

基于 EEMD—Treelet 和高斯过程的 起重机齿轮故障诊断

李 勇¹, 钱尼君¹, 陈星斌¹, 黄荔生¹, 彭献永^{2,3}

(1. 江西省特种设备检验检测研究院, 南昌 330029; 2. 腾羿数据(上海)科技有限公司, 上海 200240;
3. 上海交通大学 电子信息与电气工程学院, 上海 200240)

摘要: 齿轮故障诊断对于起重机安全运行至关重要; 提出了一种基于集成经验模态分解(ensemble empirical mode decomposition, EEMD)—Treelet 变换和高斯过程(gaussian process, GP)的起重机齿轮振动故障诊断新方法; 设计一种细菌觅食算法(bacterial foraging optimization, BFO)优化高斯过程模型超参数; 建立基于集成经验模态分解—希尔伯特变换的齿轮振动参数信号特征提取方法, 利用 Treelet 变换实现这些特征的降维学习; 建立基于细菌觅食算法优化高斯过程的齿轮故障模型; 实验结果表明, EEMD—Treelet—GP 诊断方法不仅可以识别最佳特征向量, 而且可以识别故障位置。

关键词: 集成经验模态分解; 希尔伯特变换; Treelet 变换; 高斯过程; 故障诊断

Fault Diagnosis of Crane Gear Using EEMD—Treelet and Gaussian Process

LI Yong¹, QIAN Nijun¹, CHEN Xingbin¹, HUANG Lisheng¹, PENG Xianyong^{2,3}

(1. Jiangxi Special Equipment Inspection and Testing Institute, Nanchang 330029, China;

2. Tengyi Data (Shanghai) Technology Co., Ltd., Shanghai 200240, China;

3. School of Electronic Information and Electrical Engineering, Shanghai Jiaotong University, Shanghai 200240, China)

Abstract: Gear fault diagnosis is essential to the safe operation of cranes. A new vibration fault diagnosis method of crane gear based on ensemble empirical mode decomposition (EEMD), Treelet transform, and Gaussian Process (GP) was proposed in this work. A Bacterial foraging optimization (BFO) algorithm is proposed to optimize the hyper parameters of the GP model. A gear vibration parameter signal feature extraction method is developed based on ensemble empirical mode decomposition and Hilbert transform. Treelet transform is used to reduce their feature dimensionality. Finally, the fault location of the gear is identified by the BFO—GP model. Experimental results show that the EEMD—Treelet—GP diagnosis method can not only identify the best feature vector, but also identify the fault location.

Keywords: EEMD; HHT; Treelet; BFO—GP; fault diagnosis

0 引言

齿轮传动系统的主要机械振动通常归因于齿轮故障, 包括磨损/折断的齿或不平衡的齿轮, 并可能导致系统故障。众所周知, 对于不同的故障类型, 其影响将以不同的频率出现。准确而自动地评估其性能下降有两个重要方面: 特征提取和故障分类器。Randall^[1]提供了有关齿轮诊断技术的综述。目前, 循环平稳性分析方法来诊断旋转机械中的齿轮已经被广泛采用。振动信号的频谱分析也已经用以检测齿轮中的剥落。

通常, 在机器故障的情况下, 测得的振动信号可能会出现不平稳的现象。因此, 时频分析方法, 如小波变换方法和希尔伯特—黄氏变换(HHT)被用来观察信号时变特

性。Saravanan 等^[3]使用 Morlet 小波提取齿轮箱的故障特征作为 SVM 模型输入。Wu and Chan^[4]通过小波变换和人工神经网络开发了齿轮故障识别模型。Peter 等^[5]利用小波分析和包络线检测进行轴承故障诊断。Peng 等^[6]比较了改进的希尔伯特—黄变换和小波变换在滚动轴承故障诊断中的性能差异。Lei 和 Zuo^[7]用 EEMD 产生敏感的本征模态函数(intrinsic mode function, IMF), 用于旋转机械的故障诊断。Fan 和 Zuo^[8]利用本征模态函数提取机器故障特征。Yu 等^[9]用希尔伯特—黄变换的时频熵方法进行齿轮故障诊断。Yang 和 Wu^[10]用 EEMD 方法和 PCA 来诊断齿轮性能退化。

机器的故障信号通常显示出很高的复杂性, 许多研究人员利用机器学习来识别机械运行状态故障。Samanta 和 Al-Balushi^[11]提出了一种人工神经网络, 使用时域特征对

收稿日期: 2020-11-25; 修回日期: 2021-01-06。

基金项目: 国家自然科学基金(61671293); 上海浦江计划人才(15PJ1404300)。

作者简介: 李 勇(1964-), 男, 江西南昌人, 高级工程师, 主要从事特种装备检测方向的研究。

通讯作者: 钱尼君(1993-), 男, 安徽青阳人, 硕士, 工程师, 主要从事装备故障诊断方向的研究。

引用格式: 李 勇, 钱尼君, 陈星斌, 等. 基于 EEMD—Treelet 和高斯过程的起重机齿轮故障诊断[J]. 计算机测量与控制, 2021, 29(7):

36-40, 51.

滚动轴承进行故障诊断。Wang 等^[12]使用时间序列分析和神经网络进行旋转机械故障诊断。Shafei 等^[13]将神经网络和模糊逻辑应用于齿轮的故障诊断。除了人工神经网络, 支持向量机 (SVM, support vector machine)^[2] 和决策树方法^[14] 也被用于不同的故障类型。Bordoloi 和 Tiwari^[17] 用 SVM 对齿轮频域数据进行多故障分类。他们通过在 4 个不同的故障条件下检查 SVM 模型的多类能力的性能。Rajeswari 等^[18] 提出了一种基于遗传算法和反向传播神经网络的齿轮不同状态诊断混合框架。Sugumaran 和 Ramachandran^[19] 使用齿轮振动信号的时域统计和直方图特征, 作为 SVM 分类器输入, 找到了最佳故障特征。Zhang Ying 等^[2] 提出了基于多种特征的故障诊断方法, 他们用核主成分分析和粒子群优化支持向量机 (来定位轴承故障)。

高斯过程 (GP) 是一种基于核的非线性学习方法, 可以处理带有噪声观测值和系统不确定性的建模问题^[20]。它已经被广泛的应用于动作识别等。它具有严格的统计理论基础和很好的适应复杂问题的能力。与 ANN 和 SVM 相比, 它既保持良好性能又具有灵活的非参数推理能力的条件。在 GP 模型中, 关键问题是估计一组适当的超参数, 该参数会使边缘似然函数最小化。为了提高 GP 模型参数寻优的准确性^[15], 用一种细菌觅食优化 (BFO) 算法^[16] 来优化 GP 模型的超参数。

为了提高起重机齿轮传动系统故障识别性能, 提出一种基于 EEMD-Treellet 的自动特征选择方法, 用于诊断齿轮故障。首先, 采用 EEMD 方法来提取通常隐藏在振动信号中的与故障相关的特征。然后, 通过 Treellet 变换对原始特征进行降维, 降维后的特征可以表示齿轮的主要故障特征。所得的特征向量作为 BFO-GP 模型输入, 自动识别齿轮故障。

1 特征提取与降维

1.1 边际谱

EEMD 方法^[3] 的本征模式函数是单振荡成分。因此, IMF 瞬时频率计算是可行的。这是建立时频分布的必要和关键步骤。为了建立信号的时频分布, 第 k 个 IMF 可以用其包络和载波部分表示为:

$$c_k(\omega, t) = A_k(t) \cos\left(\int \omega_k(t) dt\right) \quad (1)$$

其中: 包络线 $A_k(t)$ 表示随时间变化的幅度项, 可以通过复杂的三次样条拟合计算得出, 而被测信号 $x(t)$ 的时频分布 $H(\omega, t)$ 可以表示为:

$$H(\omega, t) = \sum_{k=1}^m A_k(t) \cos\left(\int \omega_k(t) dt\right) \quad (2)$$

此外, 边缘频谱 $S(\omega)$ 可以通过积分沿时间轴的时频分布表示如下:

$$S(\omega) = \sum_{\Omega} \int_0^T H_k(\omega, t) dt \quad (3)$$

其中: $H_k(\omega, t)$ 表示第 k 个 IMF 的时频分布, T 表示信号长度, Ω 表示所选 IMF 的索引集。

1.2 Treelets 降维

Treelets 降维算法是一个自适应的降维算法, 它在数据每层结构上将两列最相似的数据用一组逼近信号与一组细节信号来代替, 采用 PCA 方法进行对这两列数据进行分析^[21]。

Treelets 算法的结构可以表示为一个树结构。图 1 即为一个 5 层的树结构信号: 部分 (主成分结构) 代表的为逼近信号, (次成分信号) 代表与主成分正交的细节信号。

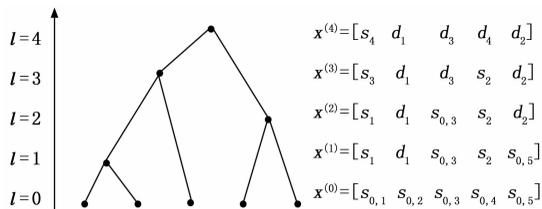


图 1 五层 Treelets 结构

2 BFO-GP 分类器

2.1 GP 分类器

一个高斯过程可以通过其均值函数 $m(x)$ 和它的协方差 $k(x, x')$ 确定。它的超参数最佳估计可以在对数边缘似然函数最大情况下获取。也就是说, 可以通过对目标函数进行边缘化, 获得高斯过程超参数的概率, 使用共轭梯度方法优化超参数。高斯过程的对数边缘似然函数定义为:

$$\begin{aligned} \log p(y | x, \Theta) = \\ - \frac{1}{2} \log |K| - \frac{1}{2} (y - \mu)^T K^{-1} (y - \mu) - \frac{n}{2} \log(2\pi) \end{aligned} \quad (4)$$

超参数的选择对于高斯过程分类器的整体分类性能至关重要。它的超参数 $\{\mu, \sigma, l_1, l_2, \dots, l_d\}$ 可以在很大的值范围内变化。通常的共轭梯度优化方法的性能或准确性取决于初始数值的选择, 并且相对于小扰动和局部最优而言可能不稳定。由于选择超参数会极大地影响高斯过程模型的泛化性能, 因此进化算法可能是一个可好的选择。在这个工作中, 细菌觅食优化算法被用作高斯过程超参数优化算法。细菌觅食优化算法的适应度函数采用式 (7) 中定义的对数边缘似然函数。

2.2 细菌觅食算法

BFO 是一种自然启发式优化算法^[16], 它能够找目标函数的最小值, 并且不需要计算目标函数的梯度。BFO 模仿了在实际细菌系统中观察到的 4 个主要机制: 趋化性, 群聚, 繁殖和迁徙, 以解决非梯度优化问题。

1) 趋向性操作:

大肠杆菌在整个觅食过程中有两个基本运动: 旋转和游动。旋转是为找一个新的方向而转动, 而游动是指保持方向不变的向前运动。BFO 算法的趋向性操作就是对这两种基本动作的模拟。通常, 细菌会在食物丰盛或环境的酸性碱性适中的区域中较多地游动, 而在食物缺乏或环境的酸性碱性偏高的区域则会较多地旋转, 即原地不动。

假设要找到目标函数 $J(\theta)$ 的最小值, 其中 $\theta \in R^p$ (即 θ 是实数 p 维向量), 并且没有测量值或梯度 $\nabla J(\theta)$ 的数学解析描述。假设 $\theta^i(j, k, l)$ 代表第 j 个趋化性的第 i 个细菌, 第 k 个繁殖和第 l 个消除—扩散事件。 $C(i)$ 表示在翻滚指定的随机方向上执行的步长。在计算趋化性中, 细菌的运动可以表示为:

$$\theta^i(j+1, k, l) = \theta^i(j, k, l) + C(i) \frac{\Delta(i)}{\sqrt{\Delta^T(i)\Delta(i)}} \quad (5)$$

其中: Δ 表示随机方向上的向量, 其元素位于 $[-1, 1]$ 。

2) 群聚性操作: 设目标函数的变化量如下:

$$J_c C(\theta, P(j, k, l)) = \sum_{i=1}^S J_c C(\theta, \theta^i(j, k, l)) = \sum_{i=1}^S [-d_{\text{attrac}} \exp(-w_{\text{attrac}} \sum_{m=1}^p (\theta_m - \theta_m^i)^2)] + \sum_{i=1}^S [h_{\text{repeal}} \exp(-w_{\text{repeal}} \sum_{m=1}^p (\theta_m - \theta_m^i)^2)] \quad (6)$$

其中: $J_c C(\theta, P(j, k, l))$ 表示目标函数 $J(\theta)$ 的目时变值, S 是细菌总数, p 是每个细菌中要优化的变量数量。 $\theta = [\theta_1, \theta_2, \dots, \theta_p]^T$ 是 p 维搜索域中的一个点。 $d_{\text{attrac}}, w_{\text{attrac}}, h_{\text{repeal}}, w_{\text{repeal}}$ 是固定学习系数。

3) 繁殖性操作:

生物进化过程一直服从达尔文进化准则, 即“适者生存、优胜劣汰”。BFO 算法执行一段时间的觅食过程后, 部分寻找食物源能力弱的细菌会被自然淘汰, 而为了维持种群规模不变, 剩余的寻找食物能力强 (适应度值低) 的细菌会进行繁殖。在 BFO 算法中模拟这种现象称为繁殖性操作。

$$J_{\text{health}}^i = \sum_{i=1}^{N+1} J(i, j, k, l) \quad (7)$$

4) 迁徙性操作:

实际环境中的细菌所生活的局部区域可能会发生逐渐变化 (如食物消耗殆尽) 或者发生突如其来的变化 (如温度突然升高等)。这样可能会导致生活在这个局部区域的细菌种群被迁徙到新的区域中去或者集体被外力杀死。在 BFO 算法中模拟这种现象称为迁徙性操作。

2.3 BFO-GP 分类器

基于 EEMD-Trelet 和细菌觅食优化算法—高斯过程的齿轮故障诊断步骤如下:

步骤 (1): 数据准备, 从原始振动信号中提取特征作为特征向量, 标签这些特征向量。使用 Trelet 消除原始特征向量的冗余;

步骤 (2): GP 分类初始化, 使用常数均值函数和平方指数协方差核函数;

步骤 (3): 使用 BFO 训练 GP 分类器: 选择不同的超参数选择, 使用式 (4) 计算相应的适应度函数值。设置和使用 GP 分类器: 使用优化的超参数集来设置 GP 分类器。对于新的分类诊断问题, 按照步骤 (1) 提取特征, 并计算分类概率。

3 实验结果与分析

实验设备由起重机齿轮箱组成, 模拟不同齿轮故障的

工作条件。安装在驱动轴上的 1 号齿轮与安装在从动轴上的 2 号齿轮啮合。驱动轴连接到由伺服电动机驱动的挠性联轴器。两个轴由四套轴承支撑。机械振动由加速度计测量。表 1 显示了此实验中 6 种齿轮故障情况。驱动马达的转速为 1 500 RPM, 驱动轴和从动轴的转动频率分别为 25 Hz 和 11.3 Hz。根据轴的转速和相应的齿轮啮合频率, 将数据采集装置的采样率设置为 6 400 Hz。此实验中, 每个实验案例有 50 组振动信号, 总共记录了 300 组信号。

表 1 实验齿轮故障类型

	故障描述	故障位置
案例 1	正常	
案例 2	轻微磨损	1 号齿轮
案例 3	严重磨损	1 号齿轮
案例 4	断齿	1 号齿轮
案例 5	轻微齿轮不平衡	2 号齿轮
案例 6	严重齿轮不平	2 号齿轮

3.1 特征提取

这里以案例 3 的信号为例进行说明。将所有振动信号用 EEMD 分解为本征模态函数 (C_1, C_2, \dots, C_n), 如图 2 所示。然后, 计算每个 IMF 的瞬时频率, 表 2 列出了每个瞬时值的平均值。结果显示本征模态函数 C_7 和 C_8 与主动轴和从动轴的转动频率有关, 分别为 25 Hz 和 11.3 Hz。研究结果也显示啮合频率 575 Hz 位于本征模态函数 C_2 和 C_3 的带宽之内。由于在啮合频率附近的振动信号分量通常由与机器故障有关, 因此提取 C_2 和 C_3 相关的特征, 更具实际意义。为了提取与故障有关的特征, 对 C_2 和 C_3 进行包络分析如下。

步骤 1: 将与啮合频率相关的 C_2 和 C_3 表示为 S , 提取 S 信号的包络信号 Env_s 。

步骤 2: 在 Env_s 上应用 EEMD 和希尔伯特变换, 得到 S 的希尔伯特时频分布频谱。

步骤 3: 沿时间轴对步骤 2 中的频谱进行积分, 得到 S 的希尔伯特边际包络谱。

步骤 4: 利用三次样条拟合希尔伯特边际包络谱的包络信号。

表 2 每个 IMF 的瞬时频率分布的平均值

	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
平均值	1002.9	583.0	319.1	170.0	91.4	46.7
	IMF7	IMF8	IMF9	IMF10	IMF11	IMF12
平均值	24.9	11.5	5.3	3.3	1.8	0

包络分析结果显示案例 3 的包络信号在 0~50 Hz 范围内比案例 2 的能量集中度更高, 这是因为案例 3 的齿轮故障水平比案例 2 更为严重。齿轮故障在 25 Hz (1 号齿轮的旋转频率) 处观察到峰值。还要注意的, 驱动齿轮转速峰值的大小取决于齿轮损坏的程度, 这意味着严重磨损的牙齿 (如案例 3) 的包络信号具有比轻微磨损的情况更集中的

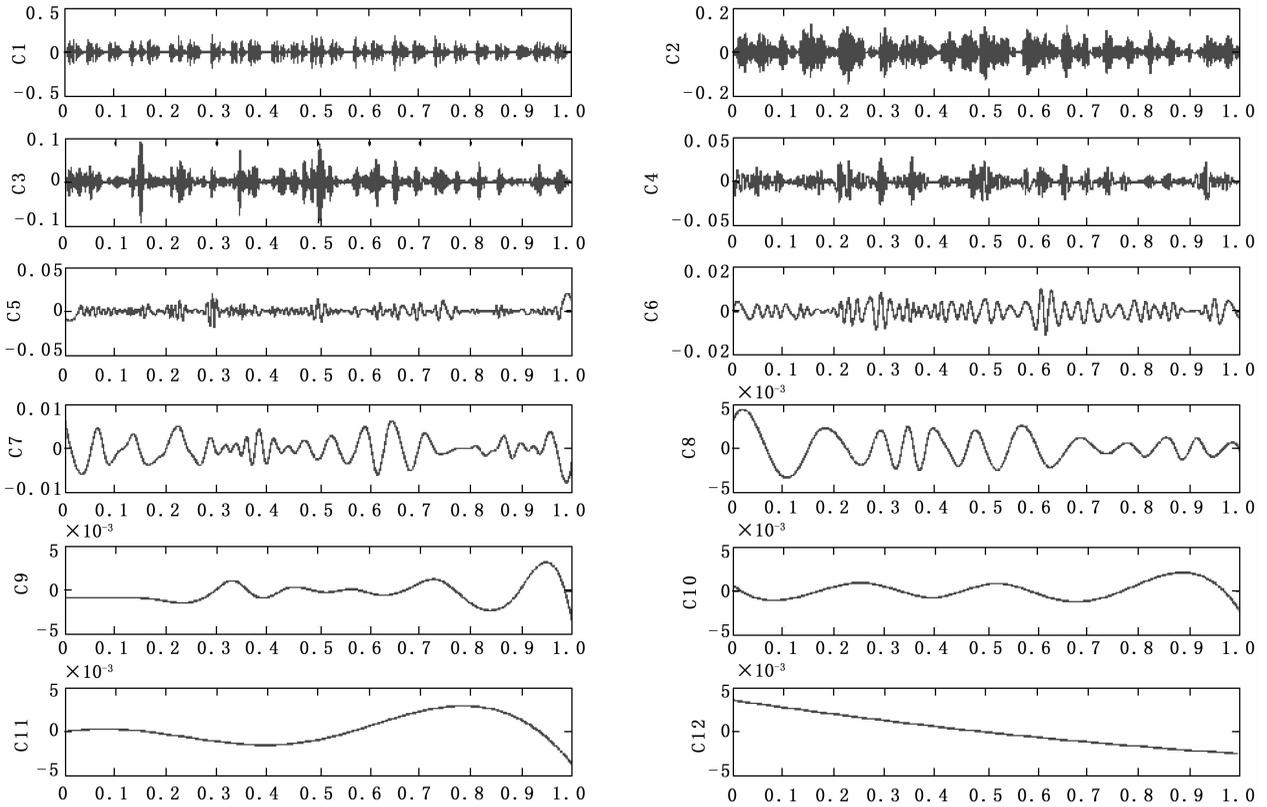


图 2 案例 2 中振动信号的 EEMD 分解产生的 IMF

能量。另外, 由于断齿的劣化程度比轻度 and 严重磨损的牙齿更严重, 因此在 25 Hz 的情况下断齿 (案例 4) 的包络谱峰值高于案例 2 和案例 3。2 号齿轮的主要特征频率是 11.3 Hz。在齿轮的边缘希尔伯特包络谱中观察到严重不平衡情况的能量集中度高于轻微不平衡情况和正常情况 (11.3 Hz) 的能量集中。这是因为严重不平衡情况下的故障水平比轻微失衡和正常情况要严重。

根据以上分析, 从振动信号中提取的特征如表 3 所示。

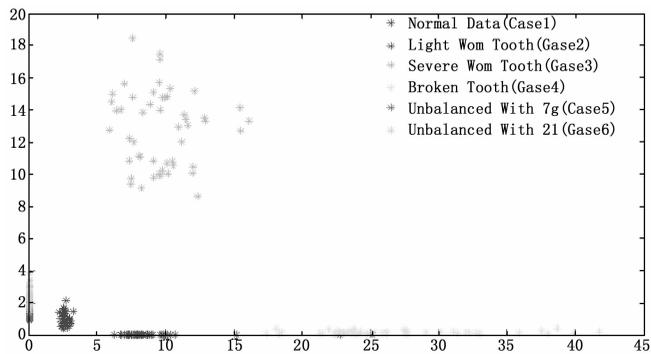


图 3 特征空间中的齿轮数据分布

从案例 1—5 中随机选择 30 个振动信号, 形成样本集, 计算表 3 的特征, 获得 21 维振动信号状态特征。Treelet 变换算法层次设置为 2, 将这 21 维特征降为 2 维。图 3 显示了经 Treelet 变换后齿轮特征数据分布。显然, Treelet 方法可以将正常数据与故障数据分开。每种案例的数据都在特

表 3 每个 IMFS 的瞬时频率分布的平均值

$RMS = \sqrt{\frac{\sum_{i=1}^N x(i)^2}{N}}$	IMF C ₁ 的 RMS	IMF C ₂ 的 RMS	IMF C ₃ 的 RMS
$Range = \max(x) - \min(x)$	IMF C ₁ 的范围	IMF C ₂ 的范围	IMF C ₃ 的范围
$Skewness = \frac{\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^3}{\sigma^3}$	IMF C ₇ 的 RMS	IMF C ₈ 的 RMS	
$kurtosis = \frac{\frac{1}{N} \sum_{i=1}^N (x(i) - \bar{x})^4}{\sigma^4}$	IMF C ₇ 的 Range	IMF C ₈ 的 Range	

C₁ 的边缘希尔伯特包络谱在 11.3 Hz 时的幅度;
 C₁ 的边缘希尔伯特包络谱在 25 Hz 时的幅度;
 啮合频率相关信号分量(C₂+C₃)的边缘希尔伯特包络谱在 11.3 Hz 时的幅度;
 啮合频率相关信号分量(C₂+C₃)在 25 Hz 时的边缘希尔伯特包络谱在 25 Hz 时的幅度;
 振动信号边缘希尔伯特频谱在 25 Hz 时的幅度;
 振动信号边缘希尔伯特频谱在 25 Hz 时的幅度;
 振动信号边缘希尔伯特频谱在 575 Hz 时的幅度。

征空间中较好地聚集。仅有一对不平衡数据特征存在重叠。但是, BFO—GP 仍然可以获得 95% 的诊断精度, 这是令人满意的。对于严重磨损的齿轮和断齿的齿轮, 也发现了相同的情况。

BFO—GP 输出特征空间中每个数据点的分类概率。以 0.5 概率轮廓线作为决策线, 将特征空间分为两类。图 4 显

示了齿轮诊断结果。显然，在使用 Treelet 进行特征降维之后，正常齿轮和退化齿轮数据集在特征空间中得到很好的分类，并且彼此之间有着很好的区分。分类结果是令人满意的。基于 BFO-GP 的方法是适合齿轮故障诊断。

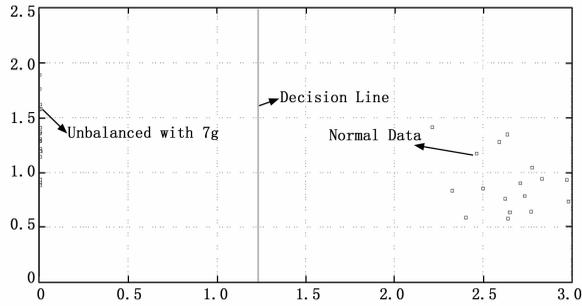


图 4 齿轮诊断结果

进一步，C1-C55 案例的故障诊断其结果如表 6 所示。显然，BFO-GP 的诊断精度高于其它模型如 GA-GP，PSO-GP 和 BFO-SVM，但是 BFO-GP 消耗更多的运行时间成本。测试结果显示对于 GP 的超参数优化能力，BFO 比 GA、PSO 等其它算法表现得更好。

表 6 不同案例的诊断结果

案例		精度/%				运行时间/秒	
C1	C2~5	BFO-GP	GA-GP	PSO-GP	BFO-SVM	BFO-GP	BFO-SVM
20	0	100	80	95	90	289.5	354.7
0	20	100	90	95	85	285.6	352.8

案例					精度/%				运行时间/秒	
C2	C3	C4	C5		BFO-GP	GA-GP	PSO-GP	BFO-SVM	BFO-GP	BFO-SVM
19	1	-	-		95	85	90	85	288.6	357.4s
3	17	-	-		85	80	90	95	284.5	355.8s
-	-	18	0		90	85	80	85	291.6	362.1s
-	-	0	20		100	90	95	90	278.4	352.6s

案例		精度/%				运行时间/秒	
C3	C5	BFO-GP	GA-GP	PSO-GP	BFO-SVM	BFO-GP	BFO-SVM
18	0	90	85	90	85	280.1	353.7s
0	20	100	90	95	90	275.6	349.3s

4 结束语

基于 EEMD-Treelet-GP 的齿轮故障诊断结果发现 EEMD-Treelet 算法能够学习到更多振动信号精细特征。由 EEMD-HT 获得齿轮振动信号的希尔伯特频谱，更多齿轮故障特征被提取。通过 Treelet 变换对这些特征进行筛选，获得线性不相关特征。这些特征输入进 BFO-GP 模型，实现齿轮故障诊断与退化检测。

参考文献:

[1] RANDALL R B. State of the art in monitoring rotating machinery—part 1 [J]. Sound and Vibration, 2004, 38: 14-21.

[2] ZHANG Y, ZUO H, Bai F. Classification of fault location and performance degradation of a roller bearing [J]. Measurement, 2013, 46: 1178-1189.

[3] SARAVANAN N, SIDDABATTUNI V K, RAMACHANDRAN K. A comparative study on classification of features by SVM and PSVM extracted using Morlet wavelet for fault diagnosis of spur bevel gear box [J]. Expert Systems with Applications, 2008, 35: 1351-1366.

[4] WU J D, CHAN J J. Faulted gear identification of a rotating machinery based on wavelet transform and artificial neural network [J]. Expert Systems with Applications, 2009, 36: 8862-8875.

[5] PETER W T, PENG Y, YAM R. Wavelet analysis and envelope detection for rolling element bearing fault diagnosis—their effectiveness and flexibilities [J]. Journal of Vibration and Acoustics, 2001, 123: 303-310.

[6] PENG Z, PETER W T, CHU F. A comparison study of improved Hilbert-Huang transform and wavelet transform: application to fault diagnosis for rolling bearing [J]. Mechanical Systems and Signal Processing, 2005, 19: 974-988.

[7] LEI Y, ZUO M J. Fault diagnosis of rotating machinery using an improved HHT based on EEMD and sensitive IMFs [J]. Measurement Science and Technology, 2009, 20: 125701.

[8] FAN X, ZUO M J. Machine fault feature extraction based on intrinsic mode functions [J]. Measurement Science and Technology, 2008, 19: 045105.

[9] YU D, YANG Y, CHENG J. Application of time-frequency entropy method based on Hilbert-Huang transform to gear fault diagnosis [J]. Measurement, 2007, 40: 823-830.

[10] YANG C Y, WU T Y. Diagnostics of gear deterioration using EEMD approach and PCA process [J]. Measurement, 2015, 61: 75-87.

[11] SAMANTA B, AL-BALUSHI K. Artificial neural network-based fault diagnostics of rolling element bearings using time-domain features [J]. Mechanical systems and signal processing, 2003, 17: 317-328.

[12] WANG C C, KANG Y, SHEN P C, et al. Applications of fault diagnosis in rotating machinery by using time series analysis with neural network [J]. Expert Systems with Applications, 2010, 37: 1696-1702.

[13] EL-SHAFEI A, HASSAN T, SOLIMAN A, et al. Neural network and fuzzy logic diagnostics of 1x faults in rotating machinery [J]. Journal of Engineering for Gas Turbines and Power, 2007, 129: 703-710.

[14] SARAVANAN N, RAMACHANDRAN K. Fault diagnosis of spur bevel gear box using discrete wavelet features and Decision Tree classification [J]. Expert Systems with Applications, 2009, 36: 9564-9573.

[15] XIAO Y, WANG H, XU W. Hyperparameter Selection for Gaussian Process One-Class Classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26 (9): 2182-2187.

(下转第 51 页)