

DOI:10.3969/j.issn.1001-4551.2019.06.004

风电机组齿轮箱系统的故障预警研究*

黄小光,潘东浩,史晓鸣,王杏,王欣
(浙江运达风电股份有限公司,浙江杭州310012)

摘要:针对风电机组齿轮箱系统的故障预测问题,利用了齿轮箱异常时的动态特性将会偏离正常工作状态的现象,提出了同时使用温度和压力信号对齿轮箱进行故障预测,并据此建立了一种齿轮箱的温度和压力模型。采用了滑动窗口法计算残差的分布特性,以天为单位,定义了残差超限比例,根据预测值残差分布特性的改变,对齿轮箱故障做出及时的预测;设计了以残差超限比例为依据,向风电场发起报警信息的系统流程,提示运维人员有针对性地对设备进行检查;通过对现场实际机组进行模型部署试验,实现了对齿轮箱温控阀故障的提前预警。研究表明:该模型对齿轮箱异常状态的判断能力可以起到提前预警的目的。

关键词:状态监测;齿轮箱;非线性状态估计;风力发电;故障诊断

中图分类号:TH132.41;TM315

文献标志码:A

文章编号:1001-4551(2019)06-0574-05

Fault warning of wind turbine gearbox

HUANG Xiao-guang, PAN Dong-hao, SHI Xiao-ming, WANG Xing, WANG Xin
(Zhejiang Windey Co., Ltd., Hangzhou 310012, China)

Abstract: In order to provide early anomaly warnings for wind turbine gearbox, the model of bearing temperature and lube oil pressure of gearbox was established. The model was based on the fact that the behavior mode of the gearbox would change when faults existed. A moving window statistical method was used to detect the change of the distribution of residual errors, thus the fault of wind turbine gearbox could be predicted in time by monitoring this change. The residual error overrun ratio was defined and calculated within a day. The alarm would be sent out if the ratio of the previous day exceeded the threshold set based on the historical gearbox operational data. The operation and maintenance personnel could be triggered by the alarm to check the status of the gearbox. The model was tested on real wind turbines on site, and an early anomaly warning of the gearbox temperature control valve was detected and validated. The experimental results indicate that the model can be applied satisfactory to provide the early warning of wind turbine gearbox anomalies.

Key words: condition monitoring; gearbox; nonlinear state estimation; wind turbine; fault diagnose

0 引言

齿轮箱是风力发电机组传动链的重要组成部分。与其他部件相比,齿轮箱的受力情况复杂,维修过程费时费力,对机组的运行时长和发电量影响较大。因此,有必要对齿轮箱的异常状态进行提前预警,提示运维人员及时检查和维护。

目前,风电机组配备的在线状态监测系统(CMS)大多采用振动分析手段,受限于传感器的安装位置和数量,且系统采样点数存在上限,导致信号采样间隔较长、采样频率较低或采样时长较短,难以满足齿轮箱实时故障预警的要求;其次,目前在工程中应用较多的专家系统、神经网络技术、支持向量机技术等故障诊断方法,多需要构建完整的故障数据库,造成风电机组成本较高;再次,目前已有方法多是使用单一特征或者某几

收稿日期:2018-11-20

基金项目:浙江省重点研发计划项目(2019C01050)

作者简介:黄小光(1974-),男,湖南浏阳人,博士,高级工程师,主要从事电力大数据分析,故障预测和智能诊断方面的研究。E-mail:huangxg@chinawindey.com

个特征进行分析,导致故障诊断正确率较低。因此,为提高故障诊断准确性,迫切需要有一种新的基于多源信息融合的故障诊断方法,实现齿轮箱故障准确诊断和定位。

近年来,研究人员针对齿轮箱的故障预警提出了多种方法。龙泉等人^[1]提出了一种基于粒子群优化BP神经网络风电机组齿轮箱故障诊断方法,网络的收敛速度快,减小了陷入局部极小点的风险;唐明珠等人^[2]提出了基于增量代价敏感支持向量机(ICSVM)的齿轮箱故障诊断方法,建立了以误差分类代价最小化为目标的代价敏感支持向量机模型;ZAHER 等人^[3]利用数据采集与监视控制系统(SCADA),使用多层神经网络算法对齿轮箱和发电机进行了建模,根据温度参数设定阈值,采用 Multi-Agent 系统对不同部件的诊断结果进行了综合分析来进行故障预测,同时指出了神经网络算法的精度受多种因素影响,例如训练算法的选择、建模对象的网络结构以及学习样本等;方瑞明等人^[4]基于风电机组齿轮箱的历史运行温度,结合正态云模型和趋势状态分析法构建了齿轮箱状态评估云模型,该模型应用云理论对温度边界具有的模糊性和不确定性进行了有效处理,能够提前发现齿轮箱的异常状态。

但以上方法算法复杂、耗时较长,且对样本的选取要求较高。郭鹏等人^[5]使用非线性状态估计(NSET)方法建立了齿轮箱的油温模型,通过温度残差的变化,发现了齿轮箱的潜在故障,该方法可以有效规避齿轮箱故障样本缺乏的影响,但很难覆盖齿轮箱系统内的各种故障。

本文在齿轮箱油温模型的基础上,建立齿轮箱的温度和压力预警模型,实现齿轮箱的故障预警。

1 齿轮箱监测参数

某风场 2.5 MW 风电机组的齿轮箱系统内的润滑油循环过程如图 1 所示^[6]。

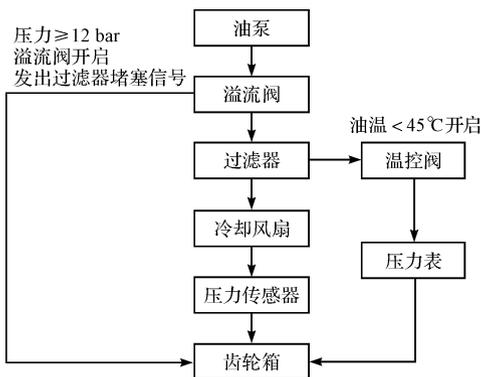


图1 齿轮箱润滑油循环

从图 1 中可以看到:冷却风扇与温控阀用于调节齿轮箱系统内的温度,压力传感器监测压力的变化。该机组的 SCADA 系统每 10 min 记录一次机组的参数,内容包括时间、有功功率、风速、机舱温度、发电机转速、齿箱轴承温度等共计 102 个参数。现场运维档案则记录了机组报发生故障的具体时刻、类型与损坏部件等信息。

2 齿轮箱模型与验证

2.1 建模原理

NSET 是 SINGER 等^[7]提出的一种非参数自适应建模方法,在核电站传感器校验、设备监测、电子产品寿命预测等方面都有成功的应用^[8-10]。本文采用这一方法,并以郭鹏等人的温度模型为基础,建立齿轮箱的温度和压力模型。

将 i 时刻的 n 个输入量记为一组观测向量 $\mathbf{X}(i)$:

$$\mathbf{X}(i) = [x_1(i) \quad x_2(i) \quad \cdots \quad x_n(i)]^T \quad (1)$$

在机组正常运行的 SCADA 历史数据中,挑选 m 组观测向量,组成记忆矩阵 \mathbf{D} :

$$\mathbf{D} = [\mathbf{X}(1) \quad \mathbf{X}(2) \quad \cdots \quad \mathbf{X}(m)] = \begin{bmatrix} x_1(1) & x_1(2) & \cdots & x_1(m) \\ x_2(1) & x_2(2) & \cdots & x_2(m) \\ \cdots & \cdots & \cdots & \cdots \\ x_n(1) & x_n(2) & \cdots & x_n(m) \end{bmatrix}_{n \times m} \quad (2)$$

记模型的输入为某时刻机组的一组观测向量 \mathbf{X}_{obs} ,输出为该时刻的预测值 \mathbf{X}_{est} 。该模型假设输出值是记忆矩阵 \mathbf{D} 中所有观测向量的线性组合,即认为存在一个权值向量 \mathbf{W} ,使得下式成立:

$$\mathbf{X}_{\text{est}} = \mathbf{D}\mathbf{W} \quad (3)$$

式中: $\mathbf{W} = [w_1 \quad w_2 \quad \cdots \quad w_m]^T$ 。

则模型输入值与输出值的残差为:

$$\boldsymbol{\varepsilon} = \mathbf{X}_{\text{est}} - \mathbf{X}_{\text{obs}} \quad (4)$$

令残差值最小,可得:

$$\mathbf{W} = (\mathbf{D}^T \cdot \mathbf{D})^{-1} \cdot (\mathbf{D}^T \cdot \mathbf{X}_{\text{obs}}) \quad (5)$$

为了避免出现无法求逆矩阵的现象,同时赋予模型物理意义^[5],可将式(5)的点乘改为欧氏距离,即:

$$\mathbf{W} = (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (6)$$

其中:

$$\mathbf{X} \otimes \mathbf{Y} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (7)$$

即可得到模型输出值与输入值之间的关系:

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (8)$$

如果模型的输入值是机组正常工作时的数据,就

会与记忆矩阵中的某些观测向量接近,从而得到一组比较准确的预测值,残差值也就比较小;如果模型的输入值是机组存在故障时的数据,就会偏离记忆矩阵中的观测向量,输出值的准确度就相应下降,残差值也将变大。因此,对残差的变化设定阈值并进行监测,即可实现齿轮箱故障提前预警。

2.2 齿轮箱预警模型构造

齿轮箱温度和压力预警模型的输入变量包括两类:一类是间接变量,包括机组功率、风速、发电机转速、机舱温度等;另一类是直接变量,包括齿箱泵出口压力、齿箱进口压力、齿轮箱油温等。模型的输出变量有 5 个:齿箱泵出口压力、齿箱进口压力、齿轮箱油温、齿箱前端轴承温度、齿箱后端轴承温度。与郭鹏等人仅使用齿轮箱油温来监测齿轮箱的异常状态相比,该模型更加全面准确。

首先需确定输入输出变量。本研究通过分析各变量与齿轮箱故障的相关度,从机组 SCADA 记录的 102 个参数中选取模型输入输出变量,如表 1 所示。

表 1 模型输入输出变量选取

输入变量	输出变量
机组功率	齿箱泵出口压力
风速	齿箱进口压力
发电机转速	齿轮箱油温
齿箱泵出口压力	齿箱前端轴承温度
齿箱进口压力	齿箱后端轴承温度
齿轮箱油温	
齿箱前端轴承温度	
齿箱后端轴承温度	
机舱温度	

2.3 记忆矩阵构造

模型的观测向量包括:风速、机组功率、发电机转速、机舱温度、齿箱泵出口压力、齿箱进口压力、齿轮箱油温、齿箱前端轴承温度与齿箱后端轴承温度 9 个变量,分别记为 $X(1), X(2), X(3), X(4), X(5), X(6), X(7), X(8), X(9)$, 则有效历史观测向量集合可以表示为:

$$K = [X(1) \quad X(2) \quad \cdots \quad X(9)] \quad (9)$$

为了避免因各变量取值范围不同而产生误差,记忆矩阵 K 中的每一个变量需做归一化处理。

在训练集中,删除掉所有异常数据后,即可以使用 9 个变量进行记忆矩阵的构造,但会出现两个问题:(1) 记忆矩阵中多数样本聚集在某个局部,而不能整体均匀的分布在正常样本空间;(2) 记忆矩阵太

庞大,导致后续预测的计算成本过高。所以,在构建记忆矩阵时有必要进行均匀系数。具体做法如下^[11]:对于每一个变量,将 $[0, 1]$ 之间等分为 h 份,以 $1/h$ 为步距从集合 K 中找出符合条件的观测向量加入记忆矩阵 D 中。

以变量 $X(1)$ 为例,选取符合条件的观测向量的流程,如图 2 所示。

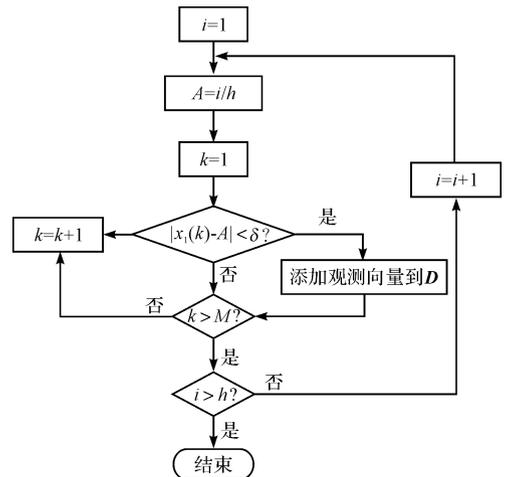


图 2 选取符合条件的观测向量的流程

对第 i 个步距,遍历集合 K 中的全部观测向量(共 M 个),若某一观测向量中 $X(1)$ 变量与 A 距离小于设定值 δ ,则将其加入记忆矩阵 D 中,直至遍历完成。其它变量均采用相同的流程,选择符合条件的观测向量添加到记忆矩阵 D 中。对于某些幅值变化较大或者十分重要的监测变量如齿轮箱油温等,步距可以适当缩小。为避免某些观测向量被重复选取,最后还需对记忆矩阵做去重处理。通过以上步骤构造的过程记忆矩阵,能够比较完整地覆盖齿轮箱正常工作范围。

记忆矩阵 D 的构建主要涉及到 3 个参数:观测向量、步距和步距左右区间 δ 值。步距一般取 0.01,而步距左右区间 δ 的取值不同,将会影响记忆矩阵 D 的维度。根据模型构造经验,记忆矩阵 D 中样本数量以 6 000 ~ 8 000 为宜,该模型为了保证计算效率,采用自适应算法求解满足条件的最大 δ 值。

2.4 齿轮箱模型有效性验证

本文选择某 2.5 MW 机组对模型进行验证。该机组在 2017-11-25 14:33 发生油温过高停机,上塔检查发现是温控阀损坏,经检查运维档案发现,该机组在 2016 年没有齿轮箱类故障,因而利用该机组 2016 年的 SCADA 历史运行数据,构造正常运行状态记忆矩阵 D ,对 2017 年的数据进行预测,其残差时序图如图 3 所示。

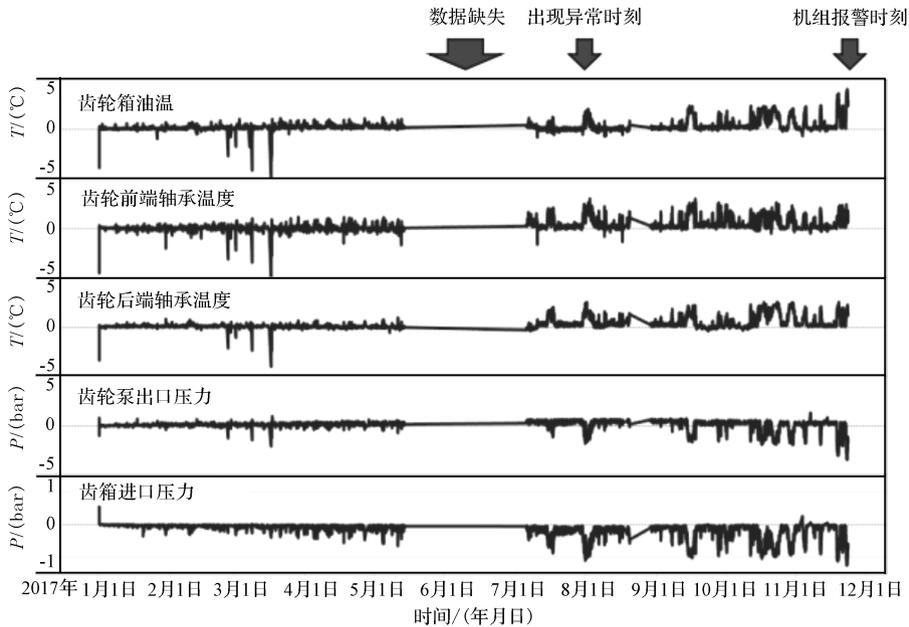


图3 残差时序图

从图3可以发现,在机组SCADA报警时刻约4个月前,残差已经有明显异常,温度和压力的残差更大且波动更加剧烈,而在更早期的正常运行状态,残差变化不大,基本保持稳定。这表明齿轮箱温度和压力模型对齿轮箱正常工作时的动态特性具有比较高的建模精度。

3 齿轮箱温度和压力模型预测残差统计分析

3.1 齿轮箱预警模型构造

由于齿轮箱模型的记忆矩阵基本覆盖了正常工作空间,模型的残差分布情况可以用来对齿轮箱异常进行预测。本文使用滑动窗口残差统计方法来实时连续地观测残差分布特性的变化。

记齿轮箱模型的温度和压力预测残差序列为:

$$\varepsilon_i = [\varepsilon_{i1} \ \varepsilon_{i2} \ \varepsilon_{i3} \ \varepsilon_{i4} \ \varepsilon_{i5}] \quad (10)$$

取一个宽度为 N 的滑动窗口,对窗口内的连续 N 个残差计算出超出某个阈值 δ 的比例,即:

$$\theta_j = \frac{1}{N} \sum_{i=1}^N \max(|\varepsilon_{ij} - \delta_j|, 0) \quad (11)$$

再根据这一比例 θ ,设定齿轮箱异常的报警阈值。采用滑动窗口残差统计方法的原因如下^[12-13]:

- (1) 算法简单且能够连续实时地监测残差统计特性的变化,适合在线实时分析;
- (2) 能抑制孤立的大残差对预测精度的影响;
- (3) 通过合理选择滑动窗口的宽度 N ,能及时迅速地反映残差统计特性的连续变化,同时消除随机因素的影响,提高齿轮箱状态监测的可靠性。

3.2 齿轮箱模型预警阈值划分

选择滑动窗口宽度 $N = 144$ (一天),根据机组历史数据,设定残差阈值与比例阈值,如表(2,3)所示。

表2 机组残差阈值

输出变量	残差阈值	
齿轮箱油温/(°C)	min	-2
	max	1.5
齿箱前端轴承温度/(°C)	min	-2
	max	1.5
齿箱后端轴承温度/(°C)	min	-2
	max	1.5
齿箱泵出口压力/bar	min	-0.5
	max	0.5
齿箱进口压力/bar	min	-0.5
	max	0.5

表3 机组前1天超过残差阈值的次数比例阈值

输出变量	比例阈值/(%)
齿轮箱油温	50
齿箱前端轴承温度	50
齿箱后端轴承温度	50
齿箱泵出口压力	50
齿箱进口压力	50

该机组前一天超出残差阈值的次数比例统计如图4所示。

从图4中可以看出:预警模型在大约8月份的时候即开始报警,提前大约4个月发现温控阀故障,证明该阈值划分方法可以有效提前预警齿轮箱系统内的异常。

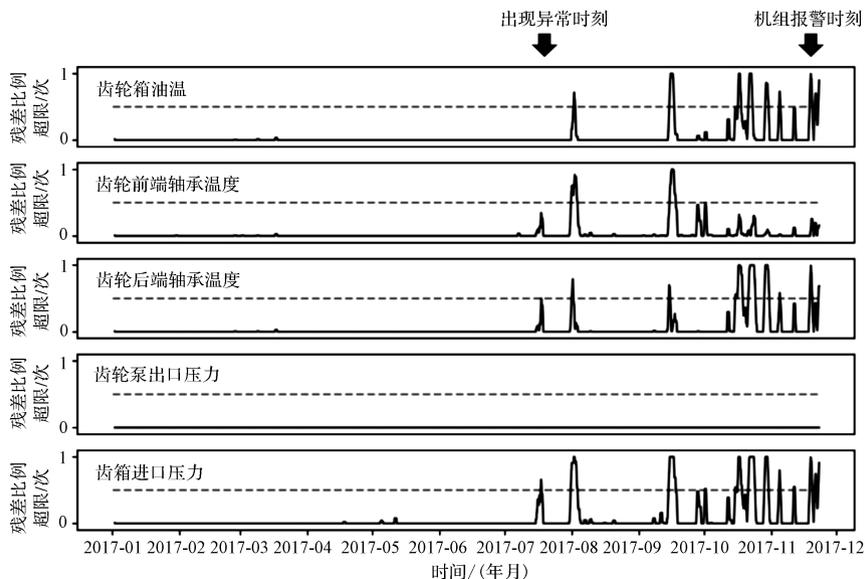


图 4 机组前 1 天超出残差阈值次数

虚线—报警比例限值,超出该次数比例阈值即进行预警

4 结束语

为了提前预警齿轮箱系统内的异常,本文建立了风电机组齿轮箱温度和压力模型,以 SCADA 数据为输入来源,通过选择恰当的输入变量、记忆矩阵空间及残差阈值,实现了实时预警齿轮箱异常的功能。该模型增加了可监测的异常种类以及预警的准确性,保证了预警的可靠性。

本文以实际发生在机组上的齿轮箱温控阀故障为例,对模型进行了验证。结果表明:该模型可以提前约 4 个月发现异常,实现了提前预警功能。

参考文献 (References) :

[1] 龙 泉,刘永前,杨勇平. 基于粒子群优化 BP 神经网络的风电机组齿轮箱故障诊断方法[J]. 太阳能学报,2012, 33(1):120-125.

[2] 唐明珠,黎 涛,谭欣星,等. 基于 ICSVM 的风电机组齿轮箱故障诊断[J]. 计算机工程与应用唯一官方网站, 2016,52(14):232-236.

[3] VOYDANOFF P. Online wind turbine fault detection through automated scada data analysis[J]. **Wind Energy**, 2010,12 (6):574-593.

[4] 方瑞明,江顺辉,尚荣艳,等. 采用趋势状态分析的风机齿轮箱状态在线评估云模型[J]. 华侨大学学报:自然科学版,2016,37(1):32-37.

[5] 郭 鹏,DAVIDI,杨锡运. 风电机组齿轮箱温度趋势状态

监测及分析方法[J]. 中国电机工程学报,2011,31(32): 129-136.

[6] 胡伟辉,杨 超,伍保华,等. 风力发电机组齿轮箱减振系统的优化[J]. 2017,44(2):25-29.

[7] GROSS K C, SINGER R M, WEGERICH S W, et al. Application of a model-based fault detection system to nuclear plant signals[R]. Seoul: International Conference on Intelligent Systems Applications to Power Systems, 1997.

[8] BOCKHORST F K, GROSS K C, HERZOG J P, et al. MSET modeling of crystal river-3 venturi flow meters[C]. Proceedings of International Conference on Nuclear Engineering, San Diego:ASME, 1998.

[9] CHENG S F, PECHT M G. Multivariate state estimation technique for remaining useful life prediction of electronic products[C]. Proceedings of AAAI Fall Symp, Artif. Intell. Prognostics, Arlington:IEEE, 2007.

[10] CASSIDY K J, GROSS K C, MALEKPOUR A. Advanced pattern recognition for detection of complex software aging phenomena in online transaction processing servers[C]. Proceedings of Dependable Systems and Networks, Washington:IEEE, 2002.

[11] 邹 迪. 基于状态监测信息的风力发电机故障预警与短期可靠性评估研究[D]. 重庆:重庆大学电气工程学院,2014.

[12] 冉广鹏,傅允准. 基于 WinCC 和 S7-200 PLC 的转轮除湿多点温湿度监测系统[J]. 轻工机械,2017,35(1):57-60.

[13] 李淋淋. 风力发电机组非参数模型状态监测关键问题研究[D]. 北京:华北电力大学控制与计算机学院,2013.

[编辑:周昱晨]

本文引用格式:

黄小光,潘东浩,史晓鸣,等. 风电机组齿轮箱系统的故障预警研究[J]. 机电工程,2019,36(6):574-578.

HUANG Xiao-guang, PAN Dong-hao, SHI Xiao-ming, et al. Fault warning of wind turbine gearbox[J]. Journal of Mechanical & Electrical Engineering, 2019, 36(6):574-578.