

非线性状态估计法在风电齿轮箱故障预警中的应用

王志强¹, 王志华², 张秀云³, 王旭龙¹, 周海松¹, 李小鹏¹

(1. 天津职业技术师范大学 汽车与交通学院, 天津 300222; 2. 河北工业大学 电气工程学院, 天津 300130;
3. 河北工业大学 控制科学与工程学院, 天津 300130)

摘要: 针对现阶段在齿轮箱的状态监测方法中遇到的问题, 提出一种以易于采集的油温信号来对齿轮箱故障进行预警的分析方法; 通过非线性状态估计法 (nonlinear state estimate technology) 建立齿轮箱的温度预测模型, 之后根据统计温度预测残差的变化趋势, 然后通过验证集合确定出的残差均值和标准差的故障阈值进行对比, 以实现及早发现齿轮箱的潜在故障, 优化运行的效果; 并且与神经网络预测方法进行对比分析, 结果表明非线性状态估计法对风电齿轮箱进行故障预警有着较好的效果。

关键词: 非线性状态估计; 故障预警; 神经网络

Fault Prediction in Gear Box of Wind Turbines Based on Nonlinear State Estimate Technology

Wang Zhiqiang¹, Wang Zhihua², Zhang Xiuyun³, Wang Xulong¹, Zhou Haisong¹, Li Xiaopeng¹

(1. School of Automotive and Transportation, Tianjin University of Technology and Education, Tianjin 300222, China; 2. School of Electrical Engineering, Hebei University of Technology, Tianjin 300130, China;
3. School of Control Science and Engineering, Hebei University of Technology, Tianjin 300130, China)

Abstract: Aiming at the problem of condition monitoring method in the gearbox, it puts forward a new analysis method of gear box fault based on the oil temperature collected easily and establishes the temperature model of gear box by (nonlinear state estimate technology) NSET method to predict the temperature of the gear box. It is when gear box runs abnormally that the statistical features of the temperature prediction residual change largely to detect the fault of gearbox early. A statistical method is used to detect the changes of the residual mean value and standard deviation. When one of these parameters exceeds predefined thresholds, an incipient failure was flagged. And compared with neural network forecasting method, it highlights the advantages of this method.

Keywords: nonlinear state estimate technology; fault prediction; neural network

0 引言

在我国, 风电机组故障率的增高和维护成本的增加使得对其状态监测和故障预警和诊断技术要求更高^[1]。风电机组如果发生故障, 不仅仅会影响到风机自身的利用率, 还会严重影响发电量, 造成很大的经济损失, 增加高额的维护成本。并结合实际的调查可知, 目前齿轮箱油温高是齿轮箱故障报警中概率较高的一项, 在这种情况下, 如果油温达不到齿轮箱最高承受的极限值, 一般不会选择停机检查, 而只能降功率运行, 这不仅造成了风机本身的浪费, 也造成了不必要的经济损失。

从齿轮箱的原理来看, 齿轮箱结构复杂, 且组件间相互关联度高, 所以在分析齿轮箱故障时, 不能单一地只分析发生故障的部件, 而是要综合考虑齿轮箱内部各个部件的关联性, 之后建立动态、多变量的模型, 再进行分析^[2-5]。

1 非线性状态估计法

本文选取某一时刻的过程或设备的观测向量 \mathbf{X}_{obs} 作为

NSET 的输入, 选取该输入的预测向量 \mathbf{X}_{est} 作为模型的输出。设对任意输入的一个观测向量 \mathbf{X}_{obs} , NSET 都相对应地生成一个 m 维的权值向量为:

$$\mathbf{W} = [\omega_1 \quad \omega_2 \quad \cdots \quad \omega_m]^T \quad (1)$$

使得:

$$\mathbf{X}_{est} = \mathbf{D} \cdot \mathbf{W} = \omega_1 \cdot \mathbf{X}(1) + \omega_2 \cdot \mathbf{X}(2) + \cdots + \omega_m \cdot \mathbf{X}(m) \quad (2)$$

之后确定过程记忆矩阵 \mathbf{D} :

$$\mathbf{D} = [\mathbf{X}^N(1) \quad \mathbf{X}^N(2) \quad \cdots \quad \mathbf{X}^N(M)] = \begin{bmatrix} x_1^N(1) & x_1^N(2) & \cdots & x_1^N(M) \\ x_2^N(1) & x_2^N(2) & \cdots & x_2^N(M) \\ \vdots & \vdots & \cdots & \vdots \\ x_5^N(1) & x_5^N(2) & \cdots & x_5^N(M) \end{bmatrix}_{5 \times M} \quad (3)$$

然后确定权值向量 \mathbf{W} , 方法如下, 首先求输入和输出的残差 ϵ :

$$\epsilon = \mathbf{X}_{obs} - \mathbf{X}_{est} \quad (4)$$

之后对残差进行极小化变化, 求得权值向量 \mathbf{W} :

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

式中, \otimes 表示非线性运算符, 这种非线性运算符可以有多种选择, 经过查阅资料与反复验证, 本文选取为两向量间的 Euclidean 距离, 即

$$\otimes(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (6)$$

欧式距离反应向量间的相似程度, 距离越近就越相似。所

收稿日期: 2014-01-09; 修回日期: 2014-03-21。

基金项目: 国家自然科学基金青年基金项目(51107030); 河北省自然科学基金青年基金资助项目(E2012202070); 天津职业技术师范大学科研发展基金项目(KJY1304); 天津市科学技术普及项目(13KPKXM01SY016); 天津职业技术师范大学科研发展基金项目(KJ13-06)。

作者简介: 王志强(1987-), 男, 河南安阳人, 硕士研究生, 主要从事新能源技术方向的研究。

以当距离为 0 或接近 0 时,表明两向量相同或相似;当距离越大时,表明两向量差异也就越大。本文中输入观测向量与过程记忆矩阵 D 中各向量的相似度用权值向量 W 代表,当 W 为 0 或接近 0 时,表明 NSET 模型输入观测向量与过程记忆矩阵相同或相似;反之,偏差越大^[6]。

把式 (5) 代入到式 (2) 中,求得预测的最后结果为:

$$X_{est} = D \cdot (D^T \otimes D)^{-1} \cdot (D^T \otimes X_{obs}) \quad (7)$$

由上可知:通过输入和预测输出的残差来判断预测的精度,当设备处于正常工作状态时, W 接近于 0,预测输出 X_{est} 就越接近于输入 X_{obs} ,残差越小,说明所获得的预测精度很高;当设备发生故障时, W 的值会变得相对很大,预测值 X_{est} 就会相对输入偏差很大,残差越大,说明预测值 X_{est} 精度下降^[7]。

得到残差之后,就需要采用一定方法将其直观反映出来,一般选取残差的均值和标准差来直观反映其大小和分布情况。

选取一段时间,记 NSET 模型的齿轮箱温度预测残差序列为:

$$\epsilon_{GT} = [\epsilon_1 \quad \epsilon_2 \quad \epsilon_3 \quad \dots \quad \epsilon_N \quad \dots] \quad (8)$$

连续 N 个残差的均值和标准差的计算公式为:

$$\bar{X}_\epsilon = \frac{1}{N} \sum_{i=1}^N \epsilon_i \quad (9)$$

$$S_\epsilon = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (\epsilon_i - \bar{X}_\epsilon)^2} \quad (10)$$

当齿轮箱处于正常工作状态时,NSET 模型预测残差表现为均值接近于 0,而且其标准差较小。但当出现故障时,NSET 温度模型预测残差的均值和标准差可能有 3 种表现形式:1) 残差的均值接近于 0,但其标准差会明显增大;2) 残差的均值明显偏离 0,但标准差变化不大;3) 残差的均值明显偏离 0,且标准差也明显增大。

为了能够及时检测出齿轮箱的故障隐患,就首先需要通过验证集合来确定出残差均值和标准差的故障阈值,之后用输入观测向量的残差均值和标准差与故障阈值相对比,如果超过阈值,则报警^[8]。

2 齿轮箱温度 NSET 建模及预测

2.1 数据选取及预测

本文以天威在内蒙古卓资山风电场 33 台风电机组 2 个月的 10 分钟运行数据作为研究对象,选取 2013 年 6 月 15 日~8 月 14 日齿轮箱在正常工作状态下的有效数据记录构造过程记忆矩阵 D ,并且每个观测向量都包含功率、风速、环境温度、齿轮箱温度、上一时刻齿轮箱温度 5 个值,再对这 5 个变量的测量值根据各自的极值进行归一化处理,使其实际测量值都映射在 $[0, 1]$ 区间内。之后就可以按照图 1 的模型图进行预测和残差的分析,在监测齿轮箱的运行状态的同时,及早发现其故障隐患。




图 1 NSET 模型状态监测结构图

2.2 模型结果分析与评价

选取输入向量 X_{obs} 数量 $m = 488$,记齿轮箱温度的 NSET

模型预测残差为:

$$\epsilon_{GT} = x_4 - x'_4 \quad (11)$$

式中, x_4 为 NSET 预测模型的输入观测向量中的齿轮箱温度分量; x'_4 为该输入对应的预测向量。




图 2 有故障时仿真图

图 2 结果表明,当机组处于停机状态时,输入观测向量中的功率 x_1 为 0,这时候,NSET 温度预测模型不会对输入向量预测,所以此时对应的温度预测值为 0,残差也为 0。预测残差大的点的位置及出现原因与表 1 中的两次停机相互对应,且这些点是成对出现的。除了这些点,NSET 模型的预测精度很高,预测残差绝大多数情况下在 0.005 以下。

表 1 验证结果中残差大的位置与原因

位置	原因
第 72 点	发生齿轮箱油超温停机
第 86 点	OK 机组重启
第 203 点	指令停机
第 212 点	OK 机组重启

3 神经网络与 NSET 建模对比

以机组 2013 年 6 月 15 日~8 月 14 日功率、风速、环境温度、上一时刻齿轮箱温度为该函数的输入数据,该时间段的齿轮箱温度为函数对应输出数据,以 8 月 15 日~8 月 18 日的无故障数据为该函数的测试数据,与真实数据进行对比。

3.1 BP 神经网络与 NSET 模型对比

BP 网络的隐层和隐层节点是否能够足够体现它的泛化能力,如果其泛化能力好的话,就可以采取全局逼近的办法逼近任意的非线性映射关系。但是也存在缺点,在网络的训练过程中过多的隐层和隐层节点会造成收敛速度变慢,训练时间变长,容易使模型陷入局部最小。另外 BP 网络要求人为调试一些参数如隐层个数等,这样通过人为经验或依赖经验公式,会加大网络学习负担,增强网络的冗余性^[9]。




图 3 BP 神经网络与 NSET 对比仿真图

图 3 为 BP 神经网络与 NSET 对比仿真图, 由对比可知, NSET 比 BP 神经网络的仿真结果精度更高, 并且 NSET 较 Elman 神经网络所用时间稍短些。

3.2 遗传算法优化 BP 神经网络与 NSET 模型对比

由美国 Holland 教授提出的遗传算法模拟自然界的遗传机制和生物进化论。通过 3 步完成: 选择、交叉和变异, 根据“优胜劣汰”进行选择, 在程序中一般用适应度函数进行选择, 保留适应度好的个体, 淘汰适应度差的个体, 如此反复循环, 一直到满足条件为止^[10-11]。




图 4 遗传算法优化 BP 神经网络与 NSET 对比仿真图

图 4 为遗传算法优化 BP 神经网络与 NSET 对比仿真图, 由对比可知, NSET 比遗传算法优化 BP 神经网络的仿真结果精度更高, 并且 NSET 较遗传算法优化 BP 神经网络所用时间稍短些, 但遗传算法优化 BP 与 BP 神经网络相比精度提高很多, 使预测误差一般控制在 0.1 以内。

3.3 遗传算法函数极值寻优—BP 神经网络与 NSET 模型对比

神经网络遗传算法函数极值寻优主要分为 BP 神经网络训练拟合和遗传算法极值寻优两方面。BP 神经网络预测精度的好坏和寻优结果有密切关系。BP 神经网络预测越准确, 寻优得到的最优值越接近实际最优值, 这就需要在网络训练时采用尽可能多的训练样本^[12-13]。




图 5 遗传算法函数极值寻优—BP 神经网络与 NSET 对比仿真图

图 5 为遗传算法函数极值寻优—BP 神经网络与 NSET 对比仿真图, 由对比可知, NSET 比遗传算法函数极值寻优—BP 神经网络的仿真结果精度稍好一点, 都能使训练预测误差一般控制在 0.01 以内。但是遗传算法函数极值寻优—BP 神经网络的预测误差变化幅度更大, 分布更加分散, 这在通过残差来预测故障这一点上可能效果就不如 NSET 更加明显、准确。但遗传算法函数极值寻优—BP 相比遗传算法优化 BP 和 BP 神经网络, 精度提高很多, 使预测误差一般控制在 0.01 内。

4 结论

本文所选用的非线性状态估计法是一种非参数的建模方法, 与神经网络不同的是, NSET 建模对每一个不同的新输入观测向量, 权值 W 是动态优化的, 是不同的, 因此, NSET 对每个新的输入观测向量的预测是个性化的, 权值 W 具有直观的物理意义。它的优势表现为建模算法简单、物理意义明确、便于在线使用和无须费时等。通过分析并总结选择出能够影响齿轮箱温度变化的过程变量, 之后选取过程记忆矩阵 D , 建立起 NSET 温度预测模型, 再通过统计温度预测残差的变化趋势来及早识别出齿轮箱的潜在故障。本文研究的故障预警技术在不增加硬件成本的情况下可以监测机组重要工作部件的运行状态, 并及时发现设备的故障隐患, 对风电场特别是潜力巨大的海上风电有重要的实际意义。

参考文献:

- [1] 杭俊, 张建忠, 程明, 等. 风力发电系统状态监测和故障诊断技术综述 (英文) [J]. 电工技术学报, 2013, 04: 261-271.
- [2] Song Z Y, Li J Q, Yang M G, et al. Rule-based fault diagnosis of hall sensors and fault-tolerant control of PMSM [J]. Chinese Journal of Mechanical Engineering, 2013, 04: 813-822.
- [3] Wu C Y, Liu J, Peng F Q, et al. Gearbox fault diagnosis using adaptive zero phase time-varying filter based on multi-scale chirplet sparse signal decomposition [J]. Chinese Journal of Mechanical Engineering, 2013, 04: 831-838.
- [4] 谢松汕, 许宝杰, 吴国新, 等. 基于 HMM/SVM 的风电设备故障趋势预测方法研究 [J]. 计算机测量与控制, 2014, 22 (1): 39-41.
- [5] 赵广社, 张希仁. 数据挖掘中的统计方法概述 [J]. 计算机测量与控制, 2003, 11 (12): 914-917.
- [6] 郭鹏, David Infield, 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, 32: 129-136.
- [7] Guo P. Wind turbine generator bearing Condition Monitoring with NEST method [A]. Control and Decision Conference (CCDC) [C]. 2012, 05: 235-239.
- [8] 常澍平, 郭江龙, 吕玉坤, 等. 非线性状态估计 (NSET) 建模方法在故障预警系统中的应用 [J]. 软件, 2011, 07: 57-60.
- [9] 时建峰, 程珩, 许征程, 等. 小波包与改进 BP 神经网络相结合的齿轮箱故障识别 [J]. 振动、测试与诊断, 2009, 03: 321-324.
- [10] 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, 01: 120-125.
- [11] 林盾, 陈俐. BP 神经网络在模拟非线性系统输出中的应用 [J]. 武汉理工大学学报, 2003, 27 (5): 731-734.
- [12] 王成宝, 任传祥, 尹唱唱, 等. 基于遗传算法的 BP 神经网络短时交通流预测 [J]. 山东交通科技, 2012, (5): 5-7, 12.
- [13] 杨柳, 刘建国. 基于改进粒子群细菌觅食算法的矿井控制研究 [J]. 计算机测量与控制, 2014, 22 (1): 113-115.