

风电机组齿轮箱温度趋势状态监测及分析方法

郭鹏¹, David Infield², 杨锡运¹

(1. 华北电力大学控制与计算机工程学院, 北京市 昌平区 102206

2. 斯特莱斯克莱德大学能源与环境学院, 英国 格拉斯哥 G1 1XW)

Wind Turbine Gearbox Condition Monitoring Using Temperature Trend Analysis

GUO Peng¹, DAVID Infield², YANG Xiyun¹

(1. School of Control and Computer Engineering, North China Electric Power University, Changping District,

Beijing 102206, China; 2. Institute for Energy and Environment, University of Strathclyde, Glasgow, UK, G1 1XW)

ABSTRACT: Condition monitoring (CM) of wind turbine can greatly reduce the maintenance cost for wind farm especially offshore wind farm. A new condition monitoring method using temperature trend analysis for a wind turbine gearbox was proposed. Nonlinear state estimate technique (NSET) was used to construct the normal behavior model of the gearbox temperature. With a proper construction of memory matrix, the NSET model can cover the normal working space for the gearbox. When the gearbox has an incipient failure, the residuals between NSET model estimates and the measurement temperature will become significant. A moving window statistical method was used to detect the changes of the residual mean value and standard deviation in a timely manner. When one of these parameters exceeds predefined thresholds, an incipient failure was flagged. In order to simulate the gearbox fault, manual temperature drift was added to the initial SCADA data. Analysis of the simulating gearbox fault shows that the new condition monitoring is effective.

KEY WORDS: condition monitoring; gearbox; nonlinear state estimate technique (NSET); residual; moving window statistic

摘要: 风电机组状态监测对于风电场特别是海上风电场降低维护成本, 提高运行水平具有重要的实用价值。采用温度趋势分析的方法对风电机组齿轮箱的运行状态进行监测。利用非线性状态估计(nonlinear state estimate technology, NSET)方法建立齿轮箱正常工作状态下的温度模型并用其进行温度预测。通过合理构造过程记忆矩阵, 使模型覆盖齿轮箱的

正常工作空间。当齿轮箱工作异常时, 其动态特性偏离正常工作空间, NSET 温度模型预测残差的分布特性发生改变。采用滑动窗口方法实时计算残差的统计分布特性, 当残差的均值或标准差的置信区间超出预先设定的阈值时, 发出报警信息, 提示运行人员检查设备状态。为模拟齿轮箱的故障情况, 在机组数据采集与监视控制系统(supervisory control and data acquisition, SCADA)数据中加入人为温度偏移。通过对该模拟故障的分析, 新的状态监测方法能够及时发现齿轮箱的异常状态, 达到实时在线状态监测的目的。

关键词: 状态监测; 齿轮箱; 非线性状态估计; 残差; 滑动窗口统计

0 引言

风电机组的运行条件恶劣, 如外界温差变化大, 风速变化随机等。这些不确定的外界因素导致风电机组的故障率高, 使风电场后期运行维护成本居高不下。风电机组状态监测技术是采用多种方法和手段对机组的重要部件(叶轮、齿轮箱、发电机等)进行在线监测和分析, 评估其运行状态, 尽早提前发现故障征兆, 避免和减轻严重的设备损坏, 确定合理的维护时间和方案, 从而达到大幅降低维护成本的目的。

齿轮箱是风电机组的重要部件之一, 其制造技术已较为成熟, 具有较高的可靠性。文献[1]的统计显示, 尽管齿轮箱的故障率较低, 但和故障出现频率最高的电控系统、液压系统相比, 其维修过程复杂, 特别是对于海上风机, 维护过程需要船舶、吊车等专用设备以及合适的天气, 因此齿轮箱故障导致的停机时间和维护费用在各类故障中最高。风电

基金项目: 国家自然科学基金项目(61074094); 中央高校基本科研业务费专项资金资助项目(09MG18)。

Project Supported by the National Natural Science Foundation of China (61074094); Fundamental Research Funds for the Chinese Central University(09MG18).

机组齿轮箱运行有其自身的特点,即变速变载荷。随着风速的变化,齿轮箱各级的转速及承受的载荷随时发生变化,这给传统的状态监测方法应用于风电机组齿轮箱带来很大的挑战。对于齿轮箱状态监测方法的选择还需要考虑监测方法的性价比。和火电机组和水电机组相比,单台风机的造价较低,齿轮箱监测系统的成本是必须考虑的因素。

文献[2-4]对近年来的风电机组不同部分的状态监测方法进行了系统的分析和综述。文献[5]采用BP神经网络对齿轮箱和发电机进行建模并预测,采用多Agent方法对不同部件的诊断结果进行综合分析,给出机组整体的运行状态。但采用神经网络建模需要耗时的学习过程,学习样本的选择缺乏依据。文献[6-9]建立了齿轮箱和发电机的硬件实验台,通过小波分析方法处理高速采集的振动信号,但与其与实际齿轮箱的运行状态有较大差别。现场风电机组的传动链系统安装的振动传感器数量有限且仅用来进行振动幅值的阈值报警,振动信号的采集速度往往难以满足高频振动分析的需要。本文采用温度趋势分析的方法进行齿轮箱状态的监测。首先对某1.5MW机组的SCADA数据进行了整理和分析,采用非线性状态估计(nonlinear state estimate technology, NSET)方法建立了齿轮箱的温度模型,并利用该模型对齿轮箱的温度进行预测。当齿轮箱运行异常时,其温度预测残差的统计特性会发生较大的改变,从而及早发现齿轮箱的潜在故障。

1 风电机组齿轮箱结构及SCADA监测参数

本文研究的风电机组的额定功率为1.5MW。切入风速为3m/s,额定风速为12m/s。叶轮的额定转速为20r/min,双馈发电机的额定转速为1800r/min,齿轮箱的变速比为1:90。为使齿轮箱具有高变速比同时体积较小,大型风电机组齿轮箱通常采用三级结构:第一级为行星齿轮,第二三级为常规齿轮传动级,如图1所示。第一级行星齿轮的太阳轮位于中心,与四周的3个行星轮啮合。3个行星轮用行星架支撑并与轮毂的大轴相连。由于3个行星轮同时和太阳轮接触,行星齿轮能够承受更大的力矩,同时结构尺寸紧凑。行星齿轮的输出和第二级即中间级齿轮啮合。第三级齿轮的输出端与发电机轴相连。齿轮箱采用润滑油进行润滑和降温。润滑油循




图1 风电机组齿轮箱结构

Fig. 1 Structure of gearbox for wind turbine

环使用,油路中的设备包括冷却器和风扇、过滤器、油箱和泵。为保证润滑油系统在冬季室外极低气温(20℃)下运行,油系统中还配备1.5kW左右的加热系统。各级齿轮采用滚珠轴承固定支撑,轴承采用油脂润滑。

该机组的SCADA系统每10min记录一次机组的参数。记录的内容包括时间标签、有功功率、无功功率、定子三相电压电流、风速、环境和机舱温度、齿轮箱和轴承温度、发电机转速、传动链振动加速度等共计47个参数。同时SCADA系统还保存机组的运行状态信息,如机组启动、停机、发电机超温、变桨系统故障等。每条运行信息包括记录时间、唯一的状态编号、状态说明等。例如:在2006/04/02, 2:28,发生了状态号为77的齿轮箱油超温报警,机组停机。在该机组的运行手册中齿轮箱油超温报警的处理措施为:如油温高于80℃且持续60s则停机,油温降至65℃后重新启动。

2 齿轮箱温度NSET建模与预测

2.1 非线性状态估计建模原理

本文采用非线性状态估计方法建立齿轮箱正常工作状态时的温度模型。NSET是由Singer等^[10]提出的一种非参数建模方法,目前在核电站传感器校验、设备监测、电子产品寿命预测等方面有成功的应用^[11-13]。

某一过程或设备共有 n 个相互关联的变量,设在某一时刻 i ,观测到的 n 个变量记为观测向量,即

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

过程记忆矩阵 \mathbf{D} 的构造是NSET建模的第一个步骤。在该过程或设备正常工作的时段内,在不同运行工况下(如低负荷,高负荷等)采集 m 个历史观测向量,组成过程记忆矩阵为

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

过程记忆矩阵中的每一列观测向量代表设备的一个正常工作状态。经过合理选择的过程记忆矩阵中的 m 个历史观测向量所张成的子空间(用 \mathbf{D} 代表)能够代表过程或设备正常运行的整个动态过程。因此,过程记忆矩阵的构造实质就是对过程或设备正常运行特性的学习和记忆过程。

NSET 的输入为某一时刻过程或设备的观测向量 \mathbf{X}_{obs} , 模型的输出为对该输入的预测向量 \mathbf{X}_{est} 。对任何一个输入观测向量 \mathbf{X}_{obs} , NSET 生成一个 m 维的权值向量为

$$\mathbf{W} = [w_1 \quad w_2 \quad \cdots \quad w_m]^T \quad (3)$$

使得:

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot \mathbf{W} = w_1 \cdot \mathbf{X}(1) + w_2 \cdot \mathbf{X}(2) + \cdots + w_m \cdot \mathbf{X}(m) \quad (4)$$

即 NSET 模型的预测输出为过程记忆矩阵中 m 个观测向量的线性组合。权值向量 \mathbf{W} 采用以下方法确定。构造 NSET 模型输入和输出预测向量的残差为

$$\boldsymbol{\varepsilon} = \mathbf{X}_{\text{obs}} - \mathbf{X}_{\text{est}} \quad (5)$$

对残差进行极小化,求得权值向量 $\mathbf{W}^{[11,14]}$ 为

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

式中 \otimes 为非线性运算符,用来替代普通矩阵运算中的乘法运算。非线性运算符有多种选择^[15], 本文选取为两向量间的 Euclidean 距离, 即

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

该非线性运算符具有直观的物理意义,当两向量相同或相似时,距离为 0 或接近 0; 两向量差异越大,其非线性运算的结果越大。式(6)中的权值向量 \mathbf{W} 反映了 NSET 模型输入观测向量与过程记忆矩阵中各向量的相似性。

将式(6)代入式(4)中, NSET 模型对过程或设备预测的最终结果为

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

当过程或设备工作正常时, NSET 的新输入观测向量位于过程记忆矩阵所代表的正常工作空间内,与 \mathbf{D} 矩阵中的某些历史观测向量距离较近,相

应其 NSET 的预测值 \mathbf{X}_{est} 具有很高的精度。当过程或设备工作状态发生变化出现故障隐患时,由于动态特性的改变,输入观测向量将偏离正常工作空间,通过 \mathbf{D} 矩阵中历史观测向量的组合无法构造其对应的精确预测值,导致预测精度下降,残差增大。

2.2 齿轮箱温度 NSET 建模变量选取

为建立齿轮箱 NSET 温度模型,需确定观测向量中的建模变量,即与齿轮箱温度密切相关的风电机组参数。通过对机组 SCADA 记录的 47 个参数的分析,选择与齿轮箱温度密切相关的以下变量组成观测向量。

1) 机组功率(P): 其与齿轮箱温度密切相关,当机组输出功率高时,齿轮箱承受的载荷大,导致齿轮箱温度高。

2) 风速(v): 风是风电机组的能量来源。对于本文研究的变速风电机组,为达到最佳叶尖速比从而实现最大风能追踪的目的,传动系统的转速与风速成正比。风速越大,齿轮箱转速越高,导致齿轮箱温度升高。

3) 环境温度(T): 由于该机组所处的环境温度在短期(昼夜)和长期(星期、月)时间尺度上变化很大,环境温度必须作为考虑因素之一。特别是在春季 3、4 月份,由于大风寒潮等原因,环境温差可达 30 °C。在不同时刻,即使机组的功率和风速相同时,由于环境温度的不同也会导致齿轮箱温度有很大差异。

4) 齿轮箱温度自身(T_G);

5) 上一时刻齿轮箱温度(T_{G1}): 由于温度参数变化具有较大的惯性,前一时刻的齿轮箱温度对当前时刻温度有直接影响。

齿轮箱温度 NSET 模型的时间跨度选取需考虑机组所处位置的气候特点。本文研究机组位于张家口地区,不同季节(如冬季和夏季)环境温度与风速条件有很大差别,因此建模时间跨度不应太大,否则会导致建模精度下降。本文的建模时间跨度为一个月,对某机组 2006 年 4 月份的 SCADA 数据进行分析和处理。该机组从 2006/04/01 零点到 2006/04/06 零点的 720 个 10min SCADA 数据如图 2 所示。

在此时段,该机组共发生 3 次停机,如图 2 功率曲线中的序号所示。各次停机的 SCADA 记录如表 1 所示。

需注意的是,对于实际风电机组,报警停机与




图2 某机组4月1日至6日历史趋势

Fig. 2 Trends from 04/01 0:00 to 04/06 0:00

表1 4月1日至6日机组停机记录

Tab. 1 Shutdown record during 04/01 to 04/06

序号	日期	时间	状态号	停机原因
1	2006/04/02	2:28:43	77	齿轮箱油超温
2	2006/04/02	7:42:13	77	齿轮箱油超温
3	2006/04/03	11:14:35	147	指令停机

设备故障之间没有必然联系。如表1中虽然发生了2次齿轮箱油超温报警停机，但在该机组4月份及后续月份的SCADA记录和运行日志中未发现齿轮箱故障和维修的记录。部分报警停机属于机组自身的保护功能。在4月份，齿轮箱工作正常，无超温或其他故障。4月份的10min记录共计4320个。其中有效记录即机组输出功率大于零的记录共计3731个。利用4月份齿轮箱正常工作状态下的有效10min历史记录建立齿轮箱NSET温度模型。当过程记忆矩阵D构造完成后，即可按图3所示对新的输入观测向量进行预测和残差分析，监测齿轮箱的运行状态，发现其故障隐患。




图3 NSET模型齿轮箱温度趋势状态监测

Fig. 3 Condition monitoring for gearbox using NSET model

2.3 过程记忆矩阵D的构造

在使用SCADA历史数据构造过程记忆矩阵和预测输出前，由于NSET温度模型所选择的5个变

量的量纲不同，且不同变量数据绝对值相差很大，为保证使用非线性算子正确衡量不同观测向量之间的距离，需要对5个变量的测量值根据各自的极值进行归一化处理，使实际测量值映射到[0 1]区间。对于风速变量，由于机组的切入风速为3m/s，额定风速为12m/s，因此风速的最小值和最大值分别为3和12。高于12m/s和低于3m/s的风速应分别对应为12和3。

过程记忆矩阵的构造需要使其内部的m个观测向量X(1), X(2), ..., X(m)能够尽量覆盖齿轮箱正常工作空间。记机组4月份有效的历史观测向量集合为

$$K = [X^N(1) \ X^N(2) \ \dots \ X^N(M)] = \begin{bmatrix} x_1^N(1) & x_1^N(2) & \dots & x_1^N(M) \\ x_2^N(1) & x_2^N(2) & \dots & x_2^N(M) \\ \vdots & \vdots & & \vdots \\ x_5^N(1) & x_5^N(2) & \dots & x_5^N(M) \end{bmatrix}_{5 \times M} \quad (9)$$

集中观测向量的数量为M=3731。每个观测向量包括功率、风速、环境温度、齿轮箱温度、上一时刻齿轮箱温度5个值，将其分别记为x1, x2, ..., x5，即式(1)中n=5。

齿轮箱正常工作空间的每一个观测向量由5个变量组成，且其观测值已被归一化。对每一个变量，将[0 1]之间等分为100份，以0.01为步距从集合K中查找出若干个观测向量加入矩阵D中。以机组功率x1为例，向过程矩阵D中添加观测向量的方法如图4所示。

图中δ为一小的正数。对剩余的4个变量，均采用与图4相同的流程以0.01为步距从集合K中

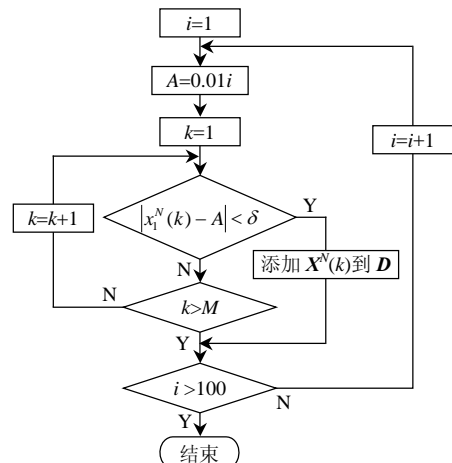


图4 根据功率变量x1构造过程记忆矩阵
Fig. 4 Memory matrix construction as to x1

选择观测向量添加到 D 中。采用此方法构造过程记忆矩阵，能够将组成观测向量的 5 个变量的不同测量值对应的历史记录选入矩阵 D 中，从而使其能较好地覆盖齿轮箱正常工作空间。对于某些重要的变量如本文所关心的齿轮箱温度变量 x_4 ，选取历史观测向量的步距可以取得更小如 0.005(等分为 200 份)。构造过程记忆矩阵完成后，即可利用式(8)对 NSET 温度模型新的输入观测向量进行预测。

2.4 齿轮箱 NSET 温度模型有效性验证

采用 2.3 节的方法构造过程记忆矩阵 D ，得到矩阵 D 中的观测向量数量 $m=486$ 。选取与图 2 对应的从 4 月 1 日 0 时到 4 月 6 日 0 时的 720 个历史记录作为验证集。在 4 月份的历史记录中，齿轮箱温度的最大值为 74.1 °C，最小值为 50.2 °C。环境温度的最大值为 20 °C，最小值为-13 °C。记齿轮箱温度的 NSET 模型预测残差为

$$\varepsilon_{GT} = x_4 - \hat{x}_4 \tag{10}$$

式中： x_4 为 NSET 模型输入观测向量中的齿轮箱温度分量； \hat{x}_4 为该输入对应的齿轮箱温度预测分量。验证结果见图 5。图中各变量的值均为归一化后的结果。当输入观测向量中的功率为 0 时即机组停机时，NSET 模型不对输入向量进行预测，对应的齿轮箱温度预测值为 0，对应的残差为 0。




图 5 某机组 4 月 1 日至 6 日的 NSET 模型验证结果
Fig. 5 Validation result using data from 04/01 to 04/06

在图 5 中，某些孤立时刻的齿轮箱温度的预测残差明显大于其他时刻。且这些预测残差大的点是成对出现的。共 3 对，其位置和出现原因如表 2 所示，与表 1 中的机组的 3 次停机时刻完全对应。

表 2 验证结果中残差大的位置与原因
Tab. 2 Large residual's position and reason

序号	位置	时刻	残差值	原因
1	第 160 点	04/02 2:30	0.008 5	2006/04/02 2:28:43 发生齿 轮箱油超温停机
		04/02 6:10		-0.019 3
2	第 192 点	04/02 7:50	0.019 1	2006/04/02 7:42:13 发生齿 轮箱油超温停机
		04/02 10:00		-0.031 2
3	第 357 点	04/03 11:20	0.010 4	2006/04/03 11:14:35 指令停机
		04/03 12:50		0.007 8

在表 2 中这些时刻出现预测残差大的原因如下。由于在这些时刻即机组停机和重新启动时，观测向量中各变量之间的关系与风电机组和齿轮箱正常运行时的状态差别很大(如当风速很高时功率低或为零)，观测向量偏离正常工作空间，通过过程记忆矩阵中的历史观测向量的组合无法给出精确的预测值，导致残差增大。这种由于启停机造成的孤立残差较大的点不应视为齿轮箱故障的出现。

去除以上由于停机导致的残差很大的 6 点后，NSET 模型的预测精度很高，预测残差绝大多数情况下在 0.5% 以下。验证结果表明齿轮箱 NSET 温度模型对齿轮箱正常工作时的动态特性具有很高的建模精度。

3 齿轮箱温度 NSET 模型预测残差统计分析

3.1 滑动窗口残差均值与标准差统计

过程记忆矩阵能够较好地覆盖齿轮箱的正常工作空间。当齿轮箱工作正常时，NSET 模型的输入观测向量位于正常工作空间，能够被过程记忆矩阵 D 覆盖，或者说输入与矩阵 D 中的某些向量距离很近，此时 NSET 模型对齿轮箱温度具有很好的预测效果。当齿轮箱出现异常时，其动态特性发生改变，观测向量中的 5 个变量之间的关系发生异常变化，偏离正常工作状态空间，无法被过程记忆矩阵 D 覆盖，其齿轮箱温度的预测残差增大且残差分布会显著区别于正常工作状态下的残差分布。残差的均值和标准差可以直观地反映其大小和分布情况。为实时连续地反映残差分布特性的变化，本文

采用滑动窗口残差统计的方法。

某段时间内,记 NSET 模型的齿轮箱温度预测残差序列为

$$\boldsymbol{\varepsilon}_{\text{GT}} = [\varepsilon_1 \quad \varepsilon_2 \quad \cdots \quad \varepsilon_N \quad \cdots] \quad (11)$$

对该序列,取一个宽度为 N 的滑动窗口。对窗口内的连续 N 个残差计算其均值和标准差:

$$\begin{cases} \bar{X}_\varepsilon = \frac{1}{N} \sum_{i=1}^N \varepsilon_i \\ S_\varepsilon = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (\varepsilon_i - \bar{X}_\varepsilon)^2} \end{cases} \quad (12)$$

残差滑动窗口如图 6 所示。




图 6 残差滑动窗口统计

Fig. 6 Moving wind residual statistics

采用滑动窗口残差统计方法的原因如下。

1) 该残差统计方法能够连续实时地检测残差统计特性的变化,算法简单,适合在线实时分析。

2) NSET 模型采用过程记忆矩阵 D 中合理选择的有限个历史观测向量代表整个齿轮箱温度特性的正常工作空间。其对整个正常工作空间总体上覆盖能力较好,如 2.4 节验证结果所示。但对正常工作空间的不同区域,其覆盖能力是有差异的。对某些特定的局部的工作空间, NSET 模型的覆盖能力比其他区域稍差。当 NSET 模型的输入观测向量位于这些区域时,其预测精度会有所下降,即在残差序列中会出现一些孤立的残差相对较大的点。这些孤立的残差相对较大的点并不是齿轮箱故障的征兆。滑动窗口残差统计方法计算滑动窗口内多个残差的统计特性,对上述情况下的孤立较大残差的不利影响具有很好的抑制作用。

3) 通过合理选择滑动窗口的宽度 N ,既能及时迅速地反映残差统计特性的连续变化,又能消除随机因素的影响,提高齿轮箱状态监测的可靠性,降低误报警的几率。

3.2 齿轮箱工作异常时温度残差统计特性分析

当齿轮箱工作正常时, NSET 温度模型预测精

度很高,预测残差的均值接近 0,且标准差较小。当齿轮箱出现故障隐患时,其工作特性会发生改变。齿轮箱的常见故障主要有润滑不良、偏心、齿面点蚀胶合等,这些故障都会导致齿轮箱温度特性发生改变,使新的观测向量偏离正常工作状态空间。NSET 温度模型预测残差增大,统计特性改变主要表现为以下 3 种形式:

1) 残差的均值仍接近 0,但残差的标准差明显增大,表现为残差的散布范围增大;

2) 残差的均值以较大幅度偏离 0,但残差的标准差变化不大,表现为预测残差出现系统偏差,偏零值;

3) 以上两种情况的组合。

为了根据残差的统计特性变化检测齿轮箱的故障隐患,需要确定残差均值和标准差的故障阈值,记其分别为 E_Y 和 S_Y 。当 NSET 模型预测的齿轮箱温度残差滑动窗口统计特性超过其中某一设定阈值时,发出故障隐患报警,提醒操作人员密切关注齿轮箱的运行状态,及时采取相应的处理措施。残差均值和标准差阈值可以由运行人员根据经验确定,也可以根据 2.4 节中 NSET 温度模型的验证结果确定。

将验证集合作为 NSET 模型的输入,计算验证集合的预测输出和残差序列,对该残差序列采用滑动窗口统计方法计算残差的连续实时均值和标准差。记验证序列的残差均值绝对值最大值为 E_V ,标准差的最大值为 S_V ,则齿轮箱故障征兆诊断的阈值标准为

$$\begin{cases} E_Y = \pm k_1 E_V \\ S_Y = k_2 S_V \end{cases} \quad (13)$$

式中 k_1 和 k_2 可以由现场运行人员根据运行经验参与确定。如 2.4 节所述,在机组停机和启动的前后时刻,会造成残差异常增大,在进行残差分析时,可以根据功率是否为 0 确定这些异常残差的位置并用 0 替代,使其不影响齿轮箱的监测。

由于非参数模型在对输入进行预测时,存在一定的不确定性^[16-18]。为简化起见,认为残差服从均值和方差均未知的正态分布,在计算滑动窗口中残差序列的均值和标准差时,需要给出置信度为 $1-\alpha$ 的均值和标准差的置信区间。对于总体均值和方差未知的正态分布残差序列,均值和标准差的置信度为 $1-\alpha$ 的置信区间^[19]分别为:

$$[\bar{X}_\varepsilon - \frac{S_\varepsilon}{\sqrt{N}}t_{\alpha/2}(N-1), \bar{X}_\varepsilon + \frac{S_\varepsilon}{\sqrt{N}}t_{\alpha/2}(N-1)] \quad (14)$$

$$[\frac{\sqrt{N-1}S_\varepsilon}{\sqrt{\chi^2_{\alpha/2}(N-1)}}, \frac{\sqrt{N-1}S_\varepsilon}{\sqrt{\chi^2_{1-\alpha/2}(N-1)}}] \quad (15)$$

式中： N 、 \bar{X}_ε 和 S_ε 分别为滑动窗口的宽度、均值和标准差； $t_{\alpha/2}$ 和 $\chi^2_{\alpha/2}$ 分别为 t 分布和 χ^2 分布的 $\alpha/2$ 分位点。当均值或标准差置信区间超过阈值时，发出齿轮箱故障征兆报警信息。

3.3 齿轮箱预测残差分析

对 2.4 节中的验证集合残差序列采用滑动窗口统计方法确定齿轮箱工作异常监测时所需的均值和标准差的阈值，本文中滑动窗口宽度 $N=100$ 。验证序列滑动窗口均值与标准差的变化趋势如图 7 所示。




图 7 验证集合的残差滑动窗口统计特性

Fig. 7 Moving window statistic for validation set

由图 7 得到 $E_V=4 \times 10^{-4}$, $S_V=1.43 \times 10^{-3}$ 。本文取 $k_1=3$, $k_2=2$, 则齿轮箱故障报警阈值为： $E_Y=\pm 1.2 \times 10^{-3}$, $S_Y=2.86 \times 10^{-3}$ 。

该机组的 2006 年的 SCADA 数据中，没有出现齿轮箱故障的记录。为了验证 NSET 模型监测齿轮箱故障的有效性，人为模拟当齿轮箱故障时导致齿轮箱温度升高的情况。对 4 月 1 日 0 时到 4 月 6 日 0 时的 720 个历史数据从第 501 点开始对齿轮箱温度变量人为加入步距为 0.001 的累积温度偏移。故障模拟的 NSET 模型预测和残差如图 8 所示。

齿轮箱温度偏移后对应的残差滑动窗口统计特性和报警阈值如图 9 所示。

从图 9 中可以看出，均值曲线的 95% 置信区间的上限在第 451 个滑动窗口超出了预先设定的均值阈值，距离开始偏离的第 501 点的位置为 $451+100-501=50$ ，100 为滑动窗口的宽度。在第 551 点处，检测出了齿轮箱温度的异常变化。该点处人为偏移后的齿轮箱温度与对应的原始正常齿轮箱温度间的偏差可以根据温度偏移步距和齿轮箱温度变化




图 8 齿轮箱温度偏移后的 NSET 模型预测结果

Fig. 8 Estimating result after manual temperature drift added




图 9 温度偏移后的残差滑动窗口统计特性

Fig. 9 Moving window statistic for manual temperature drift sequence

区间求出，即 $50 \times 0.001 \times (74.1 - 50.2) = 1.2(^\circ\text{C})$ 。可见，当齿轮箱出现故障隐患导致其温度异常变化时，本文提出的基于 NSET 温度模型状态监测方法能够及时发现并发出报警信息，实现齿轮箱状态的在线监测。

4 结论

对风电机组的 SCADA 数据进行在线分析，在不增加硬件成本的前提下可以监测机组重要部件的工作状态，及时发现设备的故障隐患，对风电场特别是有很大发展潜力的海上风电场具有重大的实用意义。本文采用非线性状态估计理论，合理选择与齿轮箱温度密切相关的过程变量，并给出了过程记忆矩阵构造的有效方法，建立了齿轮箱温度 NSET 预测模型。该非参数建模方法与神经网络等建模方法^[20]相比，具有物理意义明确，无须费时的训练过程等优点。当齿轮箱出现故障隐患时，其温度偏离正常状态，NSET 模型预测的残差的分布特

性发生改变。本文提出齿轮箱故障时温度残差分布变化的3种形式,采用滑动窗口连续实时地计算残差均值和标准差的变化趋势,并和设定阈值比较,得出齿轮箱当前的运行状态。通过对某机组齿轮箱温度 SCADA 数据及人为模拟的齿轮箱故障的分析,新方法能够及时检测出齿轮箱工作状态的异常变化,验证了新方法的有效性。

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[C]//Proceeding of European Wind Energy Conference, Poland, 2010.
- [2] Hameed Z, Hong Y S, Cho Y M, et al. Condition monitoring and fault detection of wind turbines and related algorithms: a review[J]. Renewable and Sustainable Energy Reviews, 2009, 13(1): 1-39.
- [3] Amirat Y, Benbouzid M, Al-Ahmar E. A brief status on condition monitoring and fault diagnosis in wind energy conversion systems[J]. Renewable and Sustainable Energy Reviews, 2009, 13(9): 2629-2636.
- [4] Lu Bin, Li Yaoyu, Wu Xin. A review of recent advance in wind turbine condition monitoring and fault diagnosis [C]//Proceedings of Power Electronics and Machines in Wind Application, Lincoln, 2009: 1-7.
- [5] Zaher A, McArthur S D J, Infield D G, et al. Online wind turbine fault detection through automated scada data analysis[J]. Wind Energy, 2009, 12(6): 574-593.
- [6] Yang Wenxian, Tavner P J, Crabtree C J, et al. Cost-effective condition monitoring for wind turbines[J]. IEEE Trans Industrial Electronics, 2010, 57(1): 263-271.
- [7] Simon J W, Xiang B J, Yang Wenxian. Condition monitoring of the power output of wind turbine generators using wavelets[J]. IEEE Trans. on Energy Conversion, 2010, 25(3): 715-721.
- [8] Yang W, Tavner P J, Wilkinson M R. Condition monitoring and fault diagnosis of a wind turbine synchronous generator drive train[J]. Renewable Power Generation, 2009, 3(1): 1-11.
- [9] Wilkinson M R, Tavner P J. Condition monitoring of generators & other subassemblies in wind turbine drive trains[J]. Proceedings of IEEE International Symposium on Diagnostics for Electric Machines, Power Electrics and Drives, Cracow, 2007.
- [10] Gross K C, Singer R M, Wegerich S W, et al. Application of a model-based fault detection system to nuclear plant signals[C]//Proceedings of 9th International Conference on Intelligent Systems Application to Power System, Seoul, Korea, 1997.
- [11] 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, CA, 1998.
- [12] 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, VA, 2007: 26-32.
- [13] 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, D.C., USA, 2002.
- [14] Singer R M, Gross K C, Herzog J P, et al. Model-based nuclear power plant monitoring and fault detection: theoretical foundation[C]//Proceedings of 9th International Conference on Intelligent Systems Application to Power System, Seoul, Korea, 1997.
- [15] Black C L, Uhrig R E, Hines J W. System modeling and instrument calibration verification with a nonlinear state estimate technique[C]//Proceedings of Maintenance and Reliable Conference, Knoxville, TN, 1998.
- [16] Wesley Hines J, Dustin Garvey. Process and equipment monitoring methodologies applied to sensor calibration monitoring[J]. Quality and Reliability Engineering International, 2007, 23(1): 123-135.
- [17] Hines J W, Garvey D R. Nonparametric model-based prognostics[C]//Proceedings of Reliability and Maintainability Symposium, Las Vegas, 2008: 469-474.
- [18] Kusiak A, Li Wenyan. The prediction and diagnosis of wind turbine faults[J]. Renewable Energy, 2011, 36(1): 16-23.
- [19] Sheng Zhou, Xie Shiqian, Pan Chengyi. Probability theory and statistics[M]. Beijing: High Education Press, 2010.
- [20] Hines J W, Uhrig R E, Wrest D J. Use of autoassociative neural networks for sensor validation[J]. Journal of Intelligent and Robotic Systems, 1998, 21(2): 143-154.



郭鹏

收稿日期: 2011-04-12。

作者简介:

郭鹏(1975),男,博士,副教授,研究方向为大型风电机组控制技术与状态监测,现在英国斯特莱斯克莱德大学作访问学者, huadiangp@163.com。

(责任编辑 张媛媛)