

基于应力波分析的状态监控与故障预测研究*

吴天舒¹, 陈蜀宇¹, 吴朋²

(1. 重庆大学计算机学院 重庆 400044; 2. 重庆川仪自动化股份有限公司 重庆 401121)

摘要:随着先进的仪器测量与分析、物联网、云计算、数据挖掘、人工智能等科学技术的发展,设备状态监控和故障预测技术近年来在工业设备健康管理中起到越来越重要的作用。研究了一种基于应力波分析的状态监测与故障预测技术,通过应力波传感器对设备运动部件间的摩擦、机械冲击和动态荷载的电子信号进行检测和处理,采用专为应力波分析而开发的时域和频域特征提取软件和基于神经网络的数据融合技术,对设备状态进行定量分析,对设备故障进行准确预测,并提供设备健康诊断分析报告。运行试验表明,与振动分析等传统的状态监测方法相比,本系统能更好地实时监控设备运行情况,更早地预测故障,保证了生产安全性,降低了设备检维修成本,提高了生产效率。

关键词: 应力波分析;特征提取;神经网络;数据融合

中图分类号: TH7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Condition monitoring and fault prediction based on stress wave analysis

Wu Tianshu¹, Chen Shuyu¹, Wu Peng²

(1. College of Computer Science, Chongqing University, Chongqing 400044, China;

2. Chongqing Chuanyi Automation Co., Ltd., Chongqing 401121, China)

Abstract: The equipment condition monitoring and fault prediction technology plays an increasingly important role in industrial equipment health management with the development of science and technology on instrument measurement and analysis, Internet of things, cloud computing, data mining, artificial intelligence. This paper studies a condition monitoring and fault prediction technology based on stress wave analysis. The electronic signal of friction, mechanical shock and dynamic load on equipment moving parts are detected and processed by stress wave sensor. The stress wave analysis is fulfilled by using the time domain and frequency domain feature extraction software and sensor data fusion is conducted based on neural network. The equipment states are quantitatively analyzed and the equipment fault is accurately predicted, so as to provide the equipment health diagnosis reports. The test shows that, compared with the traditional vibration analysis, the proposed system can monitor the equipment operation condition better in real time, predict the fault earlier. The production safety can be guaranteed, the equipment maintenance cost can be reduced, and the production efficiency can be improved.

Keywords: stress wave analysis; feature extraction; neural network; data fusion

0 引言

现代化生产对设备的依赖程度越来越高,实现设备安全、可靠、高效、低耗的运行是产品质量、生产安全和环境保护的重要保证。因此,加强对现代设备的管理具有重大意义。

设备检修方式可以分为故障检修、预防性检修和预

知性维修3类。故障检修是在设备故障后进行的被动检修,已经造成停产损失甚至生产事故,且由于缺乏设备运行历史数据,使维修具有盲目和不准确性;预防性检修是按规定周期进行的检修方式,是目前避免障碍和事故的主要手段,但可能在设备还处于良好状态时停机检修,造成维护过度和资源浪费;从先进设备管理的发展趋势看,采用设备状态监测与故障诊断技术作为重要手段的预知性维修已成必然。其主要目的是降低保障费用,提高设

备安全性、可靠性,以较少的维修投入,实现基于状态的维修^[1]。

随着先进的仪器测量与分析技术、物联网、云计算、数据挖掘、人工智能等科学技术的发展,仪器系统的数字化、自动化、集成化和网络化水平不断提升,近年来设备状态监测和故障诊断技术的有效性和可靠性不断提高,获得了广泛工程应用,在现代企业设备健康管理和预知维修中起到越来越重要的作用^[2]。

状态监测与故障诊断一般采用基于振动的测量与分析,油液分析、红外热像、超声探伤以及温度、压力分析等多种技术。其中,利用各种振动传感器和分析仪器获得振动信号来获取机械设备的运行状态并进行故障诊断由于具有方便性、在线性和无损性等特点,成为目前比较常用的方法^[3]。

但是,在对低速旋转设备诊断时,故障特征频率被设备的共振和背景噪声所覆盖,传统的振动方法检测不到设备的工作频率,而且低速旋转设备有组件失效时对振动信号也影响不大^[4]。

目前对应力波理论的研究主要集中在土木建筑和交通施工领域对材料^[5-6]和结构^[7-9]的应用,虽然近年来也有少量文献表明有研究齿轮中应力波传播机理的成果,但只限于测试技术探讨及把结果用于算法验证^[10],真正将应力波检测和分析研究成果应用于工业设备状态监控和故障预测的还几乎是空白。

本文研究了一种基于应力波分析的状态监控与故障预测技术,它实时测量运行设备摩擦、冲击和动态载荷的电子信号,这种高频声波传感技术滤除了振动和可听噪声的背景,通过时域和频域特征提取软件,采用基于神经网络的数据融合技术,可以对设备状态进行定量分析和故障预测,定期提供设备健康诊断分析报告,为企业建立预知性检维修体系。

1 应力波原理

应力波是应力和应变扰动的传播形式。是可变形固体介质中机械扰动表现为质点速度的变化和相应的应力、应变状态的变化。应力、应变状态的变化以波的方式传播,称为应力波。扰动区域与未扰动区域的界面称为波阵面,波阵面的传播速度称为波速^[11]。

在运动参量随时间发生显著变化的动载荷条件下,介质中各个微元体处于随时间变化的动态过程中,因此需计及介质微元体的惯性力,由此导致对应力波传播的研究。对于一切具有惯性的可变形介质,当在应力波传过物体所需的时间内外载荷发生显著变化的情况下,介质的运动过程就总是一个应力波传播、反射和相互作用的过程,这个过程的特点主要取决于材料的特性。应力

波研究主要集中在介质的非正常运动、动载荷对介质产生的局部效应和早期效应以及载荷同介质的相互影响^[12]。

当应力与应变呈线性关系时,介质中传播的是弹性波。图1所示为最简单的一维弹性波横向振动的弦线,通过对其波动方程的分析,可以展示许多弹性动力问题的共同特点^[13]。




图1 一维弹性波弦线的横向振动

Fig. 1 Transverse vibration of one dimensional elastic wave string

图1中, U 表示位移, t 为时间, X 表示在物质坐标中波阵面沿其传播方向的位置, x 表示在空间坐标中波阵面沿其传播方向的位置。 $u(x,t)$ 表示在 t 时刻 x 点处质点的位移, $T(x,t)$ 表示该点的张力, $\rho(x,t)$ 为该点的密度。 $C = dX/dt$ 称为物质波速或内禀波速, $c = dx/dt$ 称为空间波速,两种波速是同一物理现象的不同表述方式。对于平面波,两种波速的关系是 $c = v + (1 + \varepsilon)C$ 。式中 v 为质点速度, ε 为工程应变。

对于初始密度为 ρ_0 ,在动载荷下应力 σ 和应变 ε 间具有单值函数关系 $\sigma = \sigma(\varepsilon)$ 的速率无关材料,由质量守恒和动量守恒方程可得到以位移 $u(X,t)$ 为未知量的拟线性波动方程:

$$\frac{\partial^2 u}{\partial t^2} - C^2 \frac{\partial^2 u}{\partial X^2} = 0 \quad (1)$$

式中: $C = \left(\frac{1}{\rho_0} \frac{d\sigma}{d\varepsilon} \right)^{1/2}$ 。

方程(1)有两组分别代表右行波和左行波的实特征线和相应的沿特征线的相容关系:

$$dX = \pm C dt, \quad d\sigma = \pm \rho_0 C dV \quad (2)$$

式中:波速 C 和波阻抗 $\rho_0 C$ 完全由材料性能决定。此结果与气体动力学中的一维定常运动相类似。求解应力波的传播问题在数学上归结为在给定的初始和边界条件下求解波动方程(1)或等价的特征线方程组(2)。常用的数值解法有特征线法、有限差分方法和有限元法^[14]。

对各向同性线弹性材料, $d\sigma/d\varepsilon$ 为常数,因此线弹性波波速(即声速) C_e 为恒值:对于一维应力纵波为 $C_0 = (E/\rho_0)^{1/2}$,式中 E 为杨氏模量;对于侧向受限的一维应变纵波为 $C_1 = (E'/\rho_0)^{1/2}$,式中 E' 为侧限弹性模量。

$$E' = \lambda + 2\mu = K + \frac{4}{3}\mu =$$

$$E[(1 - \nu)/(1 + \nu)(1 - 2\nu)] \quad (3)$$

式中: λ 为一阶拉梅常数,表示材料的压缩性,等价于体积弹性模量或杨氏模量; μ 为二阶拉梅常数,表示材料的剪切模量。 K 为体积压缩模量, ν 为泊松比。 C_1 也即无限弹性介质中的纵波波速。对于横波,只需把 μ 、 σ 和 ε 相应地理解为横向质点位移、剪应力和剪应变,则得横波波速 $C_t = (G/\rho_0)^{1/2}$, G 为剪切模量^[15]。

某些典型材料的弹性波波速值如表 1 所示^[16]。

表 1 几种常见材料的弹性波波速

Table 1 The elastic wave velocity of several common materials (s · m⁻¹)

材料	C_1	C_t
铝	6 100	3 100
钢	5 800	3 100
铅	2 200	700
树脂玻璃	2 600	1 200
聚苯乙烯	2 300	1 200
镁	6 400	3 100

2 应力波检测与分析

基于应力波分析(stress wave analysis, SWA)的状态监控与故障预测系统由应力波传感器、信号处理单元和控制显示单元 3 个部分组成。应力波传感器安装在设备轴承、齿轮箱等运动部件附近的表面,通过运行设备构件传输的摩擦、机械冲击和动态载荷的应力波信号是超声频率,传感器中的压电晶体将应力波振幅转换为电信号,然后在模拟信号调制器中通过高频带通滤波器进行放大和滤波,以去除设备正常运动的低频噪声和振动能量。信号通过数据采集箱进行放大处理后转化为本系统计算机或工厂已经使用的 DCS/PLC 系统可以接收的数据标准,该数据被存储在系统的服务器上。系统调用这些数据经过软件分析后生成诊断报告。如图 2 所示。

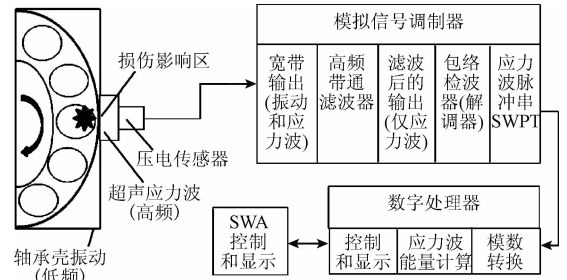


图 2 应力波检测与分析

Fig. 2 Stress wave detection and analysis

应力波分析的主要工具包括应力波能量(stress wave energy, SWE)、应力波振幅直方图和应力波频谱。

模拟信号调制器的输出是一个应力波脉冲串(stress wave pulse train, SWPT),代表设备受到的冲击和机械摩擦事件的时间历史。数字处理器通过分析 SWPT 来确定摩擦、冲击事件产生的峰值水平和总能量。计算出的应力波脉冲幅值(stress wave pulse amplitude, SWPA)和 SWE 的值,存储在数据库中做为历史趋势并与正常读数进行比较分析。

振动传感器是通过平坦的频率响应(如 100 mV/g)来检测宽范围的频率(如 0 ~ 15 000 Hz),因此它在故障早期对机器摩擦的轻微变化不敏感。只有在故障恶化之后,振动水平被激发到显著高于背景,振动传感器才能检测到异常。而应力波传感器有一个很窄的频率范围(如 36 000 ~ 40 000 Hz)和非常高的频率响应(如共振),因此对机械表面的小缺陷非常敏感。采用应力波分析,可以在破坏过程的早期从工作机械振动和可听噪声的非常低的频率范围内分离检测和分析像 SWE、SWPA 和应力波峰值持续时间(stress wave peak duration, SWPD)这样的特征,在监视设备齿轮和轴承损坏时发挥无可比拟的作用。

应力波的振幅是单个摩擦或冲击事件强度的函数,如在剥落的轴承中检测到的应力波峰值水平是冲击速度和剥落深度的函数。而 SWE 是一个时域积分的计算值,是冲击速度、剥落深度和剥落规模的函数,它考虑到在时间间隔期间发生的所有摩擦和冲击事件的振幅、形状、持续时间和速率。通过测量摩擦事件的能量含量(冲击幅度和持续时间,即脉冲串产生的曲线面积)可以把损伤进行量化^[17],如图 3 所示。

SWE 运行历史图表通过系统在日常运行中采集数据而生成。它显示出 SWE 读数随时间推移的变化趋势,并以 I、II 和 III 区域图形化表示设备的健康趋势。应力波能量在设备故障过程中的变化趋势如图 4 所示。

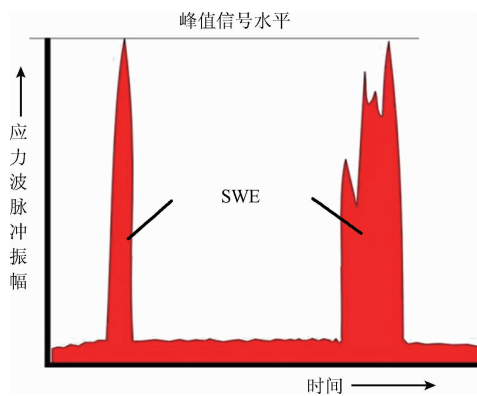


图3 应力波能量

Fig. 3 Stress wave energy




图5 应力波振幅直方图

Fig. 5 Stress wave amplitude histogram

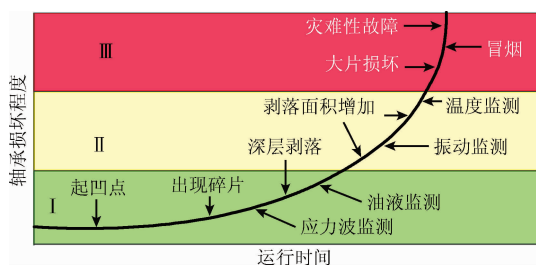



图4 故障过程中的应力波能量


Fig. 4 The SWE during the failure process

应力波振幅直方图如图5所示, Y轴表示摩擦事件的数量, X轴表示单个摩擦脉冲的峰值幅度。该工具检测应力波脉冲串中每个脉冲的峰值幅度, 并将其分布到对应每一读数值电压刻度。在正常运行状态下, 设备处于最佳性能, 分布是窄的呈正态分布的钟形曲线并处于电压的低值端, 如图5(a)所示。而在异常、摩擦和冲击事件发生时, 越来越多的高振幅摩擦事件发生, 结果是一个更广泛的分布, 即在振幅刻度上“倾斜”到右边, 如图5(b)所示。



应力波频谱是分析应力波脉冲串以检测其频谱内容(脉冲振幅作为它们发生的重复频率的函数)的算法, 如图6所示。应力波分析只检测能够激发传感器在超声波频率的事件, 所有与设备动力学相关的低频振动都被过滤掉, 剩下的只是激波或摩擦调制事件的时间历史。健康设备发生的冲击事件最少, 因此频谱是一个相对平坦的水平线, 如图6(a)所示。而在有局部损伤区域的情况下(如滚动轴承的座圈或齿轮的一个齿剥落), 当损伤区域与匹配部件接触时, 会发生重复的冲击事件。这种重复的冲击事件在频谱中显示为, 在它发生的频率上, 谱线尖峰超过背景水平 10 dB 以上, 如图6(b)所示。当发生尖峰时, 分析齿轮和轴承元件的几何形状和它们旋转的速度, 可以确定在该频率下可能引起冲击的精密零件, 从而指示损坏的部件及其位置。

SWE、应力波振幅直方图和应力波频谱这3种应力波分析工具, 在诊断各种机械传动齿轮和滚动轴承的状态上是非常有效的。SWE的运行历史具有高度趋势化故障征兆的优势, 可以用来广泛地检测和量化齿轮和轴承系统的损伤程度; SWE对由于错位或不当修理造成的润滑质量下降、润滑油污染和异常预荷载也是高度敏感的; SWE的测量还提供了将故障定位到一个特定的齿轮






图 6 应力波频谱

Fig. 6 Stress wave spectrum

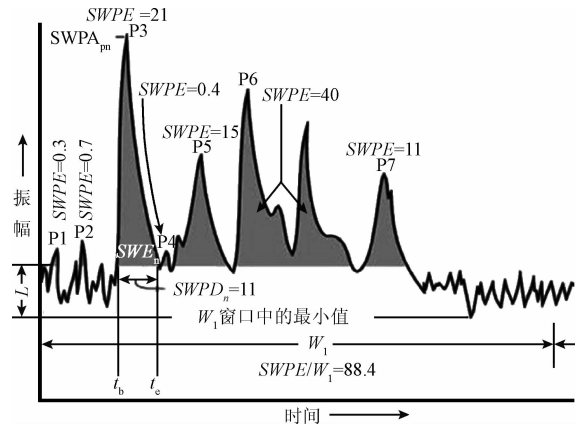


图 7 应力波时域特征

Fig. 7 Time domain characteristics of stress wave

或轴承,甚至是轴承内的一个座圈或滚珠的能力。应力波振幅直方图在早期发现经常与润滑问题有关的非周期事件(如流体或颗粒污染,滚动轴承和座圈之间打滑)方面是最有效的。应力波频谱则具有对异常动态载荷、对非常小的早期局部疲劳损伤非常敏感的优点。

3 特征提取软件

基于信号处理的故障诊断方法的主要思想是利用信号分析理论获得系统时域和频域中较深层次的多种特征向量,利用这些特征向量与系统故障源之间的关系判断故障源的位置^[18]。

应力波信号的分析 and 处理技术可以采用时域分析、频域分析、时频域分析和时间序列建模分析等方法。这些分析处理技术从不同的角度对信号进行观察和分析,为提取与设备运行状态有关的特征信息提供了不同的手段^[19]。

为应力波分析而开发的特征提取软件用于准确表征 SWPT 和压缩 SWPT 数字记录文件,可以对运行设备的摩擦和冲击事件的 SWPT 进行定量分析。SWA 特征提取软件包括时域和频域两个特征提取软件。时域方法采用平均值、均方差、峰值、脉冲等指标分析波形,频域方法使用傅里叶变换技术分析波形。

3.1 时域特征提取

时域方法始于 SWPT 的数字记录文件。然后将数学变换应用到时间序列数据中,以表征多种波形特征,如脉冲幅度、持续时间和能量含量。

图 7 所示为 SWPT 时间历史数字记录文件的一部分。当取 10 kB 的采样速率(10 000 样本/s),持续时间为 2 s(即 20 kB 个数据点)时,以二进制格式写入,SWPT 数字记录文件的大小约为 40 kB。时域特征提取算法以大约 1 kB 的文件大小把这些数据压缩为多种波形特征。因此,这个时域特征提取过程把 40 kB 的数据转换为 1 kB 的信息,由 AI 算法用来做出明确的判定^[20]。

图 7 说明了 SWPT 的提取时域特征是如何计算的。此图显示了大约 1 个窗口的持续时间。窗口 W 是用户定义的,通常选择为对应于特征设备频率的周期。对于完整的数据记录, W 的长度是恒定的。记录最多为 10 s 的数据(即 100 000 个数据点)。数据记录长度“ R ”是由数据文件表示的总的持续时间。

从 SWPT 提取的特征取决于超过极限阈值 L 。此极限计算为每个窗口的 SWPT 瞬时振幅 A_i 的最低 10% 的正值的倍数。用于计算 L 的极限阈值因子(limit threshold factor, LTF)是全记录长度的常数,可由分析人员设置。

图 7 中,SWPD 表示所有连续 $A > L$ 的时间周期,即从 A_i 上升到阈值 L 到下次又下降到阈值 L 之间的时间段。

应力波峰值能量(stress wave peak energy, SWPE)为在 SWPD 期间,每个数据点($A_i - L$)的总和。即:

$$SWPE = \int_{t_b}^{t_c} (A_i - L) dt \quad (4)$$

式中: A_i 为 SWPT (应力波脉冲串)的瞬时振幅;SWPA 为在 SWPD 期间, A_i 的最大值;SWPA _{p} 为窗口 W_n 中 SWPT 的峰值振幅(SWPA); L 为用户定义的在窗口 W 期间高于 A 最小值的限制阈值; W 为用户定义的窗口 W_i ; R 为记录长度; $SWPE/W$ 为每个窗口的应力波峰值能量(窗口中所有个体 SWPE 的总和); SWE/W 为每个窗口的应力波能量(窗口中所有大于 0 数据点的 A_i 值的数值和); PEF/W 为每个窗口的峰值能量因子(peak energy factor, PEF),即 $SWPE/W$ 和 SWE/W 的比值; SWE/R 为每个记录的应力波能量,即在一个数据记录的所有窗口中发生的数据点的所有 A_i 值大于 0 的数值和; $SWPE/R$ 为每个记录的应力波峰值能量,即在一个记录中的所有个体 SWPE 值的总和; PEF/R (每个记录的峰值能量因子)为 $SWPE/R$ 和 SWE/R 的比值;

PEAKS/R 为每个记录的峰值,即在一个记录期间出现的 SWPT 峰值总数;SWPA/R 为每个记录的应力波峰值振幅,即记录中的最大 A_i 值。

计算 5 个窗口长度特征的 4 个统计参数 (S_1 、 S_2 、 S_3 和 S_4),用于完整记录。这些相同的 4 个统计参数(描述概率密度分布特征)计算记录中的所有个体 SWPA 值。这就产生了多个 SWPT 时域统计参数。统计参数 (S_1 、 S_2 、 S_3 和 S_4) 定义如下:

$$S_1 = \frac{1}{n} \sum_{i=1}^n (A_i - \text{mean})^3 \quad (5)$$

$$S_2 = \max \quad (6)$$

$$S_3 = \frac{(\max - \text{mean})}{(\max - \min)} \quad (7)$$

$$S_4 = \frac{\sigma}{\text{mean}} = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - \text{mean})^2}}{\frac{1}{n} \sum_{i=1}^n A_i} \quad (8)$$

3.2 频域特征提取

时域统计特征指标只能反映机械设备的总体运转状态是否正常,因而在故障诊断系统中用于故障监测趋势预报。要知道故障的部位、类型就需要进一步的做精密分析。频谱分析是一个重要的、最常用的分析方法^[21]。

运转机械设备产生的振动信号都是与转速相关的周期性信号。我们用最简单的正弦信号来表示:

$$x(t) = A \sin(\omega t + \theta) = A \sin(2\pi f t + \theta) \quad (9)$$

如果正弦信号的周期为 T ,则:

$$f = \frac{1}{T} = \frac{\omega}{2\pi} \quad (10)$$

满足狄利克雷条件的周期信号,均可以用正弦函数表达成傅里叶级数的形式:

$$x(t) = a_0 + \sum_{n=1}^{\infty} A_n \sin(n\omega_0 t + \theta_n) \quad (11)$$

$n = 1, 2, 3, \dots$

式(11)的物理意义表明周期信号可以表述为一个常数分量 a_0 和一系列正弦分量之和的形式。

$n = 1$ 的正弦分量称为基波,对应的频率 ω_0 称为该周期信号的基频。其他正弦分量按 n 的数值,分别称为 n 次谐波。

设 $x(t)$ 所包含的各成分中最高频率为 f_x ,快速傅里叶变换(fast Fourier transform, FFT)的最高分析频率 $f_c = (1.5 \sim 2)f_x$,比较合适的采样频率为 $f_s = 2f_c = (3 \sim 4)f_x$ 。

频率细化分析能使重点频谱区域得到较高的分辨率,提高分析的准确性。频率细化分析的基本思想是利用频移定理,对被分析信号进行复调制,再重新采样作傅里叶变换,即可得到更高的频率分辨率。如在频带 ($f_1 \sim f_2$) 范围内进行频率细化,此频带中心频率为 $f_0 = (f_1 + f_2)/2$ 。对被分析信号 $x(k)$ 进行复调制,得频移信号如

下:

$$y(k) = x(k) e^{-j2\pi kL/N} \quad (12)$$

式中: $L = \frac{f_0}{\Delta f}$, Δf 是未细化分析前的频率间隔。

根据频移定理, $Y(n) = X(n + L)$ 。相当于把 $X(n)$ 中的第 L 条谱线移到 $Y(n)$ 的零谱线位置。此时降低采样频率为 $(2N\Delta f/D)$ 。对频移信号重采样或对已采样数据频移处理后进行选抽,就能提高频率分辨率 D 倍,分析 $Y(n)$ 零谱线附近的频谱,也即 $X(n)$ 中第 L 条谱线附近的频谱。

D 是比例因子,又称为选抽比或细化倍数。

$$D = N \frac{\Delta f}{(f_2 - f_1)} \quad (13)$$

为了保证选抽后不至于产生频混现象,在选抽前应进行抗混滤波,滤波器的截止频率为采样频率的 $1/2$ 。

复调制细化包括幅值细化与相位细化。由于复调制过程中需通过数字滤波器,产生附加相移,所以一般要按滤波器的相位特性予以修正,才能得到真实的细化相位谱^[22]。

频谱分析子程序是用来产生幅度在 2 000 个频段的频率范围在 0 ~ 6 000 Hz 的输出信号。然后将每个功率谱密度文件进一步处理为多个频域特征。

频域特征提取过程从 SWPT 数字记录文件被一个 3 000 线 FFT 频谱分析模块处理开始。所有的应力波谱密度均由均方根值(root mean square, RMS)对 10 个个体时间记录进行平均得到,数据重叠率为 60%。频率分辨率为 2 Hz/线,频率范围在 0 ~ 6 000 Hz,时间历史文件为 2 s。

然后将每个应力波谱密度转换成一个表,列出前 2 000 个频率线内的每一个信号幅度。然后软件将频谱的前 2 000 行分成 100 段 20 线(40 Hz),计算所有 2 000 线的平均振幅,以及 100 段 40 Hz 频带中的最大振幅。然后,计算出 2 000 条谱线中各波段的最大值与 2 000 线平均值之比,并将之列为 2 000 行谱的 100 个波段“峰均比”(dB)。频域特征提取软件然后计算所有 2 000 线的最大幅度与所有 2 000 线的平均幅度之比。最后计算 2 000 行谱的 100 个波段中“峰均比”的标准偏差。100 个峰均比、2 000 线平均振幅、最大平均比和峰均比标准偏差被列为在频域中表征 SWPT 的多个特征。

4 基于多项式神经网络的数据融合

神经网络(neural network, NN)技术是模拟人类大脑而产生的一种信息处理技术,近年来得到了飞速发展。神经元按层次结构的形式组织,每层上的神经元以加权的方式与其他层上的神经元联接,采用并行结构和并行

处理机制,因而网络具有很强的容错性和自学习、自组织和自适应能力,能够模拟复杂的非线性映射。应力波分析的神经网络诊断方法是把应力波信号的时域和频域特征作为神经网络的输入,通过神经网络的学习训练自动形成故障类型与故障征兆的非线性映射关系来实现故障诊断^[23]。

多传感器数据融合技术是近几年来发展起来的一门多学科交叉的新技术,涉及到信号处理、概率统计、信息论、模式识别、人工智能、模糊数学等理论。神经网络的信号处理和自动推理功能以及强大的非线性处理能力,恰好满足了多传感器信息融合技术处理的要求。针对多传感器融合过程中异常测量数据的出现会降低数据融合质量的问题,可采用基于贝叶斯方法的多传感器数据融合方法,通过识别传感器间测量数据的不一致,在融合前剔除异常数据,提高数据融合的精度。还可以在贝叶斯方法上增加一项概率因子,以表征测量数据为非正常事件的概率。在某个传感器输出数据与其它传感器不一致时,增加的因子项具有增加后验分布方差的效果。该方法能有效识别传感器数据间的不一致,使融合精度得到进一步提高^[24]。

采用 3 层多项式方程的神经网络 (polynomial neural network, PNN) 的数据融合模型如图 8 所示。第 1 层神经元对应原始数据层融合。第 2 层完成特征层融合,并根据前一层提取的特征,做出决策。对于目标识别,输出层就是目标识别结论及其置信度。输出层对应决策融合,决策层的输入输出都应该为软决策及对应决策的置信度。




图 8 多输入的 3 层多项式神经网络

Fig. 8 Three layer polynomial neural network with multiple inputs

任何给定元素的输出都可以与原始输入变量一起输入到后续层中。网络从一层到另一层合成,直到网络模型停止改进。每层的合格输入和网络合成策略在一组规则和启发式中定义,这些规则和启发式都是合成算法的固有部分。

数值建模软件以统计建模、神经网络和人工智能研究为基础,是一种监督归纳学习工具。它把网络概念从神经网络和高级回归技术结合在一起,用于从输入输出值数据库中自动合成多项式网络模型。

网络建模数据库的所有数据是经特征提取处理后的应力波传感器的数据记录,如 SWPA、SWE 和 SWPD 等。必须忽略不相关的变量,同时保留有用的信息,否则模型将对不相关变量过于敏感,或是无法提取有实际意义的特征。模型可以了解有关数据信息与它的状态标签之间的对应关系。

通过使用随机数生成器,网络建模数据库被划分成训练和测试两组数据集。训练数据集为建模数据库的 75%,测试数据集为建模数据库的 25%。训练数据集用于对所有候选模型进行参数估计和建立分类器;测试数据集用于测试已经训练好的模型的分类能力,评估合成网络。建模参数用来调整网络结构或控制模型的复杂程度。

PNN 通过训练来识别从 SWPT 提取的特征的正常与异常模式,对应应力波数据进行自动分类以代表设备部件的健康状态。数值建模软件使用一套从 SWPT 提取的“特征”作为输入来综合评价 PNN。由于 SWPT 高信号噪声比分类比较简单,神经网络用少量的软件代码即可以实现。PNN 的开发过程如图 9 所示。

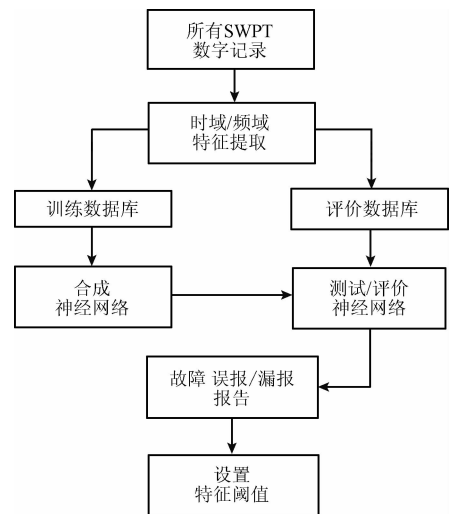


图 9 PNN 训练与评价

Fig. 9 PNN training and evaluation

表 2 所示为一个典型的故障误报/漏报报告,它被用来优化决策阈值,该阈值被应用到多项式神经网络输出(可以从 0 ~ 1 不等)。通过优化 PNN 迭代运行评价数据集,把故障误报/漏报制成表来作为决策阈值函数生成报告。

表2 决策阈值优化

Table 2 Decision threshold optimization

类别	事件	正确率/%	正确报警/%	正确排除/%	误报率/%	漏报率/%
决策阈值 0.05	10	80	70	10	20	20
决策阈值 0.10	10	80	70	10	20	20
决策阈值 0.15	10	90	70	20	10	10
决策阈值 0.20	10	90	70	20	10	10
决策阈值 0.25	10	90	70	20	10	10
决策阈值 0.30	10	90	70	20	10	10
决策阈值 0.35	10	90	70	20	10	10
决策阈值 0.40	10	100	70	30	0	0
决策阈值 0.45	10	100	70	30	0	0
决策阈值 0.50	10	100	70	30	0	0
决策阈值 0.55	10	100	70	30	0	0
决策阈值 0.60	10	90	60	30	10	10
决策阈值 0.65	10	70	40	30	10	30
决策阈值 0.70	10	70	40	30	30	30
决策阈值 0.75	10	70	40	30	30	30
决策阈值 0.80	10	70	40	30	30	30
决策阈值 0.85	10	60	30	30	40	40
决策阈值 0.90	10	60	30	30	40	40
决策阈值 0.95	10	60	30	30	40	40

特征提取和 PNN 软件模块可以对输入数据进行多种不同类型的分类,以实现全面而准确的状态监测。例如,一个多项式神经网络确定来自一个传感器的数据不正常,而另一个网络可以利用来自多个传感器的数据来确认是否存在差异。测试表明,在设备有故障的情况下运行 1 h 以内检测出齿轮或轴承损坏的概率大于 99.9%,在设备健康的情况下运行 1 000 h 的误报警概率小于 1/1 000。数据融合体系结构软件不仅能够准确地检测故障,还能找到故障,将故障源分离为齿轮或轴承,显示其劣化率,并估计剩余使用寿命。此外,为了保证早期故障检测的高概率和低误报率,需要进行置信度测试。数据融合架构将所有这些功能都结合在“专家系统”的规则中。

这个数据融合结构在作出诊断决定方面表现出较高的精确度,同时实现了高概率的问题检测 and 低概率的误报。是因为它具有以下两个关键特点。

1) 可以定义定量的精度要求。诊断指征的系统精度要求取决于每个单独指征的使用方式,以及错误可能对操作安全、任务可靠性、可用性和生命周期成本造成的不同后果;

2) 具有易于调整的数据融合体系结构。为了按系统要求调整这个数据融合结构的精确性,只需要 3 个调整参数,即每个测量决策网络的决策阈值,置信度测试中的 X 和 N 参数。

每一个 PNN 都是作为一个单独的软件对象实现的。随着更多的数据可用于训练,单个网络可以更新和替换,以提高其诊断准确性。每个更新的 PNN 将根据训练和评价数据的性能结果调整其阈值。然后调整置信检验参数(X 和 N),以满足系统决策精度要求。以这种方式,数据融合体系结构中的软件对象可以很容易地更新和调整,而不需要修改定义整个数据融合体系结构的软件代码。

5 实际应用效果

某大型钢铁企业的轧钢厂每年生产两百多万吨扁钢,以前轧辊设备经常由于故障造成突然停机维修,而一次意外故障停机可造成工厂每天几百万甚至上千万元的损失。因此迫切需要重型轧钢设备在不出现意外停机的条件下 24 h 平稳运行,最小化正常停机次数,并在计划停车维修时的停机时间尽可能最短。这就需要一种设备状态早期监测分析系统,能在故障和意外发生前,检测到其大型轧钢轮辊可能存在的磨损、磨擦或内应力问题。工厂调研了行业中采用振动分析等其他技术的应用效果后,提出了比这些应用案例更高的要求。

在采用了基于应力波分析的状态监控与故障预测系统后,能够在设备停机故障发生之前的早期就探测到重型轧辊机内部发生的磨损,摩擦或应力问题的迹象,为设备运行提供精确的诊断信息,帮助工厂在设备严重损坏或故障发生之前对生产设备做出正确、必需的维修措施。

应力波传感器安装在重型轧辊机上,与每个轴承相连接,同时承受高温和剧烈振动,仍然能够满足其功能要求。该检测和分析系统从应力波传感器采集信息,跟踪和记录测量结果,并使用位于中控室的服务器对这些信息进行分析,生成设备健康诊断报告。该系统具有对运行状况的实时在线显示,并跟踪和记录可量化的故障变化过程,实现了工厂可以随时随地对设备性能指标进行访问。

由于系统可以检测到轴承或齿轮箱的轻微故障迹象,加上系统的精确定位故障部件的能力,即可形成针对轧钢设备早期磨损的报告。管理人员可以提前 6 个月就明确预知到设备内部轴承或齿轮箱的具体故障部位,有充裕的时间来制定轧钢设备的维护或维修计划。工厂不再需要预先订购备品备件,减少了近两千万资金和几百平方米库存场地的长期占用。公司还能够更好地制定特殊定制零件的订货计划,这一类零件如果故障停机才匆

忙购买的话,即使多花数十万元的额外赶工费用马上排产,也仍然需要一定的生产周期才能交货。

应力波分析的解决方案已经帮助工厂降低了成本,提高了设备运行时间,以及具有更有效的管理设备维修流程和评估供应商的表现。通过改进设备维护计划和优化业务流程,大大提高了生产力,并很快实现了投资回报。

运行结果表明,基于应力波分析的状态监控与故障预测技术是检测设备运行条件变化的最好工具。与目前主流应用的其他监测方式相比,具有以下明显优势:

1) 应力波分析可以提供设备趋势化参数,使运行人员了解设备损伤程度和恶化速度,较好地预知损坏将造成停产的时间。可以提前实施计划检修,延长设备寿命,并避免停产造成的巨大经济损失;

2) 与振动、润滑等分析技术相比,应力波技术在检测轴承和齿轮损坏、轴倾斜、润滑效果下降、密封损坏等设备问题时更具有预测性的状态监测解决方案。

3) 应力波技术是基于超声波的,可以检测到最早阶段的轻微损伤迹象。而此时温度或振动信号尚未上升,采用其他技术还不能检测到。

4) 应力波技术不仅可以检测设备故障,还可以确定此故障是否与生产流程有关,以及是否受操作过程影响。因此还可以为优质高效的生产控制流程提供有效的设备运行基础数据,为优化生产作业提供数据分析。

6 结 论

应力波分析是测量旋转机械运动部件间摩擦、冲击和动态载荷传递的最先进的仪器技术。安装在机器轴承和齿轮外壳上的传感器检测通过机器结构传输的应力波,传感器中的压电晶体将应力波振幅转换成电信号,然后在模拟信号调节器中用高频带通滤波器进行放大和滤波,去除不需要的低频声和振动能量。特征提取软件智能地将大量的记录数据压缩成可管理的信息文件,用于训练和评估 PNN 和数据融合结构。该软件能够读取从频率分布分析系统中提取并解压的表示 SWPT 时间波形的批处理文件,对每个文件执行特征提取,包括可视化提取数据的功能,以及将提取的数据导出到 Excel 电子表格的实用程序中。

基于应力波分析的状态监测和故障预测为生产、运营和维护管理提供了在流程和系统管理的各个方面做出明智、主动的决策能力。它不仅可以帮助提醒用户设备存在异常的事实,而且还可以通过基于浏览器的用户界面、流程控制和历史系统的 MODBUS/TCP 接口以及电子邮件通知向相应的管理、操作和维修人员提供详细的诊断报告。

基于应力波分析的状态监控与故障预测技术是检测设备运行条件状态的最好工具。它采用先进的仪器测量与分析技术实时检测和分析运行设备的摩擦、机械冲击和动态载荷,结合物联网、云计算、数据挖掘和人工智能等科学技术的应用,能实时远程监控设备运行情况,更早地预测故障,向客户定期提供设备健康诊断分析报告,帮助企业提高生产安全性、降低成本、实现更高的运行时间和更好的生产效率。

由于本系统具有可调整的数据融合体系结构,因此也可以很容易地与其他任何连续可变诊断参数(振动、温度、压力等)的输入进行应用组合,形成分布式感知和监测系统,对全厂设备进行集中诊断和管理。它还可以结合对设备维护规划模型和系统调度优化策略的进一步研究,实现现代企业智能制造系统全生命周期健康管理。

参考文献

- [1] 彭宇,刘大同,彭喜元. 故障预测与健康管理技术综述[J]. 电子测量与仪器学报,2010,24(1):1-9.
PENG Y, LIU D T, PENG X Y. Technical review of prognostics and health management[J]. Journal of Electronic Measurement and Instrument, 2010,24(1): 1-9.
- [2] 夏虹,刘永阔,谢春丽. 设备故障诊断技术[M]. 哈尔滨:哈尔滨工业大学出版社,2010.
XIA H, LIU Y K, XIE CH L. Equipment fault diagnosis technology[M]. Harbin: Harbin Institute of Technology press, 2010.
- [3] 振动、冲击、噪声国家重点实验室. 机械设备状态监测和故障诊断技术[M]. 上海:上海交通大学,2015.
National Key Laboratory of vibration, shock and noise. Mechanical equipment condition monitoring and fault diagnosis technology[M]. Shanghai: Shanghai Jiao Tong University, 2015.
- [4] 陈长征,孙长城,费朝阳,等. 基于应力波的低速滚动轴承故障诊断新方法研究[J]. 机械强度,2007,29(6):885-890.
CHEN CH ZH, SUN CH CH, FEI CH Y, et al. Study on a new method for fault diagnosis of low speed rolling bearings based on stress wave [J]. Journal of Mechanical Strength, 2007,29(6): 885-890.
- [5] SADRI A, GEBSKI P, SHAMELI E. Refractory wear and lining profile determination in operating electric furnaces using stress wave non-destructive testing[C]. Proceedings of the 12th International Ferroalloys Congress, 2010: 881-890.
- [6] KWON Y D, LEE D S, CHO W G, et al. Stress wave analysis of PZP with coating layer using finite element method [J]. Material Research Innovations, 2016, 19(Suppl. 8): 370-377.
- [7] 孟凌凌,尹峰,华晓萍,等. 嵌入式桩基动测系统的设计[J]. 国外电子测量技术,2006,25(4): 25-28.

- MENG L L, YIN F, HUA X P, et al. Design of an embedded pile dynamic integrity tester[J]. Foreign Electronic Measurement Technology, 2006,25(4): 25-28.
- [8] YAN N. Numerical modeling and condition assessment of timber utility poles using stress wave technique[D]. Sydney: University of Technology, 2015.
- [9] LI J, ZHAO M J, RONG Y. Study on attenuation characteristics of stress wave in joint rock based on damage mechanics[C]. The Second International Conference on Mechanic Automation and Control Engineering, 2011: 3485 - 3488.
- [10] ELFORJANI M, MBA D. Detecting AE signals from natural degradation of slow speed rolling element bearings[C]. Proceedings of the Second International Conference on Condition Monitoring of Machinery in Non-Stationary Operations, 2012: 61-68.
- [11] 王礼力. 应力波基础[M]. 北京:国防工业出版社, 2005.
WANG L L. Foundation of Stress waves [M]. Beijing: National Defense Industry Press, 2005.
- [12] KOLSKY H. Stress waves in solids[M]. London: Oxford University Press, 1953.
- [13] 陈乾堂. 基于应力波传播理论的齿轮动应力分析[D]. 西安:西北工业大学, 2006.
CHEN Q T. Dynamic stress analysis of gear based on stress wave propagation theory[D]. Xi'an: Northwestern Polytechnic University, 2006.
- [14] RINEHART J S. Stress transients in solids[M]. New Mexico: Santa Fe, 1975.
- [15] NOWACHI W K. Stress waves in non-elastic solids[M]. London: Pergamon Press, 1978.
- [16] 郭伟国,李玉龙,索涛. 应力波基础简明教程[M]. 西安:西北工业大学出版社, 2007.
GUO W G, LI Y L, SUO T. Concise tutorial of stress wave foundations[M]. Xi'an: Northwestern Polytechnic University Press, 2007.
- [17] WRIGHT C. Proactive system operation and maintenance[C]. Stress Wave Systems Technology, 2011:1-4.
- [18] 陈果. 一种实现结构风险最小化思想的结构自适应神经网络模型[J]. 仪器仪表学报, 2007, 28(10): 1874-1879.
CHEN G. Structure self-adaptive neural network model realizing structural risk minimization principle[J]. Chinese Journal of Scientific Instrument, 2007, 28(10): 1874-1879.
- [19] 洪涛,邱畅啸,黄志奇. 基于PCA相似系数与SVM的涡轮泵故障检测算法[J]. 电子测量与仪器学报, 2012,26(6): 514-520.
HONG T, QIU CH X, HUANG ZH Q. Turbo pump fault detection algorithm based on PCA similarity coefficient and SVM[J]. Journal of Electronic Measurement and Instrument, 2012,26(6): 514-520.
- [20] STEVE S. Aircraft engine stress wave analysis report[R]. Sciencetech, 2015.
- [21] 张键. 机械故障诊断技术[M]. 北京:机械工业出版社, 2014.
ZHANG J. Mechanical fault diagnosis technology[M]. Beijing: China Machine Press, 2014.
- [22] 卢文祥,杜润生. 机械工程测试、信息、信号分析[M]. 武汉:华中科技大学出版社, 2014.
LU W X, DU R SH. Measurement information signal analysis in mechanical engineering[M]. Wuhan: Huazhong University of Science and Technology Press, 2014.
- [23] 梁武科,彭文季,罗兴铸,等. 水电机组振动故障诊断的人工神经网络选择研究[J]. 仪器仪表学报, 2006, 27(12): 1711-1714.
LIANG W K, PENG W J, LUO X Y, et al. Research on artificial neural network selection of vibrated faulty diagnosis of hydraulic generating set[J]. Chinese Journal of Scientific Instrument, 2006, 27(12): 1711-1714.
- [24] 贾海艳,苏滢滢. 异常情况下基于贝叶斯的多传感器融合方法[J]. 电子测量技术, 2013,36(8): 104-107.
JIA H Y, SU Y Y. Multi-sensor fusion method based on Bayesian in singular conditions[J]. Electronic Measurement Technology, 2013,36(8): 104-107.

作者简介



吴天舒,2011年于重庆邮电大学获得学士学位,现为重庆大学博士研究生,主要研究方向为云计算、分布式计算、数据挖掘。
E-mail: 723412117@qq.com

Wu Tianshu received his B.Sc. degree from Chongqing University of Posts and Telecommunications in 2011. Now he is a Ph.D. candidate in Chongqing University. His main research interests include cloud computing, distributed computing and data mining.



吴朋,1983年于合肥工业大学获得学士学位,分别在2002年和2006年于重庆大学获得硕士和博士学位,现为重庆川仪自动化股份有限公司教授级高级工程师、博士生导师,主要研究领域为传感器、智能化仪表和分散型控制系统。
E-mail:wupeng@cqcy.com

Wu Peng received his B.Sc. degree from HeFei University of Technology in 1983, received his M.Sc. and Ph.D. degrees both from Chongqing University in 2002 and 2006, respectively. Now he is a professor, senior engineer and Ph.D. supervisor in Chongqing Chuanyi Automation Co., Ltd. His main research interests include sensor, intelligent instrument and distributed control system.