通过伸缩和平移的一组小波基函数,提供随频率变化改变的时频窗口,使信号时域和频域部分都具备表征局部特征的能力^[15]。MFCC 特征参数一般采用短时傅里叶变换对声音信号进行线性等间隔的频率划分,此方法适用于平稳信号的分析提取,而本文采集的异响信号属于典型的非平稳信号,故在此采用离散小波变换(Discrete Wavelet Transformation, DWT)代替原来的短时傅里叶方法,对原有的 MFCC 特征提取进行改进。

图1为小波变换改进的梅尔频率倒谱系数(DWT-MFCC)特征提取框图,其具体实现过程如下:首先,对采集的异响信号进行预处理,包括归一化、预加重、分帧加窗;接着,采用 DWT 对预处理后的异响信号进行处理,选择合适的小波基和分解层数对其分解,得到分属于不同频段的小波系数;然后,采用分层 FFT 方法,根据系数所属频段求取每层小波系数的频谱并拼接完整;最后,求取拼接好频谱的能量,通过梅尔滤波器组,取对数能量后再经过离散余弦变换,便可得到相应的 DWT-MFCC 特征参数。

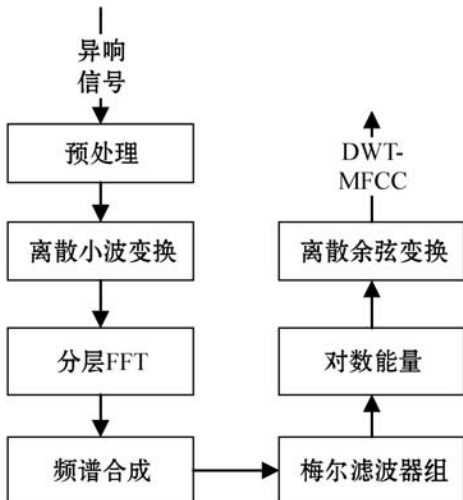


图1 DWT-MFCC 特征提取框图

1.2 灰狼优化算法

灰狼优化(Gray Wolf Optimization, GWO)是一种模拟灰狼家族的社会等级制度和群体捕食行为的群体智能优化算法,该算法最早由 Mirjalili 等^[16]于2014年提出,用于解决连续空间的问题。相比于其他优化算法,GWO 的结构更为简单、收敛速度更快、全局搜索能力更强、更容易实现最优分类^[17]。

GWO 借鉴灰狼家族内部严格的社会等级制度,按社会地位由高到低依次被分为 α 、 β 、 δ 和 ω 四种灰狼等级, α 、 β 、 δ 占主导地位,而 ω 附庸于前三个群体^[18]。在对解进行优化寻优的过程中, α 、 β 、 δ 分别代表当前迭代的最优解、次优解、次次优解。灰狼群体捕食过程一般分为包围猎物、捕猎和攻击猎物。GWO 实现的具体步骤如下:

(1) 灰狼包围猎物:狼群中狼都向 α 狼靠近,当发现猎物时,通过嚎叫通知其他狼,在 α 狼的组织下包围猎物。该数学模型为:

$$\begin{cases} \mathbf{X}(t+1) = \mathbf{X}_p(t) - \mathbf{A} \times \mathbf{D} \\ \mathbf{D} = |\mathbf{C} \times \mathbf{X}_p(t) - \mathbf{X}(t)| \end{cases} \quad (4)$$

式中: \mathbf{X} 为灰狼所在的位置; t 表示当前迭代次数; \mathbf{X}_p 为猎物所在的位置; \mathbf{D} 依赖于猎物的位置, \mathbf{A} 、 \mathbf{C} 是参数向量。其中, \mathbf{A} 、 \mathbf{C} 的计算公式如下:

$$\begin{cases} \mathbf{A} = 2a \times \mathbf{r}_1 - a \\ \mathbf{C} = 2 \times \mathbf{r}_2 \end{cases} \quad (5)$$

式中: \mathbf{r}_1 、 \mathbf{r}_2 为 $[0, 1]$ 的随机变量; a 为收敛因子。随着迭代次数的增加从 2 线性减少到 0, a 表达式如下:

$$a = 2 - 2t/t_{\max} \quad (6)$$

式中: t_{\max} 表示最大迭代次数。

(2) 灰狼捕猎过程:在实际求解中,全局最优 \mathbf{X}_p 一般是未知的。一般以 α 、 β 、 δ 狼指导种群更新位置,因为它们是当前种群的三个最优解,更接近全局最优。数学模型为:

$$\begin{cases} \mathbf{X}_1 = \mathbf{X}_\alpha - \mathbf{A}_1 \times \mathbf{D}_\alpha \\ \mathbf{X}_2 = \mathbf{X}_\beta - \mathbf{A}_2 \times \mathbf{D}_\beta \\ \mathbf{X}_3 = \mathbf{X}_\delta - \mathbf{A}_3 \times \mathbf{D}_\delta \\ \mathbf{D}_\alpha = |\mathbf{C}_1 \times \mathbf{X}_\alpha - \mathbf{X}| \\ \mathbf{D}_\beta = |\mathbf{C}_2 \times \mathbf{X}_\beta - \mathbf{X}| \\ \mathbf{D}_\delta = |\mathbf{C}_3 \times \mathbf{X}_\delta - \mathbf{X}| \end{cases} \quad (7)$$

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (9)$$

式中: \mathbf{X}_1 、 \mathbf{X}_2 、 \mathbf{X}_3 为种群中 ω 狼在 α 、 β 、 δ 狼引导下学习后的位置; $\mathbf{X}(t+1)$ 为最终种群中的狼更新后的当前位置。

(3) 灰狼攻击猎物:即结束算法获得最优解的过程。攻击行为主要通过公式中的 a 值随迭代次数的增加由 2 线性递减至 0 来完成。若 $|A| \leq 1$, 则灰狼对猎物集中攻击, 即获得最优解, 对应局部搜索; 若 $|A| > 1$, 则灰狼散去, 即继续寻找最优解, 进行全局搜索。

1.3 基于灰狼优化算法的 SVM 参数优化方法

支持向量机(SVM)是一种基于结构风险最小化有监督的统计学习方法, 适用于解决本文研究对象类似的小样本、非线性问题, 具备良好的泛化能力^[19]。由于优越的分类能力, 该方法在图像分类识别、文本识别、故障诊断等领域广泛应用。

SVM 核函数的研究一般包括核函数类型选择与参数选择。大量研究表明, 核函数类型和参数会影响 SVM 的识别分类性能, 主要包括学习能力与泛化能力。在分类方面常用的核函数包括线性核函数、多项式核函数、径向基核函数和 Sigmoid 核函数四种^[20]。在利用 SVM 进行识别的过程中, 其惩罚系数和核参数一般情况下是基于经验选取的。目前遗传算法^[21]、粒子群算法^[22]、灰狼算法、蚁群算法^[23]等智能算法已经和 SVM 结合在一起, 应用到 SVM 的参数寻优上。

本文引入 GWO 来进行 SVM 的参数优化, 优化流程如图 2 所示。

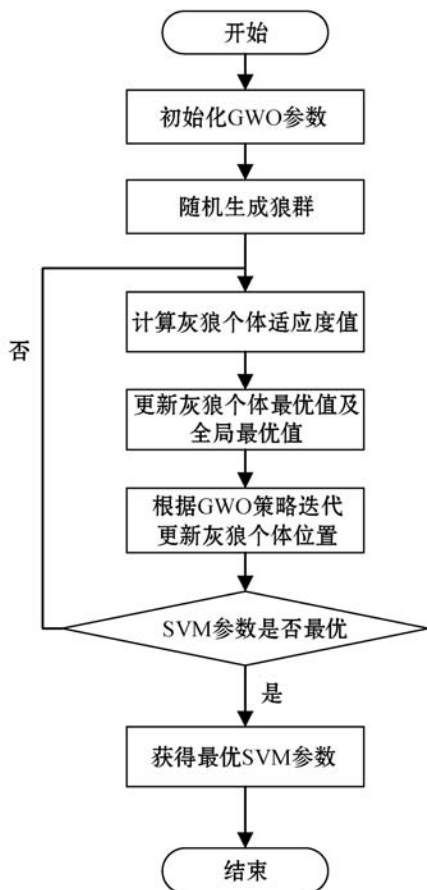


图2 GWO 优化 SVM 参数流程

2 车内异响信号采集实验

本文实验主要针对车内零部件的异响问题, 具体采集对象包括仪表板空调格栅异响、仪表板手套箱卡扣异响、安全带卷收器异响、座椅导轨碰撞异响、座椅表皮摩擦异响、车窗玻璃共振异响这 6 种异响。为了降低背景噪声对分析结果的影响, 整个实验在某汽车技术中心零部件异响半消声室中进行。采集实验时所用到的仪表板、安全带、座椅、车门零部件均是开发部存在异响问题的样件, 四种问题样件选用 8~20 个不等, 保证异响样本多样性的同时, 也使得所构建的异响数据库更具代表性。

零部件异响半消声室中, 四种问题样件的异响采集布置环境如图 3 所示。通过对零部件 BSR 实验台架输入路谱振动, 模拟零部件在实际路面行驶时的振动情况, 激起样件异响信号, 并使用 LMS SCADAS Mobile 32 通道数据采集前端和 G. R. A. S 声传感器进行信号的采集。将所有采集得到的异响信号分成 2 s 等长的声音段(均为 .wav 的文件格式)并编号保存, 存入异响数据库进行后续仿真分析。本次实验数据采集软件为 LMS Test. Lab 18A, 信号采样频率设置为 44 100 Hz, 测点选择近场采集, 声传感器位置为垂直于样件问题点 15~20 cm 处, 测试前声传感器采用 1 000 Hz、94 dB 的纯音标定。





图3 四种问题样件的异响采集实验布置环境


3 异响信号特征参数的提取

短时能量能较好地体现异响信号的时域信息, 如图 4 所示(以仪表盘手套箱卡扣异响为例), 由一帧信号求出的短时能量是一个标量值, 与其他特征结合不

会使原有特征矢量的维数明显增加,运算复杂度小。对于非平稳的异响信号来说,仅靠单纯的时域分析有时很难真正反映信号真实的特征。MFCC 是人耳听觉感知特征,属于声音的频域特征,两类特征参数相关性不大,将它们混合构成多维特征矢量,将会有效提升识别效果。同时,引入一阶差分倒谱系数 Δ MFCC 可以一定程度上描述异响信号帧间瞬时变化的动态特性,弥补了标准 MFCC 只反映参数的静态特性而忽略相邻帧间联系的缺陷^[24]。



(a) 仪表盘手套箱卡扣异响波形



(b) 仪表盘手套箱卡扣异响短时能量

图 4 仪表盘手套箱卡扣异响信号

本文提取时域内的短时能量参数和频域内的 DWT-MFCC、DWT- Δ MFCC 作为车内异响识别中所需的混合特征参数。其中,小波基函数选择 sym4,分解层数设置为 8;采用 24 阶三角滤波器,计算出 24 维特征参数,考虑到在实际的工程应用中,最前若干维的 MFCC 对声音的识别性能更好^[25],这里取前 12 维作为 DWT-MFCC 特征,其一阶差分系数作为 13 到 24 维特征,将每一帧异响信号的短时能量作为第 25 维特征,混合特征矢量共 25 维。图 5 为提取出的 6 种异响信号某一帧的 DWT-MFCC 及其一阶差分参数值。




图 5 不同异响信号 DWT-MFCC 及其一阶差分参数值

4 基于灰狼算法优化 SVM 的方法在车内异响识别的应用

4.1 基于灰狼算法优化 SVM 的车内异响识别

如前所述,在车内异响的识别过程中,主要包括异响信号的预处理、特征参数的提取与识别模型的建立及匹配。其中,SVM 模型的输入是车内异响训练样本特征参数与 GWO 初始化参数,输出是已训练好的具备最优 SVM 参数的异响识别模型。将所有测试样本特征参数输入该模型进行匹配识别,最终得到异响识别分类结果。图 6 是基于灰狼算法优化 SVM 的车内异响识别完整流程。

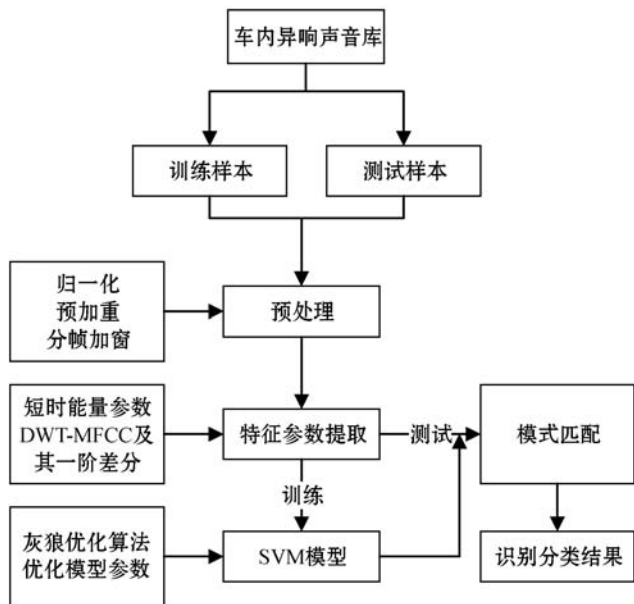


图 6 基于灰狼算法优化 SVM 的车内异响识别完整流程

4.2 仿真实验结果与分析

仿真软硬件环境:所有仿真运行在 PC 机的 Windows 10 操作平台上,处理器为 Intel Core i7-8750H(2.20 GHz),内存为 8 GB,编程主要使用软件是 MATLAB 2018b。

仿真数据:6 种异响样本由上述实验采集获得,每种异响有 200 个样本,总样本数为 1 200,将数据集按 8:2 的比例分为训练集与测试集,即随机选择每类异响中 160 个样本用于模型的训练,剩余的 40 个样本用于后续的测试,总的训练集为 960 个,总的测试集为 240 个。

根据多次测试与实际经验,SVM 核函数类型选用径向基核函数,使用“一对一”多分类和 5 次交叉验证方法进行仿真实验。考虑到每类异响训练样本均衡,将仿真获得的所有测试异响数据的识别准确率(正确分类的样本数与总样本数的比值)作为评价标准。

4.2.1 不同特征维度下识别效果的对比

为了探究不同特征维度对识别效果的影响,计算所得的 24 维特征参数取前 8 维、12 维、16 维、20 维、24 维 DWT-MFCC 特征进行对比实验。将提取的 DWT-MFCC 结合其一阶差分系数和短时能量参数构成混合特征,分别输入本文的 SVM 模型进行识别分类。图 7 给出了四种特征维度下异响识别准确率和程序运行时间。

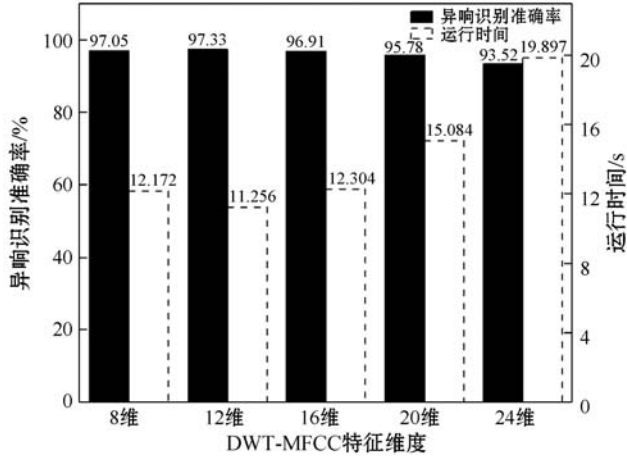


图7 四种特征维度下识别效果的对比

由图7可知,取前12维作为DWT-MFCC特征的情况下,的确可以提高异响识别准确率,平均识别准确率提高约1.21%。特征维度对程序运行时间有显著影响,当取前12维作为DWT-MFCC特征时,程序的运行时间最短,计算复杂度最低,此后随着特征参数维度的增加,程序的运行时间不断变长,且增速越来越快。如果将原始计算出的24维特征直接作为DWT-MFCC特征,并计算其一阶差分与短时能量参数混合输入给模型进行识别分类,异响识别准确率最低,且计算复杂度最高。总的来说,取前12维作为DWT-MFCC特征参数时,识别效果最佳。

4.2.2 不同算法下识别效果的对比

为了验证本文提出的基于灰狼算法优化SVM方法的识别分类效果,分别采用PSO、GA、GWO三种智能优化算法对SVM进行参数寻优,将表征车内异响信号的混合特征向量输入SVM模型进行训练与测试。同时引入传统的声学识别模型HMM、GMM进行对比实验。为了确保公平性,种群规模都设置为20,最大允许迭代次数为200,径向基核函数惩罚参数取值范围设定在 $[0,100]$,核参数设定在 $[0,1]$,PSO的粒子位置与速度更新参数都设为2。

为了优化模型参数寻优效果,防止预测的分类结果出现过拟合现象,这里采用综合适应度值 F 作为最终适应度值,其计算公式为:

$$F = f_{\text{train}} \times 40\% + f_{\text{test}} \times 60\% \quad (10)$$

式中: f_{train} 、 f_{test} 分别为利用训练数据和测试数据进行仿真实验计算所得的适应度值。 F 的取值是训练数据和测试数据预测结果的综合,分配占比为4:6。

采用不同的算法进行仿真获得的识别分类结果如表1所示,传统的声学模型HMM、GMM对六种异响的识别效果不佳,识别准确率和 F 值都不足90%。同时,相对于未优化的SVM,基于GWO-SVM、PSO-SVM、GA-SVM算法得到的异响识别效果都有明显的提升,其中,基于GA-SVM算法获得的识别准确率和 F 值都是最低的,基于GWO-SVM与PSO-SVM算法得到的识别效果相当,识别准确率和 F 值达到了97%以上。

表1 不同算法下识别分类结果

算法	异响识别准确率/%	F 值/%	最优参数/ (c, g)
SVM	90.20	92.05	—
GWO-SVM	97.33	98.82	(40.903, 0.018)
PSO-SVM	97.12	98.75	(28.021, 0.060)
GA-SVM	94.06	95.26	(35.635, 0.327)
HMM	87.09	88.13	—
GMM	88.50	89.64	—

图8和表2给出了不同优化算法进行SVM参数寻优过程中5次交叉验证获得的适应度值 F 的变化曲线与参数寻优的耗时结果,由此看出,GWO-SVM算法在第75次左右迭代就趋于收敛至最优解,参数寻优只用了11.256s,而PSO-SVM算法此时仍未收敛,直至第110次左右迭代才趋于最大适应度值,寻优耗时比GWO-SVM慢了5.253s。GA-SVM算法获得的异响识别准确率和 F 值低于前两种算法,寻找最优参数的时间也是最长的,第130次左右迭代才得到最优。

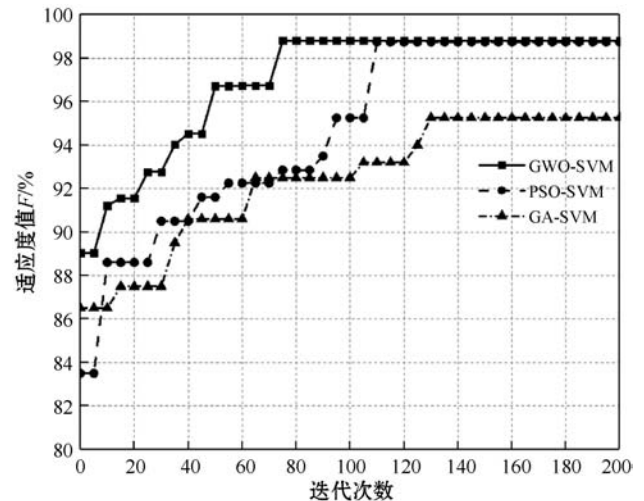


图8 不同优化算法进行SVM参数寻优适应度值 F 变化曲线

表2 不同优化算法 SVM 参数寻优耗时结果

算法	GWO-SVM	PSO-SVM	GA-SVM
寻优耗时/s	11.256	16.509	19.511

综上所述,在对车内异响的识别过程中,使用灰狼算法优化 SVM 的方法具有优势,不仅参数寻优耗时短,收敛速度快,而且很大程度上提高了识别准确率。

4.2.3 基于实验员主观判别法与不同特征下灰狼算法优化 SVM 方法的识别准确率对比

为了进一步验证本文方法的可行性,将工程实践中由实验员主观判别异响种类的方法与运用灰狼算法优化 SVM 的方法进行对比实验。

本次测试数据来自于异响样本库中待测信号,每类异响均衡选取 20 个测试样本,共 120 个样本。方法 1:邀请三位从事异响相关工作的实验人员,在声品质实验室中现场听音,根据自己的经验主观判别随机发

出的 120 个异响样本类型;方法 2:提取测试样本的不同特征向量,并调用灰狼算法优化的 SVM 模型进行识别。两种方法最终得到的识别结果如表 3 和表 4 所示。

表3 基于实验员主观判别法的识别结果(%)

异响样本	异响识别准确率		
	实验员 A	实验员 B	实验员 C
仪表盘空调格栅	45.0	45.0	40.0
仪表板手套箱卡扣	30.0	35.0	40.0
安全带卷收器	45.0	50.0	55.0
座椅导轨	80.0	75.0	75.0
座椅表皮	75.0	85.0	80.0
车窗玻璃	70.0	80.0	70.0
平均识别率	57.50	61.67	60.0

表4 基于不同特征参数下灰狼算法优化的 SVM 方法的识别结果(%)

异响样本	异响识别准确率				
	短时能量	MFCC (12 维)	DWT-MFCC (12 维)	DWT-MFCC 及其一阶差分(24 维)	本文混合特征参数(25 维)
仪表盘空调格栅	80.33	90.81	93.00	94.81	96.52
仪表板手套箱卡扣	81.15	91.12	93.75	95.06	97.50
安全带卷收器	79.36	91.33	94.50	95.74	97.35
座椅导轨	82.58	92.00	93.02	94.33	96.80
座椅表皮	80.06	90.70	92.98	93.56	96.00
车窗玻璃	83.72	93.35	95.02	96.00	98.26
平均识别率	81.20	91.55	93.71	94.92	97.07

由表 3 可知,传统的主观评价方法受实验员个人经验影响很大,识别结果不理想。三位实验员对于六类异响的平均识别率只有 60% 左右,识别准确率波动也大,对于座椅类与车门类异响,整体判别情况要远好于仪表板类和安全带类的异响判别。由表 4 可知,基于灰狼算法优化 SVM 的方法,提取不同时频域特征矢量进行仿真,各类异响样本上的平均识别率都可以达到 80% 以上。从不同种类的异响样本结果来看,车窗玻璃共振异响识别准确率好于其他异响的识别准确率;从提取不同的特征参数结果来看,单一的时域特征短时能量很难全面反映异响信号的特点,提取贴切人耳感知的 MFCC 特征可明显提升识别效果,平均识别率提高 10% 左右,通过采用 DWT 取代 DCT、增加 Δ MFCC 特征对标准的 MFCC 进行改进,弥补了一部分原先的不足,识别准确率都有稳步提高。此外,利用本文中的混合特征参数进行测试,六类异响的平均识别

率最高,达到了 97.07%,说明时频域特征的混合增加特征维度的同时,提升了模型的识别性能。

综合表 3 和表 4 对比可知,本文基于灰狼算法优化 SVM 的方法明显优于实验员主观评价方法,此方法减小了个人经验差异对于识别结果的影响,可以有效提升识别分类性能。

5 结 语

本文提出一种基于多特征提取与灰狼算法优化 SVM 的车内异响识别方法,选择短时能量与 MFCC 这两个分别在时域和频域应用广泛的特征参数,利用小波变换对标准 MFCC 进行优化,同时将 GWO 引入到 SVM 模型的参数选取上。结果表明,取前 12 维特征参数作为 DWT-MFCC 特征,并结合其一阶差分和短时能量参数构成的 25 维混合特征参数,能有效传达异响

的特征信息,输入模型获得的识别效果最佳;相较于其他算法,GWO 优化 SVM 的方法优势明显,应用此方法不仅参数寻优耗时最短,而且得到的异响识别准确率最高,能有效提高建模效率与识别性能;与传统的实验员主观判别异响种类的方法相比,本文方法判断异响种类更为准确高效,使异响的自动识别成为可能,为后续汽车异响故障诊断工作打下了基础,也为相关异响测试产品的开发提供了一种新的解决方案。

参 考 文 献

- [1] 高强,杨伟林. 浅谈汽车异响的危害及预防[J]. 内燃机与配件,2020(21):152-153.
- [2] 耿纪洲. 军用车辆发动机机械故障诊断方法的研究[D]. 青岛:中国石油大学,2014.
- [3] Zaman S M, Marma H, Liang X D. Broken rotor bar fault diagnosis for induction motors using power spectral density and complex continuous wavelet transform methods [C]// IEEE Canadian Conference of Electrical and Computer Engineering,2019:1-4.
- [4] 李双丽,刘增力. 基于单节点重构改进小波包能量与包络谱的滚动轴承故障特征提取[J]. 计算机应用与软件,2018,35(7):216-220,236.
- [5] 周宴宇,杨胜跃,何正明,等. 基于 MFCC 与 LPCC 的滚动轴承故障音频诊断法[J]. 微计算机信息,2009,25(31):123-124.
- [6] 宋春雷. 基于音频信号的汽车状态与故障分析[D]. 沈阳:沈阳理工大学,2013.
- [7] Glowacz A. Diagnostics of DC and induction motors based on the analysis of acoustic signals [J]. Measurement Science Review,2014,14(5):257-262.
- [8] 杨兴国. 发动机异响的特征提取与模式识别[D]. 重庆:重庆大学,2017.
- [9] Tsalera E, Papadakis A, Samarakou M. Monitoring, profiling and classification of urban environmental noise using sound characteristics and the KNN algorithm [J]. Energy Reports,2020,6:223-230.
- [10] 李靓,孙存威,谢凯,等. 基于深度学习的小样本声纹识别方法[J]. 计算机工程,2019,45(3):262-267,272.
- [11] Revathi A, Ravichandran C, Saisiddharth P, et al. Isolated command recognition using MFCC and clustering algorithm [J]. SN Computer Science,2020,1(2):127-132.
- [12] 孙国强,樊新海,石文雷. 基于 MFCC 和支持向量机的装甲车辆识别研究[J]. 国外电子测量技术,2017,36(10):31-35.
- [13] Xie J, Zhu M Y. Investigation of acoustic and visual features for acoustic scene classification [J]. Expert Systems with Applications,2019,126:20-29.
- [14] Sharma A, Kaul S. Two-stage supervised learning-based method to detect screams and cries in urban environments [J]. IEEE/ACM Transactions on Audio, Speech and Language Processing,2016,24(2):290-299.
- [15] 王雨青. 地震信号分数域属性分析及储层流体识别关键技术研究[D]. 成都:电子科技大学,2018.
- [16] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software,2014,69:46-61.
- [17] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用,2020,56(22):1-12.
- [18] Ozsoydan F B. Effects of dominant wolves in grey wolf optimization algorithm [J]. Applied Soft Computing,2019,83:105658.
- [19] Cervantes J, Garcia-Lamont F, Rodriguez-Mazahua L, et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends [J]. Neurocomputing,2020,408:189-215.
- [20] 刘一然,骆力明. 基于 SVM 的学科试题自动分类研究 [J]. 计算机应用与软件,2019,36(1):197-203.
- [21] 徐胜舟,裴承丹. 基于遗传算法和支持向量机的乳腺肿块识别[J]. 计算机仿真,2015,32(2):432-435,440.
- [22] Eid H F, Abraham A. Plant species identification using leaf biometrics and swarm optimization: A hybrid PSO, GWO, SVM model [J]. International Journal of Hybrid Intelligent Systems,2018,14(3):155-165.
- [23] Sathiyaraj T, Sathiyabhama B. Fuzzy relevance vector machine based classification of lung nodules in computed tomography images [J]. International Journal of Imaging Systems and Technology,2019,29(3):360-373.
- [24] 李虹,徐小力,吴国新,等. 基于 MFCC 的语音情感特征提取研究[J]. 电子测量与仪器学报,2017(3):448-453.
- [25] 张军委. 基于音频融合特征的设备异常识别研究[D]. 济南:山东大学,2019.

(上接第 21 页)

- [17] Wong S, Gatt A, Stamatescu V, et al. Understanding data augmentation for classification: When to warp? [C]//2016 International Conference on Digital Image Computing: Techniques and Applications,2016:1-6.
- [18] Olston C, Fiedel N, Gorovoy K, et al. TensorFlow-Serving: Flexible high-performance ML serving [EB]. arXiv:1712.06139,2017.
- [19] The Mnist Database of handwritten digits [EB/OL]. [2020-11-19]. <http://yann.lecun.com/exdb/mnist>.
- [20] Ren S, He K, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2015,39(6):1137-1149.