

采用趋势状态分析的风机齿轮箱状态 在线评估云模型

方瑞明, 江顺辉, 尚荣艳, 王黎

(华侨大学 信息科学与工程学院, 福建 厦门 361021)

摘要: 为预防风机齿轮箱严重故障的发生,提出了一种结合正态云模型和趋势状态分析法的齿轮箱状态评估模型.首先,基于数据采集与监控(SCADA)系统的历史数据,采用支持向量机方法建立齿轮箱运行温度预测模型,对齿轮箱不同状态下的趋势预测特征进行分析,求取正常和异常状态时预测值的相对误差序列.然后,采用改进无确定度逆向正态云发生器,利用所求取的相对误差序列提取正常云和异常云的数字特征,构建齿轮箱状态评估云模型.该模型能够根据风机 SCADA 系统的实测数据,求取齿轮箱当前状态对正常云和异常云的贴进度,并采用最大贴进度原则确定齿轮箱状态.最后,利用辽宁某风机齿轮箱的实测数据对所提模型进行验证.结果表明:该模型能够对齿轮箱的早期缺陷及时预警,达到实时监测的目的.

关键词: 齿轮箱; 风电机组; 正态云模型; 趋势状态分析; 逆向正态云发生器

中图分类号: TM 715 **文献标志码:** A

大型风电机组中,齿轮箱的故障率虽然不高,但是其维修、更换和停机损失的总费用却很昂贵^[1].因此,对齿轮箱进行实时状态监测,及时发现异常,对降低齿轮箱运维成本和提高机组可靠性具有重大意义.现代风电机组大多建立了联接机组、气象站和远程计算机的数据采集与监控(SCADA)系统,能够提供全面的设备监测数据,因而,被越来越多地应用于实现齿轮箱的状态监测^[2-4].其中,齿轮箱运行温度的趋势状态分析法是齿轮箱状态监测的一种有效方法.其基本思想是基于历史数据建立齿轮箱运行温度预测模型,并利用该模型对齿轮箱的运行温度进行预测,当预测趋势背离实际演化趋势时,认为齿轮箱状态出现了异常.由于其概念清晰、实现方便,得到了广泛应用^[2-7].然而,在实际应用中,由于齿轮箱不同状态转换时,其温度边界具有模糊性和不确定性的特征.因此,如何判断趋势状态转换一直是制约该方法应用的难题^[3-4].正态云模型理论能够综合反映定性概念的模糊性和随机性^[8],国内外学者将其应用于不同领域的设备进行状态评估和诊断^[9-14],取得了较好效果.逆向正态云发生器能够从量化数据中提取定性概念正态云模型的数字特征,将趋势预测数据准确映射到定性状态空间.因而,为了解决趋势状态分析法所存在的问题,本文提出了基于趋势状态分析法的风机齿轮箱状态在线评估云模型.

1 基于 SVM 的齿轮箱运行温度预测模型

支持向量机(SVM)具有模型简单、全局优化、样本数量少、收敛速度快、泛化能力强等特点,其基本原理参考文献[15].文中采用 SVM 建立齿轮箱运行温度的预测模型.

1.1 SVM 回归建模算法

对于给定的已知样本 $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$, $x_i \in \mathbf{R}^n, y_i \in \mathbf{R}, i=1, 2, \dots, N$, x_i 为输入量, y_i

收稿日期: 2015-08-15

通信作者: 方瑞明(1972-),男,教授,博士,主要从事电力设备在线监测与故障诊断等的研究. E-mail:fangrm@126.com.

基金项目: 国家自然科学基金资助项目(51177039);福建省自然科学基金资助项目(2012J01223);福建省厦门市重大科技创新平台项目(3502Z20111008)

为输出量. SVM 利用核函数 $k(x, \mathbf{x}_i)$ 把低维非线性输入空间映射到高维特征空间, 并在此空间中进行线性回归, 得到回归函数为

$$f(x) = \sum_{i=1}^N (\bar{\alpha}_i - \bar{\alpha}_i^*) k(x, \mathbf{x}_i) + \bar{b}. \quad (1)$$

式(1)中: N 表示样本个数; $\bar{\alpha}_i$ 和 $\bar{\alpha}_i^*$ 为拉格朗日乘子; \mathbf{x}_i 是输入值; $k(x, \mathbf{x}_i)$ 为核函数; \bar{b} 为偏置系数.

由于齿轮箱运行温度预测模型是高度非线性模型, 故采用高斯函数作为该模型的核函数. SVM 预测模型中, 文中采用网格法和十折交叉验证法对惩罚系数和核宽参数进行寻优^[15], 确定最优参数组合.

1.2 预测模型输入输出量的选取

以辽宁某风电场的风机齿轮箱为对象, 其 SCADA 系统采样频率为每分钟 1 次. SCADA 系统包含了 47 项连续监测指标. 其中, 齿轮箱的监测指标包括齿轮箱输入轴温度、齿轮箱输出轴温度、齿轮箱油温和主轴齿轮箱侧轴承温度. 采用 SPSS 19.0 软件的变量相关性分析功能, 对齿轮箱各温度指标进行相关性分析. 以齿轮箱输入轴温度为例, 分析结果表明: 其与齿轮箱输出轴温度、齿轮箱油温、发电机转速、叶轮转速及主轴齿轮箱侧轴承温度高度相关, Pearson 相关系数在 $[0.8, 1.0]$ 范围内. 因而, 以上述相关变量的当前值及齿轮箱输入轴温度上一时刻值作为 SVM 模型输入, 以齿轮箱输入轴温度作为 SVM 模型输出, 建立齿轮箱输入轴温度预测模型.

2 预测趋势状态的描述

基于齿轮箱正常状态时的历史数据建立齿轮箱运行温度预测模型后, 将其用于齿轮箱运行温度预测. 当齿轮箱状态正常时, 趋势状态分析法能够准确挖掘指标参数的非线性关系, 得出的参数预测值可较好地拟合真实值, 预测误差较小; 而若齿轮箱处于异常状态时, 其参数内部关系发生变化, 已由当前关系转移至其他不确定的关系, 导致参数趋势的变化并不在预测算法的“记忆”中, 此时, 参数预测效果必然较差, 导致误差值很大. 因此, 可以采用预测误差的变化序列描述齿轮箱趋势状态的演化过程.

考虑到相对误差较绝对误差更能反映预测的可信程度^[16], 比方根误差计算更简单. 因此, 采用齿轮箱运行温度的预测相对误差序列描述其趋势状态的演化过程, 即

$$e_{\text{RE}} = \left| \frac{y_{\text{p},i} - y_{\text{c},i}}{y_{\text{c},i}} \right| \times 100\%, \quad 1 \leq i \leq n. \quad (2)$$

式(2)中: $y_{\text{p},i}$ 表示预测值; $y_{\text{c},i}$ 表示实际值; n 表示实际值或真实值的个数.

3 正态云模型及状态评估策略

3.1 正态云模型理论

正态云模型可用 3 个数字特征 (E_x, E_n, H_e) 表征^[17]. 其中: 期望值 E_x 是最能够代表定性概念的数值; 熵 E_n 反映定性概念的模糊程度; 超熵 H_e 反映代表定性概念值的样本出现的随机性, 揭示了模糊性和随机性的关联. 正态云发生器包括正向正态云发生器、逆向正态云发生器和条件正态云发生器^[18]. 其中, 逆向正态云发生器能够基于统计学原理, 对数据序列进行挖掘, 将一定数量的精确数据转换为以数字特征 (E_x, E_n, H_e) 表示的定性概念, 从而实现从定量值到定性概念的转换. 因此, 文中采用逆向正态云发生器生成状态评估云模型.

3.2 改进无确定度逆向正态云发生器求取云数字特征

在利用逆向正态云发生器生成齿轮箱状态评估云模型时, 预测相对误差序列不包括属于定性概念的确定度信息. 因此, 采用无确定度的逆向正态云发生器建模. 但是, 传统无确定度的逆向正态云发生器生成状态云数字特征时, 由于超熵 $H_e = \sqrt{S^2 - E_n^2}$, 计算过程如果出现方差 S^2 小于 E_n^2 的情况, 则会导致超熵 H_e 的结果为虚数而无法计算. 考虑到熵 E_n 已是全局最优解^[19], 采用以下 5 个步骤改进算法.

步骤 1 根据数据样本 x_i , 计算样本均值 \bar{X} , 一阶样本绝对中心距 A , 样本方差 S^2 , 计算式为

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i, \quad (3)$$

$$A = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{X}|, \quad (4)$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2. \quad (5)$$

步骤 2 $E_x = \bar{X}$.

步骤 3 $E_n = \sqrt{\pi/2} \times A$.

步骤 4 若 $S^2 - E_n^2 < 0$, 则删除 $m = n \times 1\%$ 个离期望 E_x 最近的样本点, 在剩余样本中, 重新计算方差 S^2 , 直到 $S^2 - E_n^2 > 0$, 再跳转步骤 5; 若 $S^2 - E_n^2 > 0$, 直接跳转步骤 5.

步骤 5 $H_e = \sqrt{S^2 - E_n^2}$.

3.3 齿轮箱定性概念评估策略

若把数 x 作为一个云滴, y 表示数 x 对正态云模型的关联程度, 则称 y 为云滴关联度, 其可由 X 条件发生器求取. 具体有以下 3 个步骤.

步骤 1 $E'_n = \text{normrnd}(E_n, H_e^2)$.

步骤 2 $y' = \exp(-(x_0 - E_x)^2 / (2E_n'^2))$.

步骤 3 所求云滴关联度 y' 不是一个数值, 而是小范围内的随机数集合. 计算随机数的平均值, 即 $y = \sum_{i=1}^k y'_i / k$, 最终确定云滴关联度 y .

李德仁^[18]指出, 定性概念的正态云模型中, 99.74% 的云滴均位于 $(E_x - 3E_n, E_x + 3E_n)$ 区间内, 若将这个区间视为一个集合, 则正态云模型 C1 和 C2 之间的关联度 k 可定义为

$$k = \frac{|N|}{|M|}. \quad (6)$$

式(6)中: N 和 M 分别表示区间交集和并集, 即

$$N = \{(E_x^1 - 3E_n^1, E_x^1 + 3E_n^1) \cap (E_x^2 - 3E_n^2, E_x^2 + 3E_n^2)\}, \quad (7)$$

$$M = \{(E_x^1 - 3E_n^1, E_x^1 + 3E_n^1) \cup (E_x^2 - 3E_n^2, E_x^2 + 3E_n^2)\}. \quad (8)$$

贡献度表示正态云模型间的关联度对区分不同定性概念的贡献程度, 关联度越大, 则其对区分定性概念的贡献越小, 反之则越大. 贡献度的计算式为

$$w_i = \frac{1 - k_i}{\sum (1 - k_i)}. \quad (9)$$

贴近度表示样本对不同定性概念正态云模型的贴近程度, 计算式为

$$\rho_i = y_{i,j} \times w_j, \quad i = 1, \dots, m, \quad j = 1, \dots, n. \quad (10)$$

式(10)中: ρ_i 表示定性概念正态云模型贴近度; $y_{i,j}$ 表示状态 i 的第 j 个指标的云滴关联度; w_j 表示第 j 个指标的贡献度.

将齿轮箱运行状态评估为正常(ρ_1)或异常(ρ_2), 按照最大贴近度的原则确定齿轮箱状态, 即若 $\rho_1 > \rho_2$, 则判定齿轮箱为正常状态; 若 $\rho_1 \leq \rho_2$, 则判定齿轮箱为异常状态.

4 齿轮箱状态在线评估流程

基于风电机组的 SCADA 系统实时监测数据, 利用上述模型对风机齿轮箱状态在线评估, 具体有以下 4 个步骤.

步骤 1 基于 SCADA 系统历史数据, 采用 SVM 建立齿轮箱各温度指标正常状态下的预测模型, 分别将正常和异常的监测数据作为模型输入, 进行温度预测, 并计算相对误差指标 $e_{i,j,k}$ ($i=1, 2; j=1, 2, 3, 4; k=1, \dots, t$). 其中, $i=1$ 表示正常状态, $i=2$ 表示异常状态; $j=1, 2, 3, 4$ 表示齿轮箱各温度指标; k 表示预测样本序号.

步骤 2 采用改进无确定度逆向正态云发生器, 从相对误差序列 $e_{i,j,k}$ 中分别求取各指标正常状态云和异常状态云的数字特征, 并根据式(6)和式(9)计算不同状态云之间的关联度 k_j 和贡献度 w_j .

步骤 3 获取实时 SCADA 数据作为 SVM 温度模型的输入, 求取齿轮箱各指标的相对误差, 进而

计算得到云滴关联度 $e_{i,j}$, 结合所求正态云模型间关联度 k_j 和贡献度 w_j , 综合计算待测试样本对正常和异常正态云模型的贴近程度 ρ_1 和 ρ_2 .

步骤 4 根据最大贴近度原则, 确定齿轮箱状态.

5 实例分析

5.1 齿轮箱不同状态时预测趋势特征

利用风电机组齿轮箱的 SCADA 系统的历史监测数据, 选取该风机齿轮箱在半个月内的正常状态监测数据作为训练数据, 对所建立的 SVM 模型进行训练, 得到齿轮箱运行温度预测模型. 以齿轮箱输入轴温度为例, 对齿轮箱不同状态下的运行温度趋势预测特征进行分析. 齿轮箱输入轴温度正常状态时的预测结果, 如图 1 所示. 图 1 中: θ 为齿轮箱输入轴温度; η 为正常状态下预测相对误差. 由图 1 可知: 该风机齿轮箱输入轴温度正常状态时, 其平均预测相对误差为 0.45%, 最大相对误差为 1.19%. 可见, 模型的预测精度较高, 能够准确反映齿轮箱输入轴温度正常状态时的趋势变化.

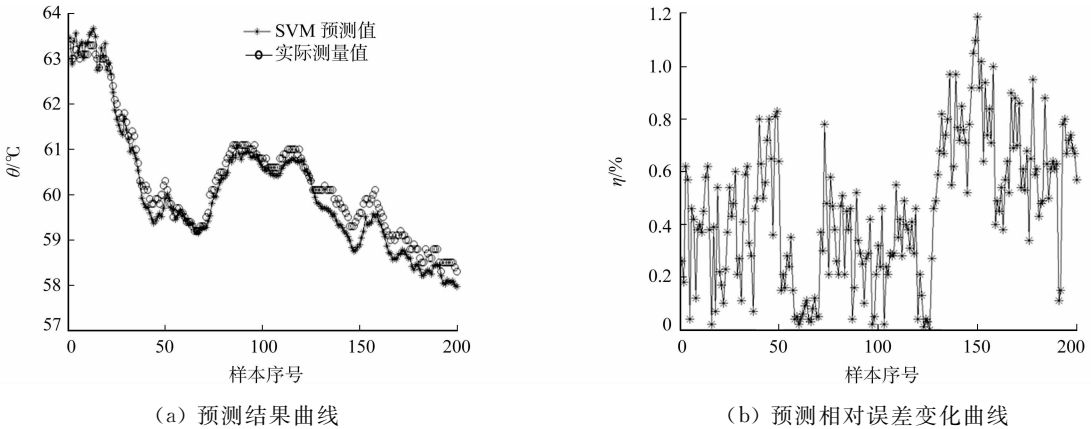


图 1 齿轮箱输入轴温度正常状态时的预测结果

Fig. 1 Gearbox input shaft temperature predictions of normal condition

该风电机组 SCADA 系统在 2012 年 1 月 22 日 2 时 41 分时发出齿轮箱故障警报. 齿轮箱输入轴温度异常状态时的预测结果, 如图 2 所示. 图 2 中: θ 为齿轮箱输入轴温度; η' 为异常状态下预测相对误差. 由图 2 可知: 异常状态时, 平均预测相对误差为 18.07%, 最大相对误差为 24.44%. 显然, 由于齿轮箱预测模型是根据正常状态的数据所建立, 因而当齿轮箱状态发生异常时, 其趋势状态的变化特征无法被准确描述.

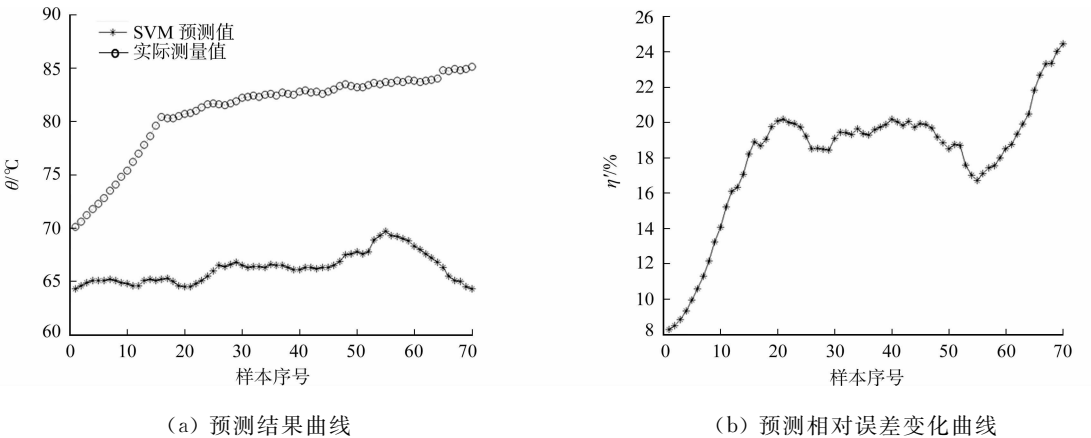


图 2 齿轮箱输入轴温度异常状态时的预测结果

Fig. 2 Gearbox input shaft temperature predictions of abnormal condition

5.2 正态云模型的数字特征

分别求取齿轮箱 4 个温度指标在正常和异常状态时的预测相对误差序列, 即可得到齿轮箱各温度指标不同趋势状态下的特征数据.

以齿轮箱输入轴温度为例,将正常样本的预测相对误差序列作为改进无确定度逆向正态云发生器的输入,得到正常正态云模型的数字特性为 $(E_{x,1},E_{n,1},H_{e,1})=(0.45,0.28,0.02)$.在超熵 $H_{e,1}$ 的计算过程中,若采用传统发生器,得到的结果为虚数 $0.26i$,采用改进发生器剔除 22 个样本点后,在剩余 178 个样本点中,重新计算得到 $H_e=0.02$.同理,异常正态云模型的数字特征为 $(E_{x,2},E_{n,2},H_{e,2})=(13.97,5.36,0.33)$.齿轮箱各指标状态的正态云模型数字特征,如表 1 所示.

表 1 各指标正态云模型的数字特征
Tab. 1 Normal cloud model digital features of each index

指标	齿轮箱输入轴	齿轮箱输出轴	齿轮箱油	主轴齿轮箱侧轴承
正常云	(0.45,0.28,0.02)	(0.82,0.62,0.17)	(0.60,0.48,0.17)	(0.62,0.44,0.56)
异常云	(13.97,5.36,0.33)	(23.92,8.32,1.55)	(17.39,6.35,0.62)	(18.67,7.42,0.56)

5.3 齿轮箱状态在线评估可行性验证

该机组于 2012 年 3 月 21 日 14 时 27 分发出齿轮箱故障警报.获取该故障发生前 3 个小时内的 SCADA 系统数据,共 180 组监测数据,应用文中模型对其状态进行在线评估.齿轮箱状态对于正常云和异常云的贴进度变化曲线,如图 3 所示.图 3 中: ρ 为正态云模型贴进度.由图 3 可知:在前半部分,正常云的贴进度曲线存在波动,但其值明显大于异常云的贴进度;在后半部分,正常贴进度快速下降为 0,而异常贴进度迅速上升至较大数值.因此,所提模型能够直观描述齿轮箱由正常状态向异常状态的转换过程.

根据最大贴进度原则,对该机组齿轮箱状态进行实时评估,在线评估结果如图 4 所示.由图 4 可知:在第 105 个样本点处,采用文中所提模型评估齿轮箱为异常状态.与原系统相比,所提模型能够提前 76 min 对齿轮箱的早期缺陷进行及时预警.




图 3 正态云模型贴进度变化曲线
Fig. 3 Variation curve of normal cloud model closeness degree




图 4 齿轮箱状态在线评估结果
Fig. 4 Gearbox condition online assessment results

6 结束语

提出基于趋势状态分析的风机齿轮箱状态在线评估云模型,以某风电机组故障前一段时间内的 SCADA 数据对所提模型的可行性进行验证.结果表明:文中模型能够根据贴进度的变化在线评估齿轮箱状态,及时发现出齿轮箱的异常状态,有助于防范齿轮箱严重故障的发生,提高风电机组安全性、可靠性和经济性.

参考文献:

[1] TAVNER P J,XIANG J,SPINATO F. Reliability analysis for wind turbines[J]. Wind Energy,2007,10(1):1-18.
[2] YUE Wang,INFIELD D. Supervisory control and data acquisition data-based non-linear state estimation technique for wind turbine gearbox condition monitoring[J]. IEEE Transactions on Renewable Power Generation,2013,7(4): 350-358.
[3] 郭鹏,INFIELD D,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.

[4] 赵洪山,胡庆春,李志为. 基于统计过程控制的风机齿轮箱故障预测[J]. 电力系统保护与控制,2012,40(13):67-73.

[5] 郭鹏,李淋淋,马登昌. 基于 IPSO-BP 的风电机组齿轮箱状态监测研究[J]. 太阳能学报,2012,33(3):439-445.

[6] QIU Yingning,SUN Juan,CAO Mengnan,et al. Model based wind turbine gearbox fault detection on SCADA data [C]//IET Conference on Renewable Power Generation. Naples:IEEE Press,2014:1-5.

[7] 赵洪山,郭伟,邵玲,等. 基于子空间方法的风机齿轮箱故障预测算法[J]. 电力自动化设备,2015,35(3):27-32.

[8] 李德毅,刘常昱,杜鹁,等. 不确定性人工智能[J]. 软件学报,2004,15(1):1583-1594.

[9] 李如琦,苏浩益. 基于可拓云理论的电能质量综合评估模型[J]. 电力系统自动化,2012,36(1):66-70.

[10] ZHOU Quan,WANG Shizheng,AN Wendou,et al. Power transformer fault diagnosis based on DGA combined with cloud model[C]// International Conference on High Voltage Engineering and Application. Poznan: IEEE Press,2014:1-4.

[11] SUN Yong,LI Zenglu,MENG Hong,et al. Fault diagnosis of flight control system based on correction high dimensional cloud model[C]// International Conference on Computer Science & Service System. Nanjing:IEEE Press, 2012:1793-1797.

[12] 董磊,阎芳,王鹏. 基于修正高维云的故障映射模型[J]. 系统工程与电子技术,2015,37(2):354-359.

[13] 徐岩,陈昕. 基于合作博弈和云模型的变压器状态评估方法[J]. 电力自动化设备,2015,35(3):88-93.

[14] 梁永亮,李可军,牛林,等. 变压器状态评估多层次不确定模型[J]. 电力系统自动化,2013,37(22):73-78.

[15] 方瑞明. 支持向量机理论及其应用分析[M]. 北京:中国电力出版社,2007:15-17.

[16] 陈雪娟,吴春华,李智华,等. 基于灰色预测的光伏组件阴影类型诊断研究[J]. 电网技术,2014,38(14):3293-3299.

[17] 凌武能,杭乃善,李如琦. 基于云支持向量机模型的短期风电功率预测[J]. 电力自动化设备,2013,33(7):34-38.

[18] 李德仁. 空间数据挖掘理论与应用[M]. 北京:科学出版社,2013:149-155.

[19] 刘常昱,李德毅,杜鹁,等. 正态云模型的统计分析[J]. 信息与控制,2005,34(2):236-239.

Online Wind Turbine Gearbox Condition Assessment
Cloud Model Using Trend Condition Analysis

FANG Ruiming, JIANG Shunhui, SHANG Rongyan, WANG Li

(College of Information Science and Engineering, Huaqiao University, Xiamen 361021, China)

Abstract: To prevent wind turbine gearbox severe faults occurrence, combined normal cloud model and trend condition analysis, this paper presents a novel condition assessment model. Firstly, based on supervisory control and data acquisition (SCADA) historical data, the forecasting model of gearbox operating temperature is established by adapting SVM, and the relative errors sequence of the forecasting values under normal and abnormal conditions are calculated after analyzing characteristics of trend forecasting. Then, inputting the relative errors sequence into improved backward normal cloud generator with the non-certainty degree, the digital features of normal and abnormal cloud model are obtained. Furthermore, the gearbox condition assessment cloud model is given, which is based on online SCADA data of wind turbine to calculate the closeness degree of normal and abnormal cloud model for gearbox current condition, and use the principle of maximum closeness degree to determine the gearbox condition. Finally, the proposed model is verified by online data of a wind turbine gearbox in Liaoning province, the results show that this model is capable of alarming early defects timely of a gearbox, achieving the aim of online condition assessment.

Keywords: gearbox; wind turbine; normal cloud model; trend condition analysis; backward cloud generator

(责任编辑: 黄晓楠 英文审校: 吴逢铁)