

全封闭往复式压缩机制造缺陷诊断方法研究^①

金华强^{②*} 孙哲^{**} 顾江萍^{*} 黄跃进^{**} 张晓娇^{**} 王新雷^{***} 郑爱武^{****} 沈希^{③**}

(* 浙江工业大学教科学院 杭州 310023)

(** 浙江工业大学机械工程学院 杭州 310023)

(*** 伊利诺伊大学香槟校区农业与生物工程学院 厄巴纳 IL61801)

(**** 加西贝拉压缩机有限公司 嘉兴 314011)

摘 要 全封闭往复式压缩机作为制冷系统的核心部件,其品质决定了整机系统的能效水平、静音效果和产品寿命。在生产制造过程中,针对全封闭结构特点难以识别缺陷产品的短板问题,本文提出了一种基于壳体振动信号的压缩机制造缺陷诊断方法。首先通过集合经验模态分解(EEMD)对振动信号进行频谱分解,再利用多尺度样本熵(MSE)来表征不同尺度下各模态分量的复杂度并以此作为特征向量,最后利用支持向量机(SVM)完成制造缺陷的分类。实验结果表明,本文所提诊断方法能准确实现典型制造缺陷的识别与分类,为全封闭往复式压缩机制造缺陷的在线检测提供了相关理论与检测依据。

关键词 全封闭压缩机;制造缺陷;集合经验模态分解(EEMD);多尺度样本熵(MSE);支持向量机(SVM)

0 引 言

全封闭往复式压缩机作为冰箱、空调等制冷系统的核心部件,是整机中制造与装配难度最大、精度最高的部件,其品质决定了整机系统的能效水平、静音效果、产品寿命。2019 年中国全封闭往复式压缩机产能 2 亿台左右,占全球产能的 60% 以上,中国已经成为全球最大的全封闭压缩机生产国。国内外压缩机制造企业基本实现自动化生产,在大规模生产线制造过程中,难以避免因部件加工或装配工艺问题而出现制造缺陷的产品,如支撑弹簧脱落、吸气消音松动、内排管碰定子。尤其在整机组装完成后,全封闭结构特点导致生产线中没有有效的方法来快速检测制造缺陷,已经成为当前全封闭压缩机制造过程中智能检测的短板环节。

实现全封闭压缩机制造缺陷的智能诊断,其本

质是缺陷特征提取与缺陷分类识别问题。国内外很多学者研究了压缩机故障识别与分类方法。Yang 等人^[1]提出了一种基于人工神经网络和支持向量机(support vector machine, SVM)的冰箱压缩机状态分类方法,用小波变换对噪声和振动信号进行特征提取,通过神经网络与支持向量机实现故障分类,但其检测的对象为生产线中的半成品压缩机(未安装与焊接上壳体)。Lin 等人^[2]利用 Wigner-Ville 分布对往复式压缩机振动信号中的故障特征进行提取,将遗传算法应用于压缩机故障的自动分类。Potocnik 和 Govekar^[3]研究了基于半监督的压缩机故障诊断与分类方法,先通过统计和频谱分析对振动信号进行预处理,然后用主成分分析划分初始类,最后通过分类方法进行故障分类,实验表明分类方法中贝叶斯、支持向量机、极限学习机具有良好的分类性能。Qi 等人^[4]将机器学习技术应用到大型往复式

① 浙江省重点研发(2020C04010),浙江省基础公益研究计划(LGG19E050020)和浙江省教育厅科研(Y201636617)资助项目。
② 男,1982 年生,博士,工程师;研究方向:热力学系统建模与计算机测量评价;E-mail: jhq@zjut.edu.cn
③ 通信作者,E-mail: sx@zjut.edu.cn
(收稿日期:2020-05-18)

压缩机故障诊断中,通过大量运营数据进行稀疏编码与训练,在压缩机潜在故障预测中取得了较好的效果。Li 等人^[5]提出了一种基于 p-V 图的往复式压缩机故障无损检测方法,其 p-V 图是通过测量活塞连杆的应变来推导获得的。张明和江志农^[6]提出了一种基于多源信息融合的往复式压缩机故障诊断方法,利用多种类型传感器数据构建特征证据体,使用径向基神经网络进行初步诊断,根据加权证据融合理论实现最终诊断。同时,还有很多学者对压缩机部件故障与缺陷的诊断进行了研究,用局部均值分解和多尺度模糊熵诊断压缩机轴承间隙故障^[7],用声发射技术^[8]、长短期记忆网络模型^[9]诊断阀片故障。所述文献中大部分研究对象为大型往复式压缩机,小型全封闭往复式压缩机研究较少,尤其是对整机制造缺陷的研究。通过文献可知,振动传感器无需介入安装,适合全封闭压缩机制造缺陷的在线检测,支持向量机对小样本数据的分类识别具有较强的优势。

在压缩机生产线制造过程中,因其全封闭结构特点,整机检测难以识别缺陷产品的短板问题,本文提出了一种基于壳体振动信号的缺陷诊断方法。首先通过集合经验模态分解(ensemble empirical mode decomposition, EEMD)对振动信号进行频谱分解,再计算各模态分量的多尺度样本熵作为特征向量,最后将特征向量输入到支持向量机完成制造缺陷的识别与分类。

1 基于壳体振动信号的缺陷诊断方法

全封闭往复式压缩机运行过程中,内部运动部件工作产生振动噪声源,并通过不同的路径传递到壳体。因此,压缩机壳体振动信号中包含了丰富的运行状态信息。当压缩机由于部件加工或装配工艺缺陷导致运行过程中产生异常的冲击和摩擦时,其壳体振动表现会发生改变。然而,封闭体内激励源众多、传递路径不明确,常规时域或频域分析手段难以快速提取隐含在振动信号内部的差异。针对上述问题,本文提出了一种基于壳体信号的压缩机制造缺陷诊断方法,通过振动频谱分解、缺陷特征提取、

缺陷分类识别 3 个过程实现压缩机制造缺陷的诊断。

1.1 振动频谱分解

全封闭往复式压缩机外壳振动信号是典型的非线性时变信号,其内部蕴含丰富的压缩机运行状态信息,将振动信号进行合理分解是制造缺陷诊断的首要任务。振动信号通常采用时域、频域、时频域、包络解调等方法进行分析,特别是小波变换^[10]、模态分解、维格纳分布^[2]在故障诊断方面都取得了较为理想的效果。全封闭往复式压缩机体积小、结构复杂、零部件封闭于壳体内,导致其外壳振动信号的耦合性较强,但是正常压缩机与制造缺陷压缩机在壳体振动频域表现上仍具有不同程度的差异。本文采用 EEMD 将压缩机壳体振动信号从高频至低频分解为若干个反映不同频率段的本征模态函数(intrinsic mode function, IMF)和残余项,并对各 IMF 的特征进行了相应的分析。EEMD 是一种能够自适应地处理非线性非平稳信号的方法,是在经验模态分解(empirical mode decomposition, EMD)的基础上发展而来的,通过多次叠加白噪声,有效改善了 EMD 存在的模态混叠等缺陷^[11]。

全封闭往复式压缩机壳体振动信号 EEMD 频谱分解的具体步骤如下^[12]。

(1) 原始采集的振动信号为 $x(t)$, 将一组均值为 0、标准差为常数的白噪声 $Q_i(t)$ 添加到原始信号中, 则加入白噪声后的信号变成:

$$X_i(t) = x(t) + Q_i(t) \quad (1)$$

(2) 对带有白噪声的时间序列信号 $X_i(t)$ 进行 EMD 分解, 得到 n 个 IMF 分量 $C_{ij}(t)$ ($j=1, 2, \dots, n$) 和一个残余分量 $Res_{in}(t)$ 。

$$X_i(t) = \sum_{j=1}^n C_{ij}(t) + Res_{in}(t) \quad (2)$$

(3) 对原始信号 $x(t)$ 中添加不同的白噪声, 重复步骤(1)和步骤(2)的次数为 N 。

(4) 将 N 次实验相应 IMF 分量的平均值作为最终对应的 IMF 分量, 同样 N 次实验残余分量的平均值作为残余分量, 计算过程如下所示。

$$C_n(t) = \frac{1}{N} \sum_{i=1}^N C_{in}(t) \quad (3)$$

$$Res_n(t) = \frac{1}{N} \sum_{i=1}^N Res_{in}(t) \tag{4}$$

(5)最后利用高斯白噪声频谱的零均值原理来消除白噪声的影响,最终原始信号 $x(t)$ 可分解为

$$x(t) = \sum_{j=1}^n C_j(t) + Res_n(t) \tag{5}$$

在 EEMD 方法中加入的白噪声应该满足条件:

$$\ln \varepsilon_n + \frac{1}{2} \varepsilon \ln N = 0 \tag{6}$$

式中, ε 为白噪声的幅值, N 为白噪声的集合数, ε_n 为原始信号与相应 IMF 分量和之间的误差。

在 EEMD 分解过程中,由式(6)可知,白噪声集合数 N 和白噪声幅值 ε 对壳体振动信号分解具有直接影响。为了确定 N 和 ε 的取值,以采集于正常定频压缩机壳体顶部的振动信号作为分析对象,振动信号的时域如图 1 所示。通过 FFT 对上述振动信号进行频谱变换,从图 2 中可以发现,有 4 个频谱




图 1 正常压缩机壳体振动信号的时域图




图 2 正常压缩机壳体振动信号的频域图

段的幅值明显较大。对全封闭往复式压缩机振动进行分析与研究,频谱段 D 为阀片撞击振动噪声、频谱段 C 为吸气气流振动噪声、频谱段 B 为排气气流振动噪声、频谱段 A 为不平衡惯性力产生的振动噪声。频谱段 A 通过线性调频 Z 变换(chirp Z-transform, CZT)进行频谱细化,幅值最大值为 49.48 Hz,余下幅值较大值为其各阶倍频。根据前期研究发现^[13],该值转换成转速为 2968.8 rpm,可以作为压缩机的实际转速值。

白噪声集合数 N 越大,理论上分解效果越好,但是 N 太大会导致计算耗时增大,考虑制造缺陷诊断的时效性,白噪声集合数 N 取值为 100。白噪声幅值 ε 用于消除原信号中的噪声,可根据壳体振动信号中的噪声干扰大小来确定,通常设置为原始信号幅值标准差(SD)的 0.1~0.4 倍。为了确定白噪声幅值 ε 的最佳取值, ε 分别取原始信号幅值标准差的 0.1 倍、0.2 倍、0.3 倍和 0.4 倍,通过 EEMD 分解后,对上述 4 个频率段的 IMF 进行对比分析,如图 3 所示。从图中数据可知,白噪声幅值 ε 取较小的标准差倍数时,高频段分解能力较差,但低频的分解效果较好;白噪声幅值 ε 取较大的标准差倍数时,高频段分解能力较好,但低频的分解效果较差。特别是当 ε 为 0.1 SD 时,IMF1 中频率段 C 的幅值仍高于频率段 D 的幅值,两个频率段难以实现有效分解。 ε 为 0.4 SD 时,IMF1、IMF2、IMF4 分解效果都不错,但 IMF7 的幅值降低较多,对后续的制造缺陷特征提取会产生不利影响。综合上述分析,白噪声幅值 ε 取 0.3 SD 较为合适。

为了检验 EEMD 方法对压缩机壳体振动信号的分解效果,以一组正常压缩机和吸气阀有异物压缩机的壳体振动信号作为分析对象,振动信号都取自壳体顶部同一位置。吸气阀有异物是压缩机制造缺陷的一种常见类型,但其振动表现与正常压缩机较为接近,导致此类缺陷在生产线上产品检测中难以发现。通过 EEMD 对两个信号分别进行分解,其中 N 取 100, ε 为 0.3 SD,分解结果如图 4 所示。通过 EEMD 分解,得出以下结论:(1)两者的原始振动信号略有不同,但相关特征难以有效提取;(2)正常压缩机振动信号的各 IMF 中,IMF7(不平衡惯性力产




图3 EEMD 在不同参数下的分解结果比较

生的振动)为最大噪声贡献量,其次为 IMF2(吸气流振动噪声)和 IMF1(阀片撞击振动噪声);(3)吸气阀片有异物压缩机振动信号的各 IMF 中,IMF1 为最大噪声贡献量,其次为 IMF2 和 IMF7。压缩机吸气阀内存在异物,造成阀片拍击阀座时由于接触面不平整而导致振动噪声增大,与 EEMD 的分解结果一致。

1.2 缺陷特征提取

通过 EEMD 对压缩机壳体振动信号进行分解,发现正常压缩机与制造缺陷压缩机在时频域上具有一定的差别,但仅从各 IMF 分量的时频域上不能明显识别出缺陷特征。因此,如何对这些时频域上的差别进行量化与提取是压缩机制造缺陷诊断的关键。针对压缩机制造缺陷特征难以提取的问题,对




图 4 正常与缺陷压缩机 EEMD 分解结果对比

分解得到的各 IMF 分量复杂度进行计算,将其作为特征向量,能有效表征压缩机的制造缺陷。随着信息熵理论的发展,近似熵^[14]、模糊熵^[15]、样本熵^[16]在信号量化度量上得到普遍应用,特别在机械故障诊断领域取得了不错的成果。但是,上述算法都是单一尺度的分析方法,并不能完全反映时间序列信号的复杂性特征,会降低压缩机制造缺陷特征提取的效果。

多尺度样本熵(multiscale sample entropy, MSE)是在样本熵的基础上发展起来的,将原始时间序列信号进行粗粒化,然后计算不同尺度的样本熵,能够反映复杂性特征,获取壳体振动信号的更多特征信息。多尺度样本熵计算的具体过程如下^[17]。

(1)原始时序信号 $X_i = \{x_1, x_2, \cdots, x_J\}$, J 为数据长度,对原始信号进行粗粒化变换,得到新的时间序列:

$$y_i^{(\tau)} = \frac{1}{\tau} \sum_{j=i}^{i+\tau-1} x_j \quad j = 1, 2, \cdots, J/\tau \quad (7)$$

式中, τ 为尺度因子。原始序列被平均分割成 J/τ

段,并且每段长度为 τ 的粗粒序列。

(2)设定嵌入维数 m 和相似容限阈值 r ,对粗粒化序列 $y_i^{(\tau)}$ 进行相空间重构,获得新矩阵可表示为

$$\begin{aligned} \mathbf{y}_m^{(\tau)}(i) &= [y^{(\tau)}(i), y^{(\tau)}(i+1), \cdots, \\ &\quad y^{(\tau)}(i+m-1)] \\ i &= 1, \cdots, J/\tau - m + 1 \end{aligned} \quad (8)$$

(3)计算向量 $\mathbf{y}_m^{(\tau)}(i)$ 与 $\mathbf{y}_m^{(\tau)}(j)$ 中对应元素的最大绝对差值,将两向量的距离定义为

$$\begin{aligned} d(\mathbf{y}_m^{(\tau)}(i), \mathbf{y}_m^{(\tau)}(j)) &= \max(|y^{(\tau)}(i+k) \\ &\quad - y^{(\tau)}(j+k)|) \\ k &= 0, \cdots, m-1 \end{aligned} \quad (9)$$

(4)将 $d(\mathbf{y}_m^{(\tau)}(i), \mathbf{y}_m^{(\tau)}(j))$ 小于相似容限阈值 r 的数量与向量总数的比值记为 $B_{\tau,i}^m(r)$,并计算 $B_{\tau,i}^m(r)$ 的平均值。

$$B^m(r) = \frac{1}{J/\tau - m + 1} \sum_{i=1}^{J/\tau - m + 1} B_{\tau,i}^m(r) \quad (10)$$

(5)维数增加到 $m+1$,获得一组 $m+1$ 的矩阵,重复以上步骤,计算获得:

$$A^m(r) = \frac{1}{J/\tau - m} \sum_{i=1}^{J/\tau - m} A^m_{\tau,i}(r) \tag{11}$$

(6)通过上述过程,不同尺度因子下的样本熵估计值可以表示为

$$S_{MSE}(\tau, m, r) = -\ln\left(\frac{A^m(r)}{B^m(r)}\right) \tag{12}$$

其中,当 $\tau=1$ 时,即对原始时间序列信号进行样本熵的计算。

为了检验多尺度样本熵能否表征压缩机振动信号的复杂度,以正常压缩机和典型缺陷压缩机的壳体振动信号作为分析对象,典型缺陷包括吸气阀有异物、曲柄碰内排管、支撑弹簧脱落、吸气消音松动。通过式(12)可知,多尺度样本熵计算需要确定3个参数,即嵌入维数 m 、相似容限阈值 r 和尺度因子 τ 。嵌入维数 m 通常取2,相似容限阈值 r 取值范围为

0.1~0.25 SD。为了获取多尺度样本熵的最佳参数, τ 取值为1~15, r 分别取0.1 SD、0.15 SD、0.2 SD、0.25 SD,每种类型振动信号在不同尺度下的样本熵如图5所示。通过多尺度样本熵的计算,可以获得以下结论:(1)正常压缩机的样本熵普遍要高于缺陷压缩机,且振动信号差异越大的缺陷类型,其样本熵越小;(2)正常压缩机与缺陷压缩机的样本熵不是在所有尺度因子下都能明显区分,特别是吸气阀有异物压缩机,当 r 取0.1SD时,各振动信号在尺度因子6下的样本熵区分最明显。基于上述分析,将EEMD分解后的各IMF分量进行多尺度样本熵计算,其中多尺度样本熵的最佳参数为 $m=2$ 、 $r=0.1$ SD、 $\tau=6$,计算所得样本熵可以作为制造缺陷的特征向量。




图5 压缩机振动信号的多尺度样本熵

1.3 缺陷分类识别

压缩机壳体振动信号通过 EEMD 从高频至低频分解成若干个 IMF 分量,再计算各 IMF 分量在尺度因子 6 下的样本熵,并以此作为缺陷特征向量,接下来需要通过这些特征向量来实现压缩机制造缺陷的识别和分类。支持向量机(SVM)是一种基于监督学习的、能有效解决小样本非线性数据分类问题的分类器,其核心是将输入样本映射到高维特征空间再执行线性回归。因此,SVM 非常适合压缩机制造缺陷的分类识别。SVM 实现的具体过程如下^[18-19]。

假设存在一个样本集 $V = \{(v_i, y_i) | y_i \in \{-1, 1\}, i = 1, 2, \dots, I\}$,其中 v_i 为样本数据, y_i 为样本类别号, I 为样本数目。利用最大间隔超平面分隔数据样本,如果存在分类超平面 $w \cdot v_i + b = 0$ 使得 $y_i(w \cdot v_i + b) \geq 1 (i = 1, 2, \dots, I)$,则训练样本集是线性可分的。针对线性不可分的情况,引入一个非负的松弛参数 ξ_i ,求解分类超平面的最优化问题为

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + c \sum_{i=1}^I \xi_i (\xi_i \geq 0) \\ \text{s. t. } y_i(wv_i + b) \geq 1 - \xi_i (i = 1, 2, \dots, I) \end{cases} \quad (13)$$

式中, c 为惩罚因子。主决策变量 w 和 b 定义分隔超平面,由此得到的分类器,即判别函数为

$$y(v) = \text{sign}(w^* \cdot v + b^*) \quad (14)$$

为了求解式(13),引入核函数 $K(v_i, v_j)$,转化为对偶最优化问题:

$$\begin{cases} \max L(\alpha) = \sum_{i=1}^I \alpha_i - \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^I \alpha_i \alpha_j y_i y_j K(v_i, v_j) \\ \text{s. t. } \sum_{i=1}^I \alpha_i y_i = 0 (0 \leq \alpha_i \leq c, i = 1, 2, \dots, I) \end{cases} \quad (15)$$

判别函数为

$$y(v) = \text{sign}(\sum_{i=1}^I \alpha_i y_i K(v_i, v_j) + b) \quad (16)$$

不同的核函数适用于不同的分类样本,常见的核函数有线性核函数、多项式核函数、径向基核函数、混合核函数等。根据 Mercer 理论^[19],本文采用径向基核函数,函数表达式如下式所示。

$$K(v_i, v_j) = \exp(-\|v_i - v_j\|^2 / 2\sigma^2) \quad (17)$$

支持向量机的性能取决于惩罚因子 c 和核参数 σ 。惩罚因子 c 决定模型的泛化性能和分类误差,值太大容易产生重叠和泛化能力降低,值太小容易陷入假设状态。核参数 σ 影响内核空间中输入样本的分布。本文采用粒子群优化算法^[20] (particle swarm optimization, PSO)实现惩罚因子 c 和核参数 σ 寻优。

2 实验验证平台建立

2.1 硬件系统搭建

为了检验基于壳体振动的压缩机制造缺陷诊断方法,项目组搭建了实验验证平台,平台由被测对象、振动测量、数据处理与分析等部分组成,如图 6 所示。




图 6 实验验证平台

实验验证平台的振动测量中,加速度传感器采用 PCB 352C33,数据采集卡为 NI-9234,并通过微型机箱 cDAQ-9171 将振动数据传递到计算机进行处理与分析。被测压缩机选用某型号定频全封闭往复压缩机,除了正常压缩机,还特制 4 类典型制造缺陷的压缩机,包括吸气阀有异物、曲柄碰内排管、吸气消音松动、支撑弹簧脱落,如图 7 所示。

2.2 诊断方法实现

全封闭往复压缩机制造缺陷诊断方法采用 LabVIEW 和 Matlab 混合编程技术实现,能有效保证系统的鲁棒性。通过 LabVIEW 中的 Matlab Script 模式将采集的壳体振动信号导入 Matlab 脚本程序进行频谱分解、多尺度样本熵计算,最后通过支持向

量机进行制造缺陷的分类识别。全封闭往复式压缩机制造缺陷诊断方法的功能流程如图 8 所示。




图 7 压缩机典型制造缺陷




图 8 诊断方法的功能流程图

3 实验数据分析

在全封闭往复式压缩机生产线制造缺陷诊断中,振动加速度传感器要紧贴壳体表面、检测时间应严格匹配生产节拍,考虑这些因素,采用一个传感器进行制造缺陷的诊断是最佳的。本文提出的制造缺陷诊断方法基于壳体振动信号,然而壳体不同位置的振动响应是有区别的,因此不同位置测量的振动信号对制造缺陷诊断会产生影响。为了探明测点位置对振动信号采集的影响,在压缩机壳体的顶面和侧面各处均匀分布 7 个振动测点,其中测点 7 位于测点 5 的正背面,如图 9 所示。选择一组被测压缩机进行实验,额定转速为 3000 rmp,空载工况运行平

稳后进行振动信号采集,采样频率为 25.6 kHz,不同测点的测量数据如图 10 所示。根据实验数据可知,(1)不同测点测量的振动信号在时域上具有显著差别,越靠近制造缺陷点,振动的幅值越大;(2)各类典型制造缺陷中,压缩机顶面中心位置,即测点 2 处的振动信号与正常压缩机对应点的振动信号区别明显。基于上述分析,压缩机制造缺陷诊断可采用测点 2 作为振动信号的测量点。




图 9 压缩机振动测点布置

针对测点 2 采集的振动信号,通过 EEMD 进行频谱分解,其中白噪声集合数 N 取 100,白噪声幅值 ε 为 0.3 SD,原始信号被分解成 9 个 IMF 分量和 1 个残余项。为了最大限度提高计算效率并保证缺陷特征的提取,对分解后的 IMF 分量进行取舍,保留相关性大的 IMF 分量进行后续计算。对分解后的 IMF 分量与原始信号进行相关度计算,相关性系数计算结果如表 1 所示,将相关性系数较大的 7 个 IMF 分量,即 IMF1 ~ IMF7,来进行后续的多尺度样本熵计算。

表 1 相关性系数计算结果

IMF 分量	正常压缩机	吸气阀有异物	支撑弹簧脱落	吸气消音松动	曲柄碰内排管
IMF1	0.9452	0.9771	0.1559	0.5631	0.6492
IMF2	0.2762	0.2107	0.2322	0.3524	0.7605
IMF3	0.0155	0.0106	0.2108	0.0127	0.0117
IMF4	0.0104	0.0058	0.2220	0.0124	0.0030
IMF5	0.0058	0.0036	0.3689	0.0126	0.0011
IMF6	0.0244	0.0097	0.7970	0.2274	0.0006
IMF7	0.1659	0.0201	0.2364	0.7116	0.0003
IMF8	0.0420	0.0125	0.0268	0.0096	0.0002
IMF9	0.0007	0.0002	0.0133	0.0031	0.0001




图 10 不同振动测点的信号对比

通过相关性系数的计算,选择前 7 个 IMF 分量进行多尺度样本熵计算,其中嵌入维数 m 取 2,相似容限阈值 r 取 0.1 SD,将尺度因子为 6 的样本熵作为特征向量。为了进行支持向量机模型的训练,选取 4 种典型制造缺陷压缩机和正常压缩机各 40 组特征向量,如表 2 所示。其中信号分类标签 1、2、3、4、5 分别代表正常压缩机、吸气阀有异物、支撑弹簧脱落、吸气消音松动、曲柄碰内排管。

支持向量机通常只能处理二分类问题,本文所解决的压缩机制造缺陷诊断问题,需要分类 5 种不同的振动信号类型。针对压缩机制造缺陷的多分类问题,采用二叉树分类算法,通过输入的样本数据训练 4 个模型,即 SVM1、SVM2、SVM3 和 SVM4,如图 11 所示。在压缩机缺陷分类时,先将吸气阀有异物的缺陷压缩机分类出来,然后把剩下类型的压缩机进行下一级分类,直到实现所有类型压缩机的分类。




图 11 制造缺陷二叉树分类

支持向量机的分类准确性受惩罚因子 c 和核参数 σ 取值的影响,运用粒子群优化算法对惩罚因子和核参数的取值进行寻优。粒子群优化算法初始化设置如下,其中学习因子 $c1$ 和 $c2$ 分别为 1.5 和 1.7,种群大小为 20,迭代次数为 200。经过粒子群

表 2 压缩机制造缺陷特征向量训练样本

信号类型	样本 编号	信号 分类标签	训练样本的特征向量						
			IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7
正常 压缩机	1	1	0.6541	0.5989	0.2479	0.1739	0.1019	0.1430	0.1583
	2	1	0.6734	0.5861	0.2311	0.1812	0.1321	0.1563	0.1385
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	40	1	0.6381	0.5996	0.2383	0.1788	0.1373	0.1545	0.1205
吸气阀 有异物	1	2	0.5630	0.6538	0.2245	0.1546	0.0732	0.0758	0.0811
	2	2	0.5720	0.6789	0.2299	0.1435	0.0700	0.0557	0.0807
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	40	2	0.5618	0.6697	0.2612	0.1673	0.0827	0.0666	0.0834
支撑弹簧 脱落	1	3	0.0671	0.1029	0.0359	0.0549	0.1185	0.3102	0.2807
	2	3	0.0599	0.0923	0.0398	0.0533	0.1244	0.2929	0.2991
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	40	3	0.0637	0.0960	0.0370	0.0543	0.1184	0.3159	0.3059
吸气消音 松动	1	4	0.0331	0.2796	0.0304	0.0221	0.0442	0.1953	0.2640
	2	4	0.0359	0.2750	0.0323	0.0211	0.0444	0.1909	0.2747
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	40	4	0.0397	0.2438	0.0479	0.0321	0.0410	0.1749	0.2532
曲柄碰内 排管	1	5	0.1846	0.1983	0.0768	0.0389	0.0127	0.0020	0.0009
	2	5	0.1805	0.1800	0.0736	0.0421	0.0114	0.0016	0.0009
	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
	40	5	0.1719	0.1909	0.0754	0.0364	0.0091	0.0016	0.0009

表 3 制造缺陷分类结果

测试样本	正常压缩机	吸气阀有异物	支撑弹簧脱落	吸气消音松动	曲柄碰内排管	准确率/%
正常压缩机	40	0	0	0	0	100
吸气阀有异物	1	39	0	0	0	97.5
支撑弹簧脱落	0	0	40	0	0	100
吸气消音松动	0	0	0	40	0	100
曲柄碰内排管	0	0	0	0	40	100

优化算法的寻优,获得惩罚因子 c 和核参数 σ 的最佳取值为 1.58 和 14.10。支持向量机模型训练完成后,为了测试分类的效果和准确性,选取一批新的数据进行检验,包括 5 种类型各 40 组数据。通过支持向量机预测的分类标签与实际分类标签进行对比,压缩机制造缺陷分类结果如表 3 所示。测试结果表明,除吸气阀有异物压缩机的 1 个样本识别有错,其他测试样本都识别准确,因此本文所提诊断方法能实现全封闭往复式压缩机典型制造缺陷的准确识别与分类。

4 结 论

本文通过对全封闭往复式压缩机典型制造缺陷的频谱分解、特征提取和分类识别进行了研究,提出了一种基于壳体振动的制造缺陷诊断新方法。在实验验证平台上进行实验,根据实验数据得出以下结论。

(1) 全封闭往复式压缩机壳体振动信号耦合性较强,通过 EEMD 能将主要噪声源分解到对应的 IMF 分量中,并且白噪声幅值 ε 为 0.3 SD 时能取得较好的分解效果。

(2) 多尺度样本熵能较好地表征压缩机振动信号的复杂度,当嵌入维数 m 为 2、相似容限阈值 r 为 0.1 SD,在尺度因子 6 下样本熵的区分最明显,各 IMF 分量在上述参数下的样本熵可作为制造缺陷的特征向量。

(3) 依据输入特征向量进行支持向量机模型的训练,并通过粒子群优化算法对模型惩罚因子和核参数寻优,实验数据表明诊断方法能准确识别各类典型制造缺陷。

本文通过对正常压缩机与典型制造缺陷压缩机壳体振动信号的分析,提出制造缺陷特征提取和制造缺陷分类识别方法,为全封闭往复式压缩机制造缺陷的在线检测提供了一条可行路径。

参考文献

- [1] Yang B S, Hwang W W, Kim D J, et al. Condition classification of small reciprocating compressor for refrigerators using artificial neural networks and support vector machines[J]. *Mechanical Systems and Signal Processing*, 2005, 19(2): 371-390
- [2] Lin Y H, Lee W S, Wu C Y. Automated fault classification of reciprocating compressors from vibration data: a case study on optimization using genetic algorithm [J]. *Procedia Engineering*, 2014, 79: 355-361
- [3] Potocnik P, Govekar E. Semi-supervised vibration-based classification and condition monitoring of compressors [J]. *Mechanical Systems and Signal Processing*, 2017, 93: 51-65
- [4] Qi G Q, Zhu Z Q, Erqinhu K. Fault-diagnosis for reciprocating compressors using big data and machine learning [J]. *Simulation Modelling Practice and Theory*, 2018, 80: 104-127
- [5] Li X Y, Peng X Y, Zhang Z T, et al. A new method for nondestructive fault diagnosis of reciprocating compressor by means of strain-based p-V diagram [J]. *Mechanical Systems and Signal Processing*, 2019, 133: 106268
- [6] 张明, 江志农. 基于多源信息融合的往复式压缩机故障诊断方法[J]. *机械工程学报*, 2017, 53(23): 46-52
- [7] Zhao H Y, Wang J D, Han H, et al. A feature extraction method based on HLMD and MFE for bearing clearance fault of reciprocating compressor [J]. *Measurement*, 2016, 89: 34-43

- [8] Ali S M, Hui K H, Hee L M, et al. Automated valve fault detection based on acoustic emission parameters and support vector machine[J]. *Alexandria Engineering Journal*, 2018, 57: 491-498
- [9] Cabrera D, Guaman A, Zhang S, et al. Bayesian approach and time series dimensionality reduction to LSTM-based model-building for fault diagnosis of a reciprocating compressor[J]. *Neurocomputing*, 2020, 380: 51-66
- [10] Tan D P, Zhang L B. A WP-based nonlinear vibration sensing method for invisible liquid steel slag detection [J]. *Sensors and Actuators B: Chemical*, 2014, 202: 1257-1269
- [11] 王书涛, 李亮, 张淑清. 基于 EEMD 样本熵和 GK 模糊聚类的机械故障识别[J]. *中国机械工程*, 2013, 24(22): 3036-3040
- [12] Wu Z H, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1: 1-41
- [13] 金华强, 顾江萍, 黄跃进, 等. 排气压力脉动的全封闭往复式压缩机转速测量方法[J]. *中国机械工程*, 2018, 29(17): 2060-2068
- [14] Zhao S F, Liang L, Xu G H, et al. Quantitative diagnosis of a spall-like fault of a rolling element bearing by empirical mode decomposition and the approximate entropy method[J]. *Mechanical Systems and Signal Processing*, 2013, 40: 154-177
- [15] Zheng J D, Cheng J S, Yang Y. A rolling bearing fault diagnosis approach based on LCD and fuzzy entropy [J]. *Mechanism and Machine Theory*, 2013, 70: 441-453
- [16] Ni Q, Feng K, Wang K S, et al. A case study of sample entropy analysis to the fault detection of bearing in wind turbine[J]. *Case Studies in Engineering Failure Analysis*, 2017, 9: 99-111
- [17] 邹晓红, 张轶勃, 孙延贞. 基于局部均值分解和多尺度熵的运动想象脑电信号特征提取方法[J]. *高技术通讯*, 2018, 28(1): 22-28
- [18] Bordoloi D J, Tiwari R. Support vector machine based optimization of multi-fault classification of gears with evolutionary algorithms from time-frequency vibration data [J]. *Measurement*, 2014, 55: 1-14
- [19] Vapnik V N. The Nature of Statistical Learning Theory [M]. New York: Springer, 1998: 401-492
- [20] 王维刚, 刘占生. 多目标粒子群优化的支持向量机及

其在齿轮故障诊断中的应用[J]. 振动工程学报,
2013,26(5):743-750

A diagnosis method for manufacturing defects of hermetic reciprocating compressor

Jin Huaqiang^{* **}, Sun Zhe^{**}, Gu Jiangping^{*}, Huang Yuejin^{**}, Zhang Xiaojiao^{**},

Wang Xinlei^{***}, Zheng Aiwu^{****}, Shen Xi^{**}

(^{*} College of Education, Zhejiang University of Technology, Hangzhou 310023)

(^{**} College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023)

(^{***} Department of Agricultural and Biological Engineering, University of Illinois

at Urbana-Champaign, Urbana IL 61801)

(^{****} JiaXiPera Compressor Co. Ltd, Jiaxing 314011)

Abstract

As the core component of the refrigeration system, the quality of hermetic reciprocating compressor determines the energy efficiency level, silent effect, and product life of the whole system. In the manufacturing process of the production line, in order to solve the shortcomings that it is difficult to identify the defective product due to the characteristics of the hermetic structure, this paper proposes a diagnosis method for manufacturing defects based on the vibration signal of the compressor shell. First, the ensemble empirical mode decomposition (EEMD) is used to spectrally decompose the vibration signal. Furthermore, the multiscale sample entropy (MSE) is utilized to characterize the complexity of each intrinsic mode function (IMF) at different scales, and the values are used as the feature vector. Finally, the support vector machine (SVM) is used to complete the classification of manufacturing defects. Experimental results show that the detection the proposed method can accurately identify and classify typical manufacturing defects, and provide relevant theoretical and testing base for the online detection of hermetic refrigeration compressors.

Key words: hermetic compressor, manufacturing defect, ensemble empirical mode decomposition (EEMD), multiscale sample entropy (MSE), support vector machine (SVM)