

基于 ANFIS 的风力发电机状态监测研究

张磊 李欣竹*

(河北工业大学 控制科学与工程学院,天津 300130)

摘要 针对风力发电机系统故障诊断中非线性和建模困难的问题,提出了一种风力发电机状态监测方法,利用从风力发电机的 SCADA 数据中挖掘出 20 种输入输出对应关系,分别建立了自适应模糊神经推理系统(ANFIS)模型,并给出了一种基于预测误差的概率分布函数的适用于所有模型的异常检测方法.使用 20 个模型单独进行状态诊断,得出诊断正确率.综合使用 20 个模型的状态诊断结果,得到了最终的判定结论,仿真结果表明:该方法能准确地诊断出风力发电机系统故障.

关键词 风力发电机; 状态检测; 自适应神经模糊推理系统

中图分类号 TM743 **文献标识码** A **文章编号** 1672-4321(2017)01-0092-04

The Reserch of Wind Turbine Condition Monitoring Based on ANFIS

Zhang Lei, Li Xinzhu

(School of Control Science and Engineering, Hebei University of Technology, Tianjin 300130, China)

Abstract With the continuous development of wind power industry, the number of installed wind power generator is increasing. Due to its complicated structure and poor working conditions, easily happened all kinds of faults. For the nonlinear problems and difficulty in modeling of wind turbine system fault diagnosis, this paper proposes a wind turbine monitoring system, using 20 different SCADA normal data developed 20 adaptive fuzzy neural inference system (ANFIS) model, and proposes a kind of can apply to all models of anomaly detection method, using the prediction error to evaluate the practicability of model in a simulated SCADA signal, comprehensive 20 anomaly detection results of the model, get the final decision to the conclusion that the simulation results show that the system can accurately diagnose the wind turbine system fault.

Keywords wind turbine; condition monitoring; ANFIS

随着风力发电机单机功率逐年增大,各种故障的发生频率也逐年上升,严重时会造成机组停机,影响风机正常作业,而且风力发电机组的重要部件都位于距离地面几十米的塔架上,维护检修费用极高,因此针对风力发电机组复杂的故障特征,设计一套风力发电机组状态监测系统就显得尤为重要^[1].近年来,不少研究学者对状态监测系统进行了研究,振动分析是目前最普遍的机器状态检测方法^[2],然而因为成本原因,振动传感器并不能安装在所有涡轮机和其他重要组件上,这就造成了数据的缺少,并不能监测所有异常情况;另一种方法就是使用风机运行过程中产生的大量 SCADA 数据来监测风电机组

状态.在文献[3]中,使用 SCADA 数据信息可以提前 5~60 min 预测出风机故障,但这并没有给风场工作人员预留出足够的时间来对设备完成改善工作.文献[4]和文献[5]都使用了神经网络理论,利用这种方法可以提前几天或者几周检测出信号变化,以达到监测状态预测故障的目的,但这两种方法经常发生故障漏检和误诊.在本文中,使用自适应神经模糊推理系统(ANFIS)来代替人工神经网络,ANFIS 模型可以通过设置一系列模糊规则学习非线性信号,并且在训练过程中调节隶属度函数的参数,根据 ANFIS 模型得到的预测误差判断风机的运行状态.

收稿日期 2016-08-10 * 通讯作者 李欣竹 研究方向:风力发电机故障诊断 E-mail: lixinzhu1005@163.com

作者简介 张磊(1977-)男 教授 博士 研究方向:风力发电机控制策略 E-mail: zhanglei@hebut.edu.cn

基金项目 河北省自然科学基金资助项目(F2015202231)

1 自适应神经模糊推理系统的工作原理

ANFIS 是一种基于 Takagi-Sugeno 模型的模糊推理系统, 它将模糊控制的模糊化、模糊推理和反模糊化 3 个基本过程全部用神经网络来实现, 通过离线训练和在线学习算法进行模糊推理控制规则的自调整, 使其系统本身朝着自适应、自组织、自学习的方向发展^[6]. ANFIS 由前件和后件构成, 其典型的模糊规则形式如下: 如果 x 是 A 且 y 是 B $z = f(x, y)$, 其中 A 和 B 是前件中的模糊集合, 而 $z = f(x, y)$ 是后件中的精确函数, 通常 $f(x, y)$ 是输入变量 x 和 y 的多项式, 假定 ANFIS 模型有两个输入 x 和 y , 以及一个输出 z , 那么有两条模糊 if-then 规则^[7].

规则 1: 如果 x 是 A_1 且 y 是 B_1 , 那么 $z_1 = p_1x + q_1y + r_1$;

规则 2: 如果 x 是 A_2 且 y 是 B_2 , 那么 $z_2 = p_2x + q_2y + r_2$.

其中 x, y 是输入, A_1, B_1, A_2, B_2 是模糊集, z_1, z_2 是输出规则.

2 ANFIS 模型的建立和异常检测

2.1 ANFIS 模型输入输出信号

正常运行的风力发电机的 SCADA 系统中有超过 150 种信号, 从时间、开关位置的数字表示和设置点, 到温度、电流电压等的连续测量值, 而这些连续测量值的最大值、最小值和十分钟内平均值都在 SCADA 系统中. 本文只使用风机正常运行时信号的十分钟平均值训练 ANFIS, 这样能排除由于瞬间变化造成的最大最小的峰值并减少了随机变化对诊断结果的影响.

每一种输入输出关系中, 输入信号数量是不同的, 相关的输入信号的选择非常重要, 这需要结合对建模系统的物理理解和先进的数据简化技术. 在输入信号的选择中, 不能单一的从提高模型的精度方面进行要求, 更重要的一点是故障的可判别性. 本文中使用了遗传算法结合偏最小二乘回归方法从大量的 SCADA 数据中挖掘出对应的输入输出信号, 有 20 种模型, 如表 1 所示.

表 1 20 个模型的输入输出信号
Tab.1 Input and output signals of 20 kind of models

编号	输入	输出
1	风速, 环境温度, 风向	输出功率
2	输出功率, 环境温度	发动机舱温度
3	输出功率, 发电机转速, 液压油温度	3#叶片高压变压器温度
4	输出功率, 发电机转速, 液压油温度	2#叶片高压变压器温度
5	输出功率, 发电机转速, 液压油温度	1#叶片高压变压器温度
6	发电机转速	无功功率
7	风速, 环境温度, 风向	3#叶片电机驱动电流
8	风速, 环境温度, 风向	2#叶片电机驱动电流
9	风速, 环境温度, 风向	1#叶片电机驱动电流
10	3#叶片电机驱动电流, 发动机舱温度, 发电机转速	3#叶片电机温度
11	2#叶片电机驱动电流, 发动机舱温度, 发电机转速	2#叶片电机温度
12	1#叶片电机驱动电流, 发动机舱温度, 发电机转速	1#叶片电机温度
13	输出功率, 发电机转速, 发动机舱温度	发电机滑环温度
14	输出功率, 发电机转速, 发动机舱温度	发电机轴承温度
15	风速, 桨距角	发电机转速
16	输出功率, 发电机转速, 发动机舱温度	齿轮箱油温度
17	发电机转速, 齿轮箱油温, 风速	齿轮箱轴承温度
18	桨距角, 风速, 风向	转子转速
19	1#叶片电机驱动电流, 1#叶片高压变压器温度	液压油温度
20	输出功率, 风速, 转子转速	桨距角

2.2 异常检测

在 ANFIS 用于实际工程中时, 隶属度函数的选取一般根据使用者的应用经验和试算^[9], 本文选择了高斯型隶属度函数, 每个隶属度函数的个数定位 5 个, ANFIS 的各初始参数都设置好, 输入训练数

据, 开始模型训练.

在一个 ANFIS 模型中, 使用同一个输入数据, 真实输出和 ANFIS 得到的输出之间的误差即为预测误差. 预测误差可以用下面的方程进行规范.

$$\bar{E}_{per}(\%) = \frac{\bar{E}}{3\sigma(\bar{E})} \times 100, \quad (1)$$

其中 \bar{E}_{per} 代表通过确定异常极限得到的误差百分比。

图1是以发电机转速、1#叶片电机驱动电流、输出功率和齿轮箱轴承温度为输出的模型在训练后得到的预测误差,所有模型的大部分的预测误差集中在零附近,证明建立的 ANFIS 模型能很好的拟合输入输出数据。

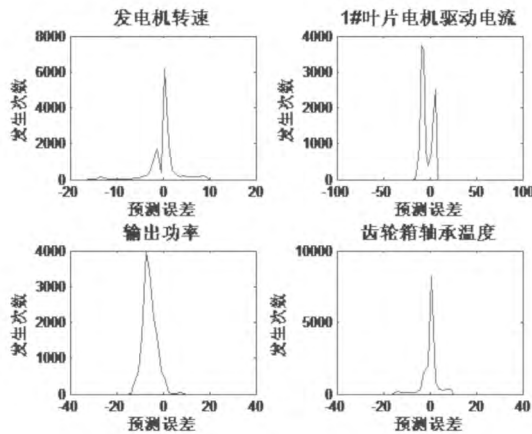


图1 ANFIS 训练后的预测误差

Fig.1 The prediction error after ANFIS training

ANFIS 模型训练时使用的是风机正常运行时的数据,所以当 SCADA 数据中的输出不符合 ANFIS 的预测输出,就说明设备发生了异常。本文提出了一种适用于所有模型的异常检测方法。该方法基于一个统计学假设,即正常数据在模型的高频率区域,而异常数据模型的低频率区域,即可以得到以下的异常检测标准:模型产生的预测误差在训练数据的预测误差中出现的概率等于或超过判定概率被认为是正常;模型产生的预测误差在训练数据的预测误差中出现的概率小于判定概率被认为是异常。

判定概率的选择决定了系统的敏感度,选择时需要在抑制假报警和检测出所有异常两方面进行权衡,本文选择 0.1% 作为判定概率。如图 2 是一个区分正常行为模型和异常行为模型的例子,判断依据是概率密度分布函数和模型的预测误差。

3 结果分析

3.1 生成的 20 种模型的性能比较

本文使用的正常数据来自于河北某 1.5MW 风场 9 个月的 SCADA 数据,用于验证的故障数据来自该风场的风机发生故障时的 SCADA 数据。正常数




图2 发电机转速模型误差概率分布

Fig.2 The error probability distribution of the generator speed model

据用于 ANFIS 建模,故障数据用于模型验证。使用以下指标检验建立的诊断模型的性能:

NN(Normal number) : 正常数据个数;

FN(Fault number) : 故障数据个数;

Nt(normal ture) : 将正常数据诊断为正常的次数;

Nf(normal false) : 将正常数据诊断为异常的次数(假警报);

Ft(fault ture) : 将异常数据诊断为异常的次数;

Ff(fault false) : 将异常数据诊断为正常的次数(漏检)。

NT: 将正常数据诊断为正常的比例。

$$NT = \frac{Nt}{NN}, \quad (2)$$

NF: 将正常数据诊断为异常的比例。

$$NF = \frac{Nf}{NN}, \quad (3)$$

FT: 将异常数据诊断为异常的比例。

$$FT = \frac{Ft}{FN}, \quad (4)$$

FF: 将异常数据诊断为正常的比例。

$$FF = \frac{Ff}{FN}, \quad (5)$$

t: 模型的诊断正确率。

$$t = \frac{Nt + Ft}{NN + FN}. \quad (6)$$

20 个模型经过正常数据的训练和故障数据的测试后,得到的性能指标如表 2 所示。

在这 20 个模型中编号 14 输入为输出功率,发动机转速,发动机舱温度,输出为发动机轴承温度,该模型的诊断正确率最高,达到了 91.03%,同时故障漏检率为 1.75%,在所有模型中也处于较高水平,该模型的模型性能最好。

表 2 20 种模型的模型性能
Tab.2 The performance of 20 kind of models

编号	NT/%	NF/%	FT/%	FF/%	t/%
1	86.70	13.30	90.50	9.50	87.28
2	88.04	11.96	64.79	35.21	84.45
3	87.76	12.24	97.94	2.06	89.33
4	88.21	11.79	95.13	4.87	88.90
5	87.76	12.24	95.13	4.87	88.90
6	80.19	19.81	99.13	0.87	83.11
7	80.69	19.31	96.16	3.84	83.08
8	79.87	20.13	96.75	3.25	82.48
9	80.46	19.54	98.84	1.16	83.30
10	88.68	11.32	97.38	2.62	90.02
11	88.99	11.01	98.17	1.83	90.40
12	87.28	12.72	97.86	2.14	90.36
13	89.14	10.86	97.96	2.04	90.50
14	89.71	10.29	98.25	1.75	91.03
15	81.10	18.90	95.45	4.55	83.31
16	87.87	12.13	99.18	0.82	89.62
17	87.90	12.10	99.10	0.90	89.63
18	81.58	18.42	98.84	1.16	84.24
19	88.68	11.32	97.43	2.57	90.03
20	74.70	25.30	97.41	2.59	78.72

3.2 生成的模型的综合应用

用 20 个模型虽然都能判断出风机的运行状态, 但单一模型的诊断正确率都不高, 所以对所有模型的诊断结果进行综合处理, 得到最后的诊断结果.

将所有模型的诊断结果 $e_i (i = 1, \dots, 20)$ 用 0 和 1 表示, 0 代表该模型判断风机运行状态为正常, 1 代表该模型判断风机发生了故障, 根据每一个模型的诊断正确率对其诊断结果分配权重, 然后对 e_i 求和, 即:

$$E = \frac{\sum_{i=1}^{20} e_i t_i}{\sum_{i=1}^{20} t_i}, \quad (7)$$

其中 E 是总判断结果, 若 E 属于 $[0, 0.5)$, 可判定风机正常运行, 若 E 属于 $[0.5, 1]$ 可判定风机发生故障.

20 个模型综合应用后, 模型性能如表 3 所示.

表 3 综合应用 20 种模型后的模型性能

Tab.3 The performance of integrated application of 20 kinds of models

NT/%	NF/%	FT/%	FF/%	t/%
98.27	1.73	99.54	0.46	95.54

由表 3 可知, 根据 20 个模型的诊断正确率对模型的诊断结果分配权重, 综合处理后, 总的诊断正确

率达到了 95.54%, 对比单一模型有了大幅度提高, 能满足风力发电机在状态监测要求.

4 结语

本文提出了一种通过 ANFIS 模型监测风力发电机状态的方法, 该方法基于 ANFIS 模型的输出预测误差的概率分布来判定异常, 判定概率的选择需要避免假警报和识别出所有异常两方面进行权衡. 该方法给了风力发电机操作者一个具体的工具, 通过挖掘大量的 SCADA 数据来寻找异常, 因为 SCADA 数据中包含几乎所有组件的运行数据, 所以它不仅监测风力发电机的关键组件, 也能监测目前的风力发电机状态监测系统不涉及的辅助设备.

该方法的适用性和精度取决于建立 ANFIS 模型的大量 SCADA 数据的可用性. 本文建立了 20 个输出信号的 ANFIS 模型, 这些输出信号同时也是其他模型的输入信号, 每一个单独模型的故障判别率并不高, 但将 20 个模型综合应用后能高效地识别故障, 对风场工作人员制定合理的维修保养计划具有重要意义.

(下转第 137 页)

市场行情也呈现出频繁波动的状况,交易亏损与质量安全等诸多问题不断涌现。这些问题从不同方面长期制约着我国粮食安全保障体系,因此,如何完善地方粮食储备机制,对于有效提升国内粮食安全保障水平和我国在“十三五”期间平稳发展有着至关重要的影响。新常态时期,国家粮食局进一步明确指出要实现稳中求进的平稳发展目标,保障国家“粮安工程”的顺利进行,并进行地方粮食储备机制的改革,在国家相关粮食政策指引下,湖北省内各地方粮管储备机构都应严格依照相关规章制度,行使具体的监管职能,不断提升地方储备外部监管机制的效率,为国内粮食安全提供充分的保障。此外,还需要不断调整地方储备管理机制,强化质量安全标准意识,以适应当前的需要。而粮食储备管理机制的改进,则能显著地提升粮食安全储备能力,为我国国民经济的平稳发展,提供切实可行的安全保障。

参 考 文 献

- [1] 党斌. 粮食仓储管理现状及科学保粮发展趋势[J]. 管理世界 2015(15):74-75.
- [2] 黄恩,陈会玲,程红莉,等. 食品安全政府监管规制差异的中美对比研究[J]. 中南民族大学学报(自然科学版) 2015(4):142-147.
- [3] 林大燕. 经济发展过程中粮食安全的现状、问题与对策—基于广西东兴市的调查[J]. 粮食流通技术 2014(6):2-4.
- [4] 李京福. 发达国家粮食储备管理制度的经验[J]. 世界农业 2016(1):84-87.
- [5] 李付才,曾海燕. 创新地方储备粮管理提升粮食安全保障能力[J]. 经营管理 2016(7):254-256.
- [6] 刘星. 东北地区粮食储备安全研究[D]. 长春:吉林大学 2013:47-51.
- [7] 李腾飞,亢霞. 新常态下中国粮食安全的价值取向与保障体系分析[J]. 中国科技论坛,2016(8):133-136.
- [8] 杨明君. 对新常态下实施国家粮食安全战略的认识和思考[J]. 粮食问题研究 2015(2):12-15.
- [9] 李腾飞,亢霞. “十三五”时期我国粮食安全的重新审视与体系构建[J]. 农业现代化研究,2016(4):658-661.
- [10] 周竹君,张正河. 城镇化对我国粮食刚性需求影响的研究[J]. 粮食科技与经济 2014(6):6-9.
- [11] 张爱国. 创新地方储备粮管理提升粮食安全保障能力[J]. 中国经贸导刊 2016(2):65-66.
- [12] 王新华,王锐. 地方战略储备粮的安全性与经济性协调发展问题研究[J]. 荆楚学刊 2015(6):41-42.

(上接第95页)

参 考 文 献

- [1] 李涛涛,贾嵘,尹浩霖,等. 风力发电机组状态监测系统设计与应用[J]. 电网与清洁能源 2016(01):95-99+106.
- [2] Randall R B. Vibration-based condition monitoring[J]. Mechanisms & Machine Science 2010 3(4):431-477.
- [3] Kusiak A, Wenyan L. The prediction and diagnosis of wind turbine faults[J]. Renewable Energy, 2011, 36: 16-23.
- [4] Sanz-Bobi M A, del Pico J, Garcia M C. SIMAP: intelligent system for predictive maintenance application to the health condition monitoring of a wind turbine, gearbox[J]. Computers in Industry 2006, 57: 552-568.
- [5] Schlechtingen M, Santos I F. Comparative analysis of neural network and regression based condition monitoring approaches for wind turbine fault detection[J]. Mechanical Systems and Signal Processing 2011, 25(5):1849-1875.
- [6] 张小娟. 自适应神经模糊推理系统(ANFIS)及其仿真[J]. 电子设计工程 2012(05):11-13.
- [7] 李伟昌,张磊. 基于风力发电系统的风电机组变桨距故障诊断[J]. 计算机仿真 2015(09):147-151.
- [8] 雷绍兰,张莲,杨菁,等. 基于粗糙集和ANFIS相结合的配电网故障诊断方法[J]. 重庆工学院学报(自然科学版) 2009(06):45-50.
- [9] 孙文江. 自适应神经—模糊推理系统在隧道结构安全评估中的应用[D]. 杭州:浙江大学 2013.