

风电机组传动系统振动监测研究进展*

汤宝平, 罗雷, 邓蕾, 韩延

(重庆大学机械传动国家重点实验室 重庆, 400030)

摘要 振动监测是当前风电机组传动系统状态监测的主要手段。首先,分析了风电机组传动系统振动监测策略和各部件振动特征提取流程,重点介绍了边频带能量因子、阶次谱边频带能量比等振动特征趋势指标;然后,分析指出解决现役风电机组因传动系统故障导致巨大经济损失的关键是进行风电机组传动系统早期故障预示,重点介绍了泛化流形学习的风电机组传动系统早期故障预示方法;最后,从系统架构、数据采集配置及监测分析方法等方面分析了现有的风电机组传动系统振动监测系统的功能与特点,指出了基于多源信息融合的大数据预测分析与智能维护将是风电机组健康管理的重要发展趋势。

关键词 风电机组传动系统; 振动监测; 特征提取; 早期故障预示; 大数据

中图分类号 TH17

引言

风能作为一种无污染的可再生资源,成为各国争相发展的领域之一。但风电机组安装在野外几十米的高空,在变风载、大温差等恶劣、变化的工况下,风电机组使用寿命受到极大的影响,尤其是风电机组的主轴、齿轮箱等传动部件在交变载荷的作用下很容易出现故障,造成机组停机。较之其他故障,风电机组传动系统故障导致机组停机时间最长^[1],严重影响发电量,造成经济损失,而且安装维护相当困难,维护费用高,使得运营成本增加,严重损害风力发电的经济效益。另一方面,随着高速发展时期安装的风电机组开始逐步走出质保期,一个巨大的风电运维市场正在逐渐显现。因此,开展风电机组传动系统状态监测,进而进行基于状态的早期故障预示和健康管理就显得非常迫切和必要。

风电机组传动系统状态监测技术通常有振动监测^[2-4]、声发射(应力波)监测^[5-6]、油液监测^[7-8]等。较之其他信号,风电机组传动系统振动信号包含的状态信息更丰富,对传动部件异常更敏感,在传动部件早期故障预示上有明显优势,并且振动信号容易解释,也更容易对故障进行定位。因此,目前风电机组传动系统状态监测多采用振动监测技术。

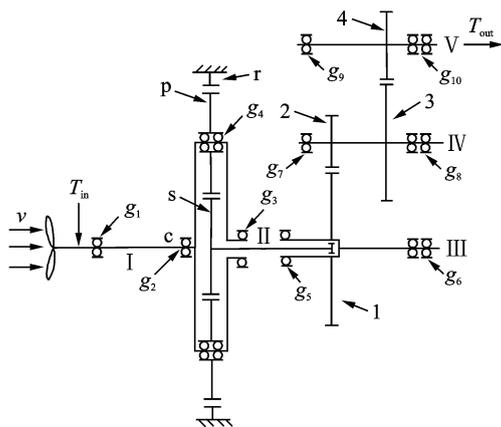
笔者介绍了风电机组传动系统振动监测研究进展,主要包括风电机组传动系统振动监测策略、常用的振动特征趋势指标、基于振动的早期故障预示以及振动监测系统等,在此基础上展望风电机组传动系统振动监测技术的发展趋势。

1 风电机组传动系统振动监测策略

风电机组传动系统主要包括叶片、主轴、增速齿轮箱和发电机等部件。增速齿轮箱结构复杂,采用多级齿轮结构,如图 1 所示。其结构采用一级行星和两级平行轴传动,其中行星级采用齿圈固定、行星架输入和太阳轮输出,所有齿轮均为斜齿轮。一般也分为低速级、中间级和高速级 3 级。低速级是结构紧凑且坚固的高转矩行星齿轮,中间级和高速级为平行轴圆柱齿轮。

风电机组叶片捕获风能,经过传动系统后将能量传递给发电机产生电能,实现风能向电能的转变。因传动系统结构复杂,传动比大,转速不稳定,载荷变化大,其振动特征时变性强,齿轮、轴承及轴等容易出现故障。因此,风电机组传动系统振动监测主要使用加速度传感器和转速计,围绕传动系统关键位置进行布置,典型的振动监测点分布如表 1 所示。由于风电机组增速齿轮箱的高传动比,主轴端与发

* 国家自然科学基金资助项目(51675067,51375514);重庆市重点产业专项资助项目(cstc2015zdcy-ztxx70012)
收稿日期:2017-02-22;修回日期:2017-05-20



1-中间级主动齿轮;2-中间级被动齿轮;3-高速级主动齿轮;4-高速级被动齿轮; T_{in} -低速端输入转矩; T_{out} -高速端输出转矩;s-太阳轮;p-行星轮;c-行星架;r-内齿圈; g_i -滚动轴承代号; i -滚动轴承编号($i=1,2,\dots,10$)

图1 风电增速齿轮箱结构

Fig. 1 Structure sketch for wind turbine gearbox

电机端的转速差异很大,监测系统通常配置低频和标准两种加速度传感器以适应最佳频率响应范围。加速度传感器的安装可采用螺纹连接或强力胶,保证传感器与风电机组表面的紧密可靠连接。电涡流转速传感器安装一般采用专用夹具,将传感器固定在高速轴刹车盘表面 $2\sim 4\text{ mm}$ 处,通过扫描高速轴刹车盘上的螺母,感知距离变化来产生转速脉冲,获取齿轮箱高速轴的转速。

表1 典型的振动监测点分布

Tab. 1 Typical distribution of monitoring point

测点	测量对象	测试方向	传感器类型
1	前主轴轴承	径向	低频加速度传感器
2	前主轴轴承	轴向	低频加速度传感器
3	后主轴轴承	径向	低频加速度传感器
4	齿轮箱低速轴	径向	低频加速度传感器
5	齿轮箱行星齿轮	径向	标准加速度传感器
6	齿轮箱中间轴	径向	标准加速度传感器
7	齿轮箱高速轴	径向	标准加速度传感器
8	发电机前端轴承	径向	标准加速度传感器
9	发电机后端轴承	径向	标准加速度传感器
10	主轴	径向	转速计(可选)
11	齿轮箱高速轴	径向	转速计

风电机组传动链各部件振动特征频率与传动链的转速和各部件结构参数密切相关,传动链振动特征提取流程如图2所示。将测得转速信息结合传动链参数计算各部件特征频率,振动加速度通过信号分析方法获得特征频谱,采用特征提取方法从特征频谱中提取特征频率,计算特征指标用于趋势分析,

从而实现部件级的状态监测。常用的振动信号处理方法包括基于快速傅里叶变换的特征提取和基于阶次谱的特征提取等,有时还需进行包络谱分析。

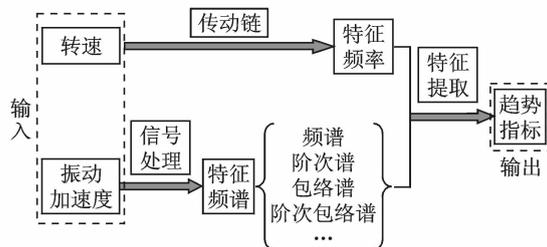


图2 风电机组传动链振动特征提取流程

Fig. 2 Feature extraction process of wind turbine drive chain

2 常用的振动特征趋势指标

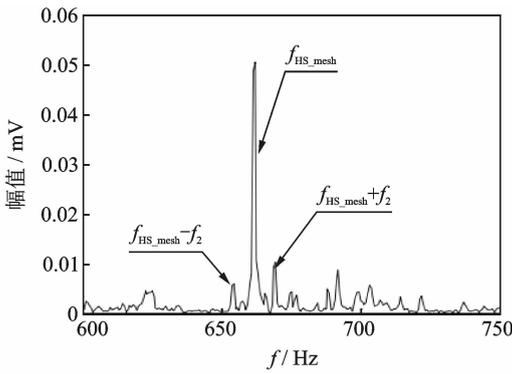
振动特征趋势指标可将海量风电机组传动系统振动数据指标化,直观展现数据中蕴藏的风电机组传动系统状态信息,其随时间的变化趋势可反映风电机组传动系统运行状态的变化过程。对这些特征指标设定合理的阈值,可在风电机组传动系统状态异常时及时报警。因此,确定恰当的风电机组传动系统状态监测振动特征趋势指标,并根据振动特征趋势指标进行趋势分析是风电机组传动系统状态监测的关键。

2.1 边频带能量因子

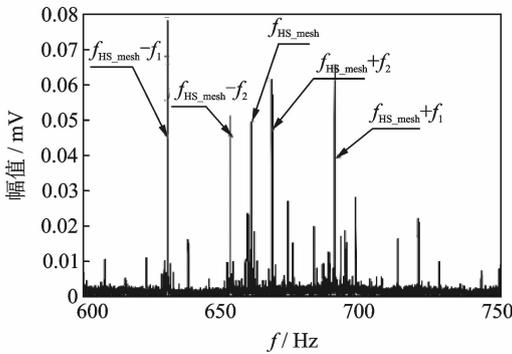
在平稳工况下,某些振动信号的时域统计特征可以作为振动特征趋势指标,如振动信号有效值、峭度及峰值因子等,但是交变载荷作用下的风电机组传动系统振动时域统计特征受工况影响大,其变化趋势单调性差、波动大,根据这些特征指标来进行状态监测很容易产生误报警。

不同传动件的振动特征不尽相同。对于齿轮传动来讲,其频谱所表现的最突出的振动特征是其啮合频率及其谐波以及由调制现象产生的边频带,不同故障程度下齿轮啮合边频带变化^[9]如图3所示。

健康状态下齿轮的边频带数量少且幅值比中心啮合频率小很多,随着健康状态退化,边频带数量和幅值都会随之增加。因此,边频带对齿轮健康状态有很强的预示作用,基于此故障机理提出的边频带能量因子(sideband power factor,简称SBPF)指标^[10]可以更好地用于齿轮的健康趋势监测,其计算如下



(a) 轻微故障状态
(a) Slight fault status



(b) 严重故障状态
(b) Serious fault status

图 3 不同故障程度下的齿轮啮合边频带

Fig. 3 The sidebands of gear meshing frequency within different fault degree

$$SBPF = PSA(2Xf_{mesh}) + \sum_{i=-5}^{+5} PSA(SB_i) \quad (1)$$

其中: $PSA(2Xf_{mesh})$ 表示功率谱中齿轮啮合频率的二次谐波幅值; $PSA(SB_i)$, $i = \pm 1, \pm 2, \pm 3, \pm 4, \pm 5$ 表示啮合频率前 5 阶边频带能量幅值。

美国 National Renewable Energy Laboratory 研究了变负载条件下平行齿轮传动结构中断齿及早期齿面磨损情况的边频带能量因子变化趋势, 如图 4^[10] 所示。从图上可以看出, 边频带能量因子对齿轮健康退化非常敏感, 呈现指数发展趋势, 特别是在风机功率输出较大时, 变化更加明显。可见边频带能量因子对平行齿轮传动中齿轮退化趋势和早期故障预示效果显著。由于行星齿轮传动结构的低机械振动传递特征和更加复杂的啮合情况, 边频带能量因子指标在行星齿轮传动中的效果还有待进一步研究证实。

2.2 阶次谱边频带能量比

风电机组长时间在变速状态下运行, 传动系统各部件特征频率呈现时变特征, 导致频谱分析时频

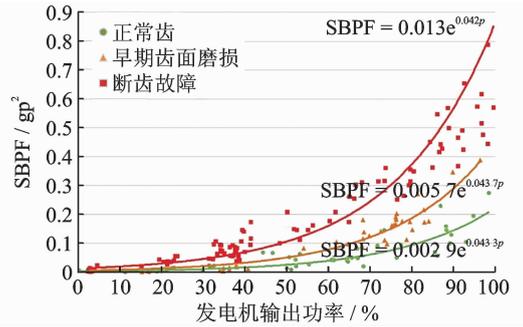
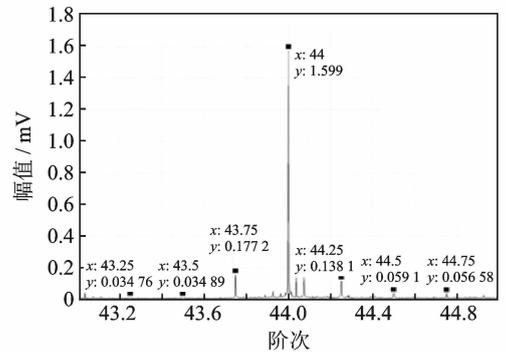


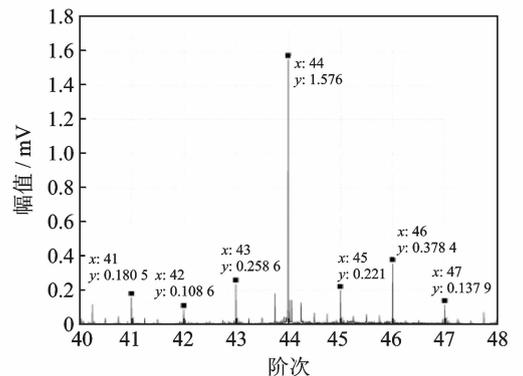
图 4 变载条件下 SBPF 随齿轮性能退化趋势

Fig. 4 Development trend of SBPF index with gear performance degradation under variable load

率成分模糊, 为特征提取带来困难。采用阶次重采样可将非平稳信号转速无关化, 把时域非平稳信号转换为角域平稳信号, 再进行傅里叶分析得到阶次谱, 目前阶次谱分析方法被风电机组振动监测系统普遍采用。不同故障程度下的齿轮啮合阶次谱边频带变化^[9]如图 5 所示。



(a) 轻微故障状态
(a) Slight fault status



(b) 严重故障状态
(b) Serious fault status

图 5 不同故障程度下的齿轮啮合阶次谱

Fig. 5 The order spectrum of gear meshing under different fault status

美国 GE 公司能源研究团队在阶次重采样基础上, 将阶次谱和边频带分析相结合, 提出了阶次谱边

频带能量比 (sideband energy ratio, 简称 SER) 指标^[9], 阶次谱前 6 阶边频带幅值之和与齿轮中心啮合频率 (或啮合频率二次谐波) 幅值的比值即是边频带能量比指标, 其计算如下

$$SER = \frac{\sum_{i=1}^6 PSA(SB_i)}{PSA(1Xf_{mesh})} \quad (2)$$

其中: $PSA(1Xf_{mesh})$ 表示功率谱中齿轮中心啮合频率 (或啮合频率二次谐波) 幅值; $PSA(SB_i)$, $i=1\sim 6$ 表示啮合频率前 6 阶边频带能量幅值。

阶次谱边频带能量比指标可以克服变转速状态下齿轮特征频率不清晰的问题, 可用于监测齿轮状态退化过程。健康状态下齿轮的边频带能量比较小, 通常小于 1。随着齿轮性能退化, 边频带能量比将逐渐增大。阶次谱边频带能量比指标已被用于美国 GE Bently Nevada 团队研发的 ADAPT. wind 风电机组状态监测系统中。变转速下某风电机组断齿故障三维瀑布图及阶次谱边频带能量比随故障的变化趋势^[11] 如图 6 所示。

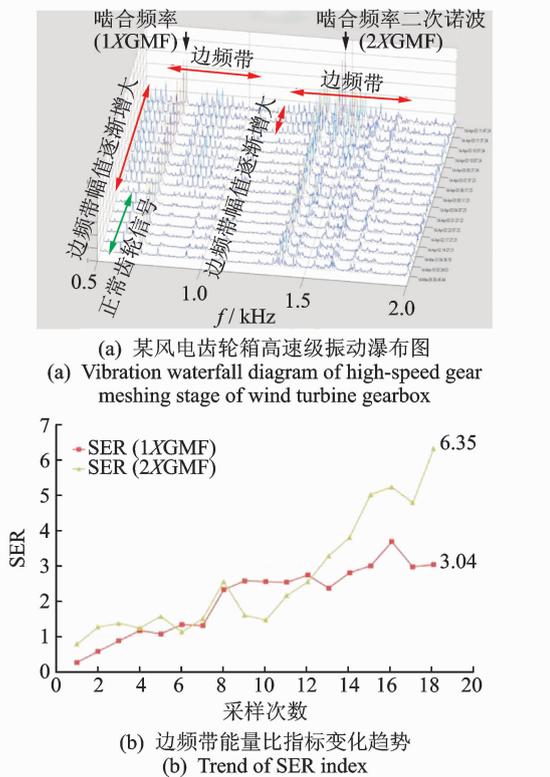


图 6 SER 指标随齿轮性能退化的发展趋势

Fig. 6 Trend of SER index with gear performance degradation

2.3 基于阶次包络解调的轴承振动特征

当滚动轴承出现故障时, 在滚动体相对滚道的旋转过程中, 常会产生有规律的冲击脉冲, 能量较大

时, 激励起外环固有频率, 形成以外环固有频率为载波频率、以轴承通过频率为调制频率的固有频率调制振动现象。对轴承故障振动信号中的周期性冲击成分进行提取和解调分析是轴承特征提取的关键。

轴承故障冲击为宽带冲击, 其激发的谐振响应在频率上高于其他谐振响应, 但是幅值更微弱, 很容易淹没在风电机组强噪声环境中。因此, 轴承振动特征提取必须建立在频率成分清晰的高分辨率频谱上, 将轴承的高频低幅信号从包含齿轮啮合频率、轴转频等大幅值成分的信号中分离出来, 再进行特征提取。为此, 采用阶次重采样将风电机组振动非平稳信号转化为平稳信号, 通过带通滤波将包含轴承高频特征的部分提取出来, 然后对提取出的信号进行包络解调得到包络信号, 再进行快速傅里叶变换, 实现轴承振动微弱特征提取^[10]。基于阶次包络解调的轴承振动特征提取流程如图 7 所示。

综上所述, 有效表征风电机组传动系统各部件状态发展趋势的特征指标是当前风电机组振动状态监测的重点。不同部件的故障机理不同, 某个特征指标并非对所有部件都适用, 不同部件采用的特征指标应有所不同。然而, 从风电机组齿轮箱上测得的振动信号包含了齿轮、轴承及齿轮箱中其他振源的响应, 如何将这些振动信号进行分离, 对能否有效地提取部件级的特征指标至关重要, 值得深入研究。

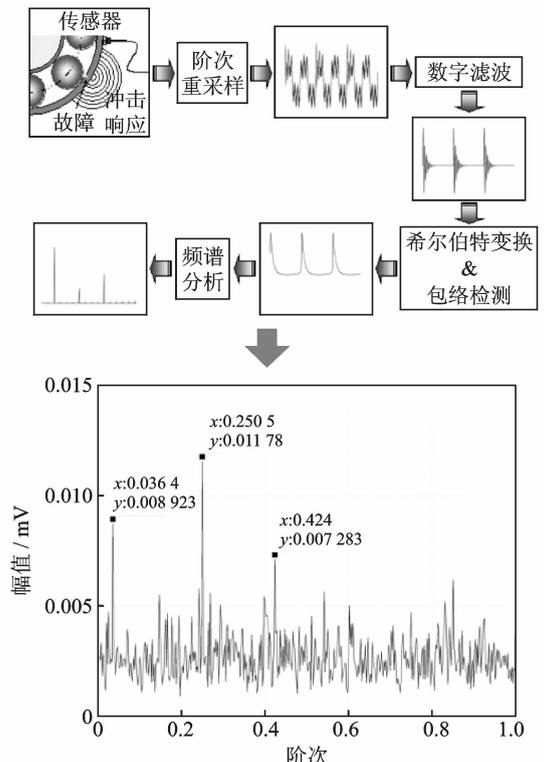


图 7 轴承振动阶次包络解调流程

Fig. 7 Vibration enveloping order demodulation process of bearing

3 风电机组传动系统早期故障预示

在风电机组传动系统早期故障出现阶段,即故障萌芽即将出现、刚刚出现或者故障程度尚轻微时,及时准确地予以辨识和预示,并据此指导保养和维修工作,及时采取措施,防止造成严重损失,可提高风电机组运行的可靠性,延长其使用寿命。

风电机组传动系统早期故障具有以下特点:首先,由于风电机组运行条件恶劣,环境影响因素多,振动信号受噪声干扰大;其次,早期故障源于正常状态,故障特征微弱,且由于转速不稳定、负载交变,其故障特征呈现非线性特点;再次,风电机组传动系统早期故障随着风电机组传动系统的服役历程逐渐演变凸现,早期故障特征处于动态发展变化之中,需要动态特征提取;最后,风电机组传动系统的振动监测才开始起步,早期故障样本缺乏系统的、长期的收集,早期故障样本稀缺。较之典型故障诊断,这些特点使得风电机组传动系统早期故障预示难度更大、要求更高。

目前,针对风电机组传动系统早期故障预示,国内外主要采用了基于信号处理的早期故障预示方法和基于模型的早期故障预示方法。贺王鹏等^[12]针对风电机组轴承提出了周期稀疏导向超小波构造方法,提取发电机轴承发生局部损伤后诱发的周期性非平稳冲击特征。Sun等^[13]采用多小波自适应分块阈值降噪方法,在有效消除噪声干扰的同时准确提取故障特征。孙自强等^[14]针对风电机组齿轮早期故障振动信号被噪声调制污染、信噪比低及难以识别问题,提出基于混沌和取样积分技术结合的风电机组齿轮早期故障特征提取方法。Wang等^[15]采用集合经验模态分解与独立成分分析相结合的方法,在不需要转速信息与轴承冲击频带等先验信息情况下,实现强噪声背景下风电机组早期故障预示。彭进等^[16]针对风力发电机组轴承故障振动信号的高噪声、非平稳特性,通过集成经验模态分解与峭度-相关系数准则提取多特征量,结合支持向量机实现风电机组轴承早期故障识别。但是,基于信号处理的早期故障预示方法主要侧重微弱信号的提取,不能很好地实现早期故障预示。由于风电机组传动系统的正常、异常和故障等状态都处于动态的连续发展变化之中,基于模型的早期故障预示方法使用固定静止的模型来辨识和预示早期故障,这样的知识推广方式无法适应早期故障过程的非线性时变性,常常导致误判和漏判。

流形学习是一种非线性数据降维方法,可有效地挖掘非线性数据的内在分布规律和本质信息,已很好地应用于机械设备故障诊断中^[17-18]。文献^[19-23]针对风电机组传动系统早期故障的非线性时变特点,在研究和拓展流形学习的基础上,将流形学习维数约简方法与信号处理方法、支持向量机等模式识别方法相结合,提出了基于泛化流形学习的风电机组传动系统早期故障预示方法(见图8),包括基于无监督流形学习的非线性信号消噪方法、基于监督流形学习的微弱特征提取方法、基于增殖流形学习的早期故障动态特征提取以及基于参数优化的小子样早期故障模式识别方法,有效实现了风电机组传动系统的早期故障预示。

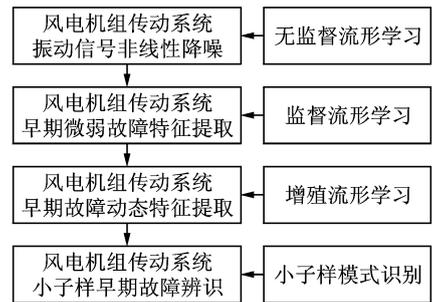


图8 泛化流形学习的早期故障预示方法流程

Fig. 8 Incipient fault prediction based on generalization manifold learning

上述的早期故障预示方法在实际应用中需要构建早期故障数据库。由于风电机组成本较高,特别是齿轮箱的技术成本较高,风场和生厂商都不会故意去制造某些故障来构建相关的早期故障库,导致风电机组传动系统早期故障样本数据十分稀缺,需开展风电机组传动系统早期故障信号收集工作,积累早期故障样本,为实际应用提供数据支持。如美国 National Wind Technology Center 在美国能源部支持下,联合了 17 家单位,正在建立风电机组传动系统早期故障数据库。

4 风电机组传动链振动监测系统

目前,国内外推出了一些风电机组传动链振动监测系统。国外典型的振动监测系统包括瑞典 SKF WindCon 状态监测系统、以色列 WSL WindSL 状态监测系统、美国 GE Bently Nevada 公司的 CBM 状态监测系统、丹麦 Brüel & Kjær 公司的 Brüel & KjærVibro 状态监测系统等^[24]。国内典型的振动监测系统如重庆大学 CQ_WindCon 状态监测系统^[25]、威锐达 WindCMS、VibAnalyzer 系统、容知 MOS3000

状态监测系统及视为 MDiag 设备健康诊断系统等。这些振动监测系统虽各具优势和特色,也存在许多共性之处。下面将从系统架构、采集配置及监测分析方法等方面就系统共性之处做简要介绍。

4.1 系统总体架构

当前风电机组传动链振动监测系统普遍采用 C/S 和 B/S 混合系统架构,以实现灵活的监测和访问。风电现场的局域网内以 C/S 架构提供现场实时数据浏览、状态监测与预警、故障诊断等功能。现场人员可以在控制中心集中监视和管理整个风场的风电机组,发现问题可及时分析并应对。B/S 架构通过互联网为远程用户提供远程访问功能,借助于互联网实现跨平台、多用户的监测模式,为风电机组的网络化状态监测与管理提供极大的便利。典型风电机组传动链振动监测系统架构^[25]如图 9 所示。

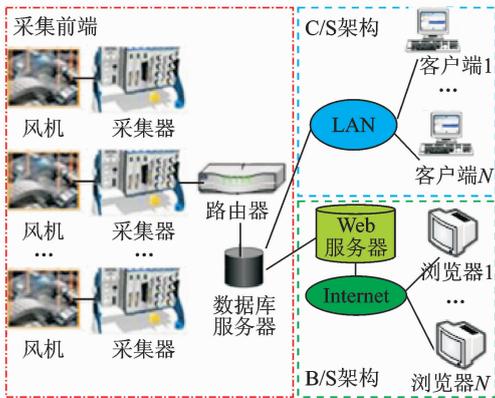


图 9 风电机组传动链振动监测系统架构

Fig. 9 Architecture of wind turbine drive chain monitoring system

4.2 系统采集配置

在对风电机组传动链振动监测之前,还必须对系统进行相关采集配置,通过振动监测系统软件、采集硬件与风电机组传动链的一一对应关系,实现数据有序采集和分析。数据采集配置通常通过建立风场-风机-测点的层级视图来组织整个振动监测过程。对于每台风电机组,需要定义机组基本信息如机组名称、机组编号、机组型号及主控 IP 等,还需定义传动系统的主要部件,包括主轴、齿轮及轴承等参数信息,建立传动链模型,结合转速信息即可计算缺陷频率以供后续分析所用。对于每个测点,需要配置测点信息如测点描述、采样频率、采样长度、采样间隔及灵敏度等以便将数据正确采集到系统中,并设置对应报警阈值。用户通常还可以针对感兴趣的内容自定义测量定义,包括定义名称、测量位置、信号类型及信号带宽等,实现对重点部件、重点频带的

跟踪观察和分析。典型的振动监测系统数据采集配置流程如图 10 所示。

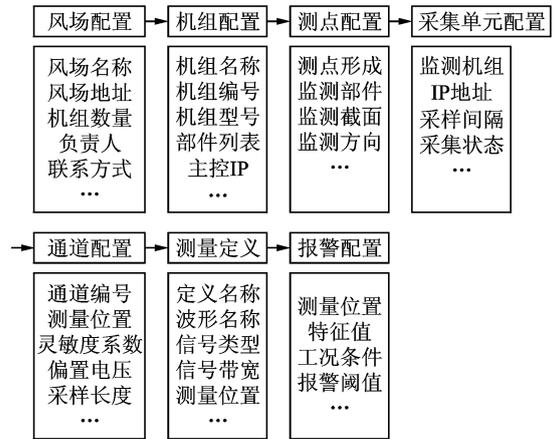


图 10 典型振动监测系统数据采集配置流程

Fig. 10 Data acquisition configuration flow of typical vibration monitoring system

4.3 监测分析方法

时域信号分析是最基本的信号分析方法,直接通过时域波形可查看信号形状,分析信号周期特性、冲击特性等特征,并可通过计算时域特征量如峰值、峰峰值、有效值、波形因子、峭度值相对于时间、负载或转速的发展趋势,并通过设置预警和告警阈值来发现信号异常。另外,同一风场不同风电机组所处的环境工况差异较小,采用临近风电机组之间振动信号的比较分析可在一定程度上剔除工况干扰,发现异常。

频域分析方面,现有振动监测系统使用方法大致相同,主要基于快速傅里叶变换,典型的如幅值谱、相位谱、包络谱分析、倒谱分析及频谱峰态等。美国 GEBently Nevada 公司的 CBM 系统和丹麦 Mita-Teknik 的 WP4086 以加速度包络谱分析为主,而 Brüel & Kjær 则兼有包络谱分析和倒谱分析。系统提供了丰富的频谱标记功能,如单光标、边频、倍频及频带能量等,用户通过频谱分析获取信号的主要频率成分以及谐波成分,结合由传动链信息和转速信息计算的部件故障频率,配合谐波分析、边频分析,即可分析振动信号的主要来源以及可能的故障类型。

丰富的图谱分析如瀑布图、色谱图及轴心轨迹图等可以对数据做全方位的展示,方便理解数据和挖掘状态信息。例如将不同时间点的频谱组合起来可以以色谱图或 3D 瀑布图显示,色谱图以横坐标表示频率,纵坐标表示时间,颜色表示幅值,色谱图上能直观地看出各频率成分在不同时间的幅值变化情况。3D 瀑布图则以三维的方式显示频率、时间以

及幅值。色谱图、瀑布图可用于跟踪频谱不随转速变化而变化的固定的频率成分。风电机组传动链振动监测系统主要功能和分析方法如图 11 所示。

目前的风电机组传动链振动监测系统的突出特点是强监测、弱诊断,分析方法以经典快速傅里叶变换分析为主,辅以振动信号趋势预测、阈值报警等功能,在风电机组传动系统早期故障预示方面亟待加强。另一方面,基于单信息源的状态监测方法往往不能全面反应风电机组传动链各部件的健康状态,难免造成误报警和误诊断,必须充分利用各种信息源的优势,研究基于多源信息的状态监测方法,提高监测和诊断的准确性和可靠性。



图 11 振动监测系统主要功能和分析方法

Fig. 11 Main functions and analysis methods of vibration monitoring system

5 基于大数据的风电机组健康管理

目前,除了振动监测系统外,风电机组状态监测系统还有 SCADA 系统、变频器监控系统及箱变监控系统等,各种工况信息如温度、油液成分、功率、电气信号及控制信号等都可以获取,如何将这海量多维状态信息有效融合是风电机组健康管理的重点。融入大数据、云计算等新一代信息技术,建立统一跨多系统的、跨设备的、基于设备状态洞察分析的大数据分析平台,挖掘大数据资源价值,实现基于多源信息融合的大数据预测分析与智能维护将是风电机组健康管理的重要发展趋势,如图 12 所示。

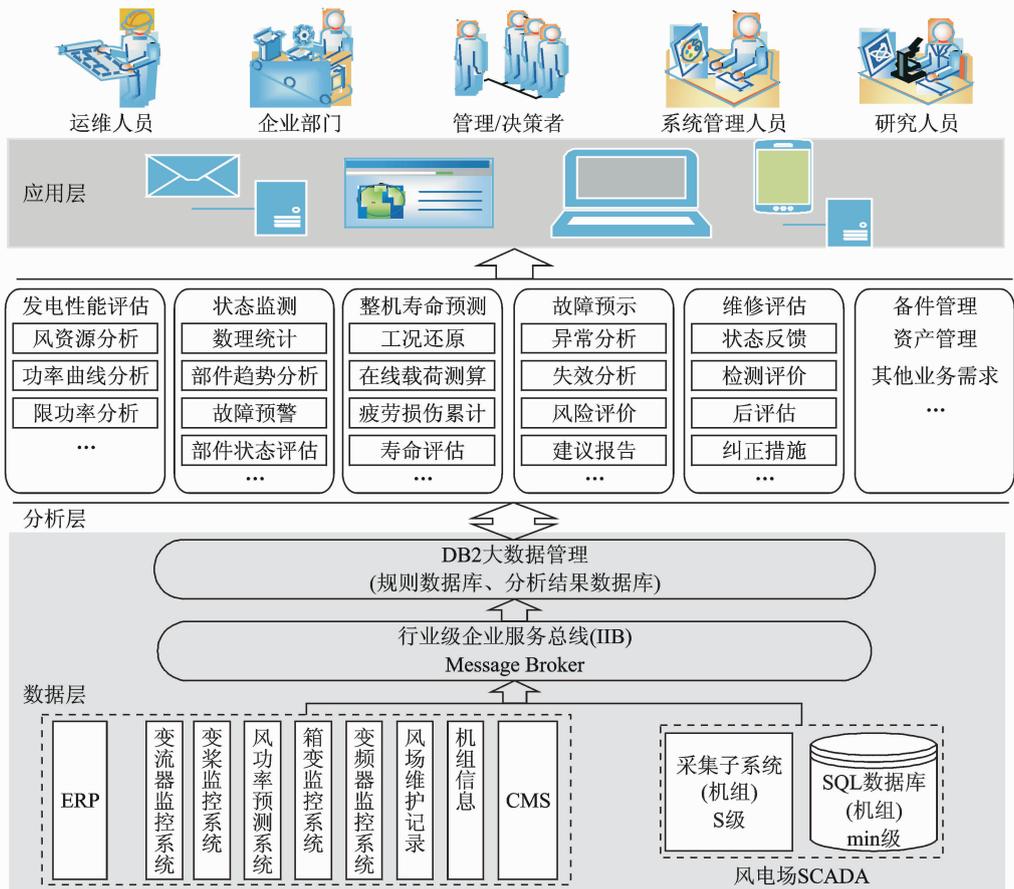


图 12 基于大数据的风电机组健康管理

Fig. 12 Health management of wind turbine based on big data

建立集风电机组零部件运行数据、风场环境数据、风机设计、制造及安装等多维数据的数据中心是进行大数据分析的基础。利用大数据技术,通过数理统计、模式识别、神经网络、机器学习及人工智能等深度数据挖掘算法,在海量数据中,挖掘出零部件故障信息,追溯其在设计、制造、装配、运输及安装各个环节的潜在缺陷,快速找寻引起故障或失效的原因是建立风电机组大数据分析平台的重点和难点。

6 结 论

1) 有效表征风电机组传动系统各部件状态发展趋势的特征指标是当前风电机组振动状态监测的重点。不同部件采用的特征指标有所不同,如何将包含了齿轮、轴承及齿轮箱中其他振源的振动信号进行分离,对有效提取部件级的特征指标至关重要,值得深入研究。

2) 解决现役风电机组因传动系统故障导致巨大经济损失的关键是进行风电机组传动系统早期故障预示,但风电机组传动系统早期故障样本数据十分稀缺,需开展风电机组传动系统早期故障信号收集工作,积累早期故障样本,为实际应用提供数据支持。

3) 建立统一跨多系统的、跨设备的、基于设备状态洞察分析的大数据分析平台,挖掘大数据资源价值,实现基于多源信息融合的大数据预测分析与智能维护将是风电机组健康管理的重要发展趋势。

参 考 文 献

[1] Crabtree C J, Feng Y, Tavner P J. Detecting incipient wind turbine gearbox failure: a signal analysis method for on-line condition monitoring[J]. *Journal of Organic Chemistry*, 2010, 75(18):6122-6140.

[2] Liang M, Faghidi H. Intelligent bearing fault detection by enhanced energy operator[J]. *Expert Systems with Applications*, 2014, 41(16):7223-7234.

[3] Unal M, Onat M, Demetgul M, et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network[J]. *Measurement*, 2014, 58:187-196.

[4] Zarei J, Tajeddini M A, Karimi H R. Vibration analysis for bearing fault detection and classification using an intelligent filter[J]. *Mechatronics*, 2014, 24(2): 151-157.

[5] Ruiz-Cárcel C, Hernani-Ros E, Cao Y, et al. Use of

spectral kurtosis for improving signal to noise ratio of acoustic emission signal from defective bearings[J]. *Journal of Failure Analysis and Prevention*, 2014, 14(3):363-371.

[6] Chacon J L F, Kappatos V, Balachandran W, et al. A novel approach for incipient defect detection in rolling bearings using acoustic emission technique[J]. *Applied Acoustics*, 2015, 89(89):88-100.

[7] Bai Xiuqing, Xiao Hanliang, Zhang Lu. The condition monitoring of large slewing bearing based on oil analysis method[J]. *Key Engineering Materials*, 2011, 474-476:716-719.

[8] Jiang Xufeng, Liu Fang, Zhao Pengcheng. Gearbox non-ferrous metal bearing wear condition monitoring based on oil analysis[J]. *Applied Mechanics & Materials*, 2012, 164:73-76.

[9] Pattabiraman T R, Srinivasan K, Malarmohan K. Assessment of sideband energy ratio technique in detection of wind turbine gear defects[J]. *Case Studies in Mechanical Systems & Signal Processing*, 2015, 2:1-11.

[10] Zappalá D, Tavner P J, Crabtree C J, et al. Sideband algorithm for automatic wind turbine gearbox fault detection and diagnosis[J]. *IET Renewable Power Generation*, 2014, 8(4):380-389.

[11] Sheng S. Wind turbine gearbox condition monitoring round robin study vibration analysis[J]. *Office of Scientific & Technical Information Technical Reports*, 2012, 68: 856-860.

[12] 贺王鹏, 訾艳阳, 陈彬强, 等. 周期稀疏导向超小波在风力发电设备发电机轴承故障诊断中的应用[J]. *机械工程学报*, 2016, 52(3):41-48.

He Wangpeng, Zi Yanyang, Chen Binqiang, et al. Periodic sparsity oriented super-wavelet analysis with application to motor bearing fault detection of wind turbine[J]. *Journal of Mechanical Engineering*, 2016, 52(3):41-48. (in Chinese)

[13] Sun Hailiang, Zi Yanyang, He Zhengjia. Wind turbine fault detection using multiwavelet denoising with the data-driven block threshold[J]. *Applied Acoustics*, 2014, 77(3):122-129.

[14] 孙自强, 陈长征, 谷艳玲, 等. 基于混沌和取样积分技术的大型风电增速箱早期故障诊断[J]. *振动与冲击*, 2013, 32(9):113-117.

Sun Ziqiang, Chen Changzheng, Gu Yanling, et al. Incipient fault diagnosis of large scale wind turbine gearbox based on chaos theory and sampling integral tech-

- nology[J]. *Journal of Vibration & Shock*, 2013, 32(9):113-117. (in Chinese)
- [15] Wang Jinjiang, Gao Robert X, Yan Ruqiang. Integration of EEMD and ICA for wind turbine gearbox diagnosis[J]. *Wind Energy*, 2014, 17(5):757-773.
- [16] 彭进,王维庆,王海云,等. 基于 EEMD 峭度-相关系数准则的多特征量风电机组轴承故障诊断[J]. *可再生能源*, 2016, 34(10):1481-1490.
Peng Jin, Wang Weiqing, Wang Haiyun, et al. Fault diagnosis method of wind turbine's bearing based on EEMD kurtosis-correlation coefficients criterion and multiple features[J]. *Renewable Energy Resources*, 2016, 34(10):1481-1490. (in Chinese)
- [17] Ding Xiaoxi, He Qingbo. Time - frequency manifold sparse reconstruction: a novel method for bearing fault feature extraction[J]. *Mechanical Systems & Signal Processing*, 2016, 80:392-413.
- [18] Wang Shoubin, Sun Xiaogang, Li Chengwei. Wind turbine gearbox fault diagnosis method based on riemannian manifold[J]. *Mathematical Problems in Engineering*, 2014, 2014(4):1-10.
- [19] 马婧华,汤宝平,宋涛. 基于自适应本征维数估计流形学习的相空间重构降噪方法[J]. *振动与冲击*, 2015, 34(11):30-34.
Ma Jinghua, Tang Baoping, Song Tao. Phase space reconstruction method for vibration signal's noise reduction based on adaptive intrinsic dimension estimation manifold learning [J]. *Journal of Vibration & Shock*, 2015, 34(11):30-34. (in Chinese)
- [20] 宋涛,汤宝平,邓蕾,等. 动态增殖流形学习算法在机械故障诊断中的应用[J]. *振动与冲击*, 2014, 33(23):15-19.
Song Tao, Tang Baoping, Deng Lei, et al. A dynamic incremental manifold learning algorithm and its application in fault diagnosis of machineries[J]. *Journal of Vibration & Shock*, 2014, 33(23):15-19. (in Chinese)
- [21] Su Zuqiang, Tang Baoping, Ma Jinghua, et al. Fault diagnosis method based on incremental enhanced supervised locally linear embedding and adaptive nearest neighbor classifier[J]. *Measurement*, 2014, 48(1):136-148.
- [22] Tang Baoping, Song Tao, Li Feng, et al. Fault diagnosis for a wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine[J]. *Renewable Energy*, 2014, 62(3):1-9.
- [23] 苏祖强,汤宝平,刘自然,等. 基于正交半监督局部 Fisher 判别分析的故障诊断[J]. *机械工程学报*, 2014, 50(6):1-7.
Su Zuqiang, Tang Baoping, Liu Ziran, et al. Fault diagnosis based on orthogonal semi-supervised local Fisher discriminant analysis[J]. *Journal of Mechanical Engineering*, 2014, 50(6):1-7. (in Chinese)
- [24] Yang Wenxian, Tavner Peter J, Crabtree Christopher J, et al. Wind turbine condition monitoring: technical and commercial challenges[J]. *Wind Energy*, 2014, 17(5):673-693.
- [25] 马婧华,汤宝平,韩延. 风电机组传动系统网络化状态监测与故障诊断系统设计[J]. *重庆大学学报*, 2015(1):37-44.
Ma Jinghua, Tang Baoping, Han Yan. Design of networking condition monitoring and fault diagnosis for wind turbine transmission system [J]. *Journal of Chongqing University*, 2015(1):37-44. (in Chinese)



第一作者简介:汤宝平,男,1971年9月生,教授、博士生导师。主要研究方向为机电装备安全服役与寿命预测、测试计量技术及仪器、无线传感器网络。曾发表论文 150 余篇,出版专著 1 部,获国家技术发明二等奖 1 项、国家科技进步二等奖 1 项。

E-mail: bptang@cqu.edu.cn