

基于 MSET 的一次风机稳健状态估计方法及应用

余兴刚¹, 王日成¹, 阳剑平², 邱斌斌³

(1. 国网湖南省电力有限公司电力科学研究院 高效清洁发电技术湖南省重点实验室, 湖南 长沙 410017;

2. 湖南省湘电试验研究院有限公司, 湖南 长沙 410017;

3. 西安交通大学 动力工程多相流国家重点实验室, 陕西 西安 710049)

摘要:为提高电站设备的运行可靠性,以某 660 MW 超临界火电机组一次风机为研究对象,采用多元状态估计技术(MSET)对设备的状态估计与故障预警方法进行了研究,提出了基于多重特征参数的动态记忆矩阵构建方法,并在非线性运算符中引入不同权重系数对 MSET 算法进行改进,通过应用改进后的 MSET 算法对一次风机的异常工况进行仿真。结果表明:相较常规 MSET 算法,改进后的 MSET 算法可有效提高异常工况下各参数应达值的预测精度;通过对各参数估计残差的监测,不仅可实现故障的提前预警,还能确定故障参数和各参数偏离应达值的程度。

关键词:一次风机;多元状态估计技术;动态记忆矩阵;权重系数;故障预警

中图分类号:TP277

文献标识码:A

DOI:10.16146/j.cnki.rndlgc.2025.01.019

[引用本文格式]余兴刚,王日成,阳剑平,等.基于 MSET 的一次风机稳健状态估计方法及应用[J].热能动力工程,2025,40(1):160-170. YU Xinggang, WANG Richeng, YANG Jianping, et al. Application of a robust state estimation method for primary air fan based on MSET[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(1):160-170.

Application of a Robust State Estimation Method for Primary Air Fan based on MSET

YU Xinggang¹, WANG Richeng¹, YANG Jianping², QIU Binbin³

(1. Hunan Provincial Key Laboratory of Efficient & Clean Power Generation Technologies, State Grid Hunan Electric Power Corporation Limited Research Institute, Changsha, China, Post Code: 410017;

2. Hunan Xiangdian Test & Research Institute Co., Ltd., Changsha, China, Post Code: 410017;

3. State Key Laboratory of Multiphase Flow in Power Engineering, Xi'an Jiaotong University, Xi'an, China, Post Code: 710049)

Abstract: To improve the operating reliability of power plant equipment, multivariate state estimation technique (MSET) was employed to investigate the method of state estimation and fault early warning of unit, taking the primary air fan of a 660 MW supercritical thermal power unit as research object. A method for constructing the dynamic memory matrix based on multiple characteristic parameters was proposed. The MSET algorithm was modified by introducing different weighted coefficients into the nonlinear operator, and the modified MSET algorithm was applied to simulate abnormal conditions of primary air fan. The results show that compared with conventional MSET algorithm, the modified MSET can improve the predicted accuracy of target values of each parameter under abnormal conditions effectively. The fault ear-

收稿日期:2024-04-24; 修订日期:2024-06-07

基金项目:国家重点研发计划资助(2022YFB4100700);湖南省湘电试验研究院有限公司科技资助项目(XDKY-2021-08)

Fund-supported Project: National Key R&D Program of China (2022YFB4100700); Science and Technology Project of Hunan Xiangdian Test & Research Institute Co., Ltd. (XDKY-2021-08)

作者简介:余兴刚(1989-),男,国网湖南省电力有限公司电力科学研究院高级工程师。

ly warning, the determination of the fault parameters and the deviation between measured value and target value can be realized through monitoring the estimated residual of each parameter.

Key words: primary air fan, multivariate state estimation technique, dynamic memory matrix, weighted coefficient, fault early warning

引 言

随着新型电力系统建设的不断推进,煤电在安全保供、灵活调节、电网支撑等方面的关键作用愈加突出,这对煤电机组的运行可靠性和调节性能提出了更高的要求^[1-2]。煤电机组的组成架构极为复杂,任何设备或系统出现故障均有可能影响机组的正常运行,进而导致机组发生出力受限或非计划停运事故^[3]。目前,主要通过分散控制系统(Distributed Control System, DCS)对火电机组设备和系统进行状态监测,DCS 通常为各设备和系统提供了限幅报警和保护跳闸功能,但主要侧重于事故后的应急处理,防止设备发生严重损坏^[4]。而大多数设备的故障从早期发展到报警跳闸一般要经历一定时间的劣化过程,若能在设备劣化早期及时发现故障,并采取有效的处理措施,将极大地提高机组运行的可靠性。

基于设备正常状态的故障预警技术为实现设备故障的早期识别提供了解决方案。故障预警方法是通过获取设备各监测参数的正常应达值,并与在线测量值进行实时比较,进而评估设备的运行状态,一旦发生异常,及时给出预警信号,为现场人员争取充足的处理时间,避免设备进一步发生跳闸或严重损坏^[5]。许多学者对电站设备故障预警方法进行了深入研究。彭道刚等人^[6]采用长短期记忆网络(Long Short Term Memory, LSTM)和支持向量机对燃气轮机压气机的故障预警和诊断方法进行了研究。魏书荣等人^[7]采用灰色关联分析(Grey Relation Analysis, GRA)-LSTM-Stacking 模型研究了海上双馈风力发电机的故障预警与诊断问题,实现了故障的提前预警和故障类型的诊断。Min 等人^[8]采用自联想核回归(Auto Associative Kernel Regression, AAKR)算法对核电设备故障预警问题进行了研究,通过 3 个案例验证了 AAKR 算法的有效性。Li 等人^[9]提出了基于 AAKR 和序贯概率比检测的核电站传感器异常检测方法。韩万里等人^[10]提出了基

于主元分析和多元状态估计(Multivariate State Estimation Technique, MSET)的电站引风机故障预警方法,并采用小波变换对数据进行降噪处理。安吉振等人^[11]基于 MSET 和向量相似度对电站磨煤机故障预警问题进行了研究。蔡吉磊等人^[12]采用改进层次凝聚聚类算法构建记忆矩阵,构建了基于 MSET 的电站给水泵故障预警模型。

本文以某 660 MW 超临界火电机组一次风机为对象,研究了基于 MSET 的稳健状态估计方法。根据一次风机的运行特点,提出了基于多重特征参数的动态记忆矩阵构建方法。针对常规 MSET 在异常工况下出现的异常参数偏差污染问题,引入不同权重系数以改进 MSET 中的非线性运算符,并对比不同权重系数计算方法对异常参数偏差污染问题的抑制效果,根据对比结果确定了最优的权重系数计算方法。最后,通过监测异常工况下各参数的估计残差,实现对一次风机故障的提前预警和故障参数的识别。

1 设备状态估计方法

1.1 MSET 算法原理

MSET 算法是一种基于设备正常运行状态的非线性、非参数数据驱动建模方法,最早由美国阿尔贡国家实验室开发,并应用于核电站传感器和设备的状态监测。属于作为一种多变量状态估计方法, MSET 算法能够对设备的整体运行状态进行监测,不需要预先设置任何超参数,泛化能力强,因而在许多工业领域中广泛得到应用^[13]。

对于有 n 个监测参数的设备,其在 t 时刻的状态可以用向量的形式表示为:

$$\mathbf{X}(t) = [x_1(t), x_2(t), \dots, x_n(t)]^T \tag{1}$$

式中: $x_i(t)$ —设备第 i 个参数在 t 时刻的测量值。

从历史运行数据中选择设备处于正常运行状态的向量,构成设备历史正常运行数据库。MSET 算法建模的关键是从历史正常运行数据库中选取具有代表性的 m 个向量构成大小为 $n \times m$ 的记忆矩阵 $\mathbf{D}$ 。

$$\mathbf{D}_{n \times m} = [\mathbf{X}(t_1), \mathbf{X}(t_2), \dots, \mathbf{X}(t_m)] =$$

$$\begin{bmatrix} x_1(t_1) & x_1(t_2) & \cdots & x_1(t_m) \\ x_2(t_1) & x_2(t_2) & \cdots & x_2(t_m) \\ \vdots & \vdots & \ddots & \vdots \\ x_n(t_1) & x_n(t_2) & \cdots & x_n(t_m) \end{bmatrix} \quad (2)$$

对于某一时刻输入的观测向量 $\mathbf{X}_{\text{obs}}$, MSET 将其与记忆矩阵 $\mathbf{D}$ 中的每个向量进行相似性比较, 得到相应的权值向量 $\mathbf{W}$:

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

式中: w —权值系数。

然后计算权值向量和记忆矩阵的乘积可得到观测向量的估计向量 $\mathbf{X}_{\text{est}}$:

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot \mathbf{W} = w_1 \mathbf{X}(t_1) + w_2 \mathbf{X}(t_2) + \cdots + w_m \mathbf{X}(t_m) \quad (4)$$

计算估计向量 $\mathbf{X}_{\text{est}}$ 与观测向量 $\mathbf{X}_{\text{obs}}$ 的残差向量 $\boldsymbol{\varepsilon}$, 使 $\|\boldsymbol{\varepsilon}\|_2$ 最小化可得到权值向量 $\mathbf{W}$ 的计算式:

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

由于记忆矩阵中的状态向量数量通常远大于其监测参数数量, 导致矩阵 $\mathbf{D}^T \cdot \mathbf{D}$ 不可逆, 使式(5)无法求解。为解决该问题, MSET 使用非线性运算符 $\otimes$ 替代矩阵乘法运算符, 常用的非线性运算符有核函数和距离度量函数两种, 由于核函数会引入额外的超参数, 因此大多选取距离度量函数中的欧氏距离作为非线性运算符, 欧氏距离计算式为:

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

式中: x_i, y_i —向量 $\mathbf{X}$ 和 $\mathbf{Y}$ 的第 i 个参数。

将式(5)中的矩阵乘法运算符替换为非线性运算符后代入式(4)可得到估计向量的计算式为:

$$\mathbf{X}_{\text{est}} = \mathbf{D} \cdot (\mathbf{D}^T \otimes \mathbf{D})^{-1} \cdot (\mathbf{D}^T \otimes \mathbf{X}_{\text{obs}}) \quad (7)$$

1.2 稳健状态估计方法

文献[14-15]的研究结果表明, 对于异常工况, 常规 MSET 模型存在异常参数偏差污染问题, 即当某参数发生异常时, 异常参数和其余正常参数的预测结果均会受到参数异常的影响, 从而影响现场人员对设备故障参数的定位和参数异常程度的评估。为解决故障参数定位问题, 文献[14-15]提出根据参数的误差分量或偏差贡献率来确定异常参数, 即当 MSET 模型发出故障预警信号时, 统计各参数的偏差占总体偏差的比例, 将偏差占比最大的参数锁定为异常参数。但该方法不适用于多个参数同

时发生异常的工况, 且没有解决参数异常程度准确评估的问题。

因此, 为实现设备故障参数的准确定位和异常程度的精准评估, 应改进 MSET 算法以消除或抑制异常参数偏差污染问题。文献[16]提出采用绝对值距离替代马氏距离的 AAKR 算法改进方法, 从而提高异常工况下 AAKR 算法对各参数的预测精度。文献[17-18]提出加权型 AAKR 算法, 通过计算观测向量和历史存储矩阵中各向量之间的绝对偏差确定各参数的权值, 为偏差较大的参数设置较小的权值、偏差较小的参数设置较大的权值, 以降低少数异常参数对其他正常参数的不利影响, 但现有文献中鲜见关于 MSET 算法的改进方法。

为抑制异常参数的偏差污染, 本文结合 MSET 算法的特点, 提出 MSET 算法的改进方法, 具体如下:

引入权重系数对式(6)中非线性运算符进行改进, 改进后的非线性运算符形式如下:

$$\otimes(\mathbf{X}, \mathbf{Y}) = \sqrt{\sum_{i=1}^n w_i (x_i - y_i)^2} \quad (8)$$

式中: w_i —第 i 个参数的权重系数。

采用常规 MSET 算法计算输入观测向量的估计向量, 根据观测向量和估计向量中各参数的偏差计算各参数的权重系数 w_i 。

使用改进后的 MSET 算法重新对输入观测向量进行计算, 得到的估计向量作为最终结果用于下一步分析。

上述 MSET 算法改进方法的核心为如何计算权重系数。通常异常参数的实测值和常规 MSET 算法估计值之间的偏差较大, 为降低异常参数的影响, 应为异常参数赋予较小的权值。另外, 还需要设法限制各参数权值的范围, 防止权值过大或过小。为此, 构造了与各参数估计值和实测值的偏差有关的参数 f_i , 各参数的权值采用式(9)计算。

$$w_i = \frac{f_i^2}{f_1^2 + f_2^2 + \cdots + f_n^2} \quad (9)$$

为了使参数的估计值与实测值之间偏差越大、权值越小, 需按照同样的原则构造 f_i 的计算式。为此, 本文引入自然常数指数函数, 构造了两个 f_i 的计算式:

$$f_i = \exp\left(-\left|\frac{x_{i,\text{obs}} - x_{i,\text{est}}}{x_{i,\text{obs}}}\right|\right) \tag{10}$$

$$f_i = \exp\left(-\left|\frac{x_{i,\text{obs}} - x_{i,\text{est}}}{\sigma_i}\right|\right) \tag{11}$$

式中: $x_{i,\text{obs}}$ —第 i 个参数的实测值; $x_{i,\text{est}}$ —常规 MSET 算法计算得到的第 i 个参数的估计值; σ_i —第 i 个参数的标准差。

可以看出,式(10)和式(11)均可将 f_i 的取值限制在 $[0,1]$ 范围内。当某参数的估计值与实测值之间偏差为 0 时, f_i 取为最大值 1,符合参数的估计值与实测值之间偏差越小、权值越大的原则。为便于区分,本文将式(10)和式(11)两种权重系数计算方法分别命名为改进方法 I 和改进方法 II。下文将对比这两种 MSET 算法改进方法对异常参数偏差污染问题的抑制效果,进而确定性能最优的权重系数计算方法。

2 记忆矩阵构建

构建记忆矩阵 D 是 MSET 建模的重要环节,对模型的计算速度和结果准确性起决定性作用。若降低模型计算量,则记忆矩阵 D 中的向量数量应尽可能少;若提高预测结果的准确性,则记忆矩阵 D 中向量数量应尽可能多,以便覆盖设备的全工况运行区间。

常用的记忆矩阵构建方法为聚类法和等距抽样法^[19]。聚类法采用聚类算法对历史正常运行数据库进行分类,提取各类中心点构成记忆矩阵,但该方法很难提取到样本量较少的正常工况点。等距抽样法按照历史数据库中设备各参数值进行均分抽样,当监测参数较多时,会导致记忆矩阵中向量数量过大。

为同时兼顾模型的准确性和计算速度,文献[14]提出基于机组发电功率和向量空间距离的一次风机动态记忆矩阵构建方法;文献[11]根据给煤量将磨煤机的记忆矩阵分成 3 类,然后按照输入观测向量中给煤量的数值确定采用哪类记忆矩阵进行计算;文献[20]提出了基于向量空间距离 k 最近邻的动态记忆矩阵构建方法。这些方法虽然都可以提升模型计算速度,但也存在一定的局限性,如按照固定参数将记忆矩阵分成几类,可能导致无法准确预测位于类边界附近的观测向量;此外,向量的空间距

离与所有监测参数的偏差相关,若部分参数存在异常,可能造成无法选取到有效的历史状态向量。

综合考虑电站设备的运行特点,本文提出基于设备多重特征参数的动态记忆矩阵构建方法,以某 660 MW 超临界火电机组配备的动叶可调轴流式一次风机为例,详细阐述其构建过程及原理。该一次风机的主要监测参数如表 1 所示。

表 1 一次风机主要监测参数

Tab. 1 Main monitoring parameters of primary air fan

编号	参数名称	单位
1	一次风机电机电流	A
2	一次风机出口风压	kPa
3	一次风机出口风量	t/h
4	一次风机出口风温	℃
5	一次风机动叶开度	%
6	一次风机/电机润滑油压力	kPa
7	润滑油温度	℃
8	一次风机轴承温度 1~12	℃
9	一次风机电机前/后轴承温度	℃
10	一次风机轴承 X/Y 向振速	mm/s

表 1 中所列各监测参数都在一定程度上表征了一次风机的运行状态。部分文献常将机组功率作为电站辅机的建模变量^[14,19],本文未将机组功率作为一次风机的监测参数,主要原因如下:

①大部分火电机组通常配备两台一次风机,正常运行过程中,一般采用两台一次风机并列运行方式。若单台一次风机因故障停运,机组仍可带部分负荷运行,但此时机组功率和一次风机运行状态的关系与两台一次风机并列运行时存在较大差别,容易导致模型误报。

②随着锅炉燃用煤种和环境温度的变化,相同功率下所需煤量和一次风量也会发生变化,进而导致机组功率与一次风机运行状态的关系发生变化。

若对监测参数进行简化,将无法对一次风机的运行状态进行全面监测。因此,本文在建模时将表 1 所列参数均作为一次风机的建模变量。

正常情况下,轴承温度和振速由一次风机的出力和运行边界条件决定,表征一次风机出力大小的参数主要有电机电流、动叶开度、出口风压和风量,且通常在一定的动叶开度下出口风压与风量存在对应关系。出口风温和环境温度与风机出力大小有

关,润滑油压和油温与润滑油系统的运行状况有关,这对一次风机轴承的运行状况都有重要影响。根据一次风机的运行特性,选取电机电流、出口风压、动叶开度、一次风机润滑油压、电机润滑油压、润滑油温和出口风温 7 个参数作为一次风机的特征参数,并将直接表征一次风机出力大小的电机电流设定为主特征参数。采用历史正常运行数据库中各特征参数的数值构建一次风机的历史正常状态集合,然后根据输入观测向量中各特征参数的数值从历史正常状态集合中选取部分向量构成动态记忆矩阵,具体步骤如下:

步骤 1:根据历史正常运行数据库中电机电流的最大值 $I_{\max}$ 和最小值 $I_{\min}$,按照步长 $(I_{\max} - I_{\min})/n$ 将一次风机历史正常运行数据库划分为 n 组;

步骤 2:针对每一组数据,分别根据出口风压、动叶开度、润滑油温、出口风温、一次风机和电机润滑油压等步长选取共 $6 \times b$ 个向量, b 为各参数的等步长划分等分;

步骤 3:将筛选出的 $n \times 6 \times b$ 个向量合并,删除重复向量后得到一次风机历史正常状态集合;

步骤 4:输入观测向量 X_{obs} ,根据 X_{obs} 中各特征参数的数值在 $\pm \delta$ 范围内,从历史正常状态集合中选取符合条件的向量构成集合 $D_1 \sim D_7$, δ 根据历史正常运行数据库中各特征参数(最大值 - 最小值)的一定百分比计算得到,本文设定为 10%;

步骤 5:将 $D_1 \sim D_7$ 合并,删除重复向量构成集合 K ,计算 K 中各向量在 $D_1 \sim D_7$ 中出现的次数;

步骤 6:选取出现 7 次的向量作为 X_{obs} 的记忆矩阵 D ,若此时 D 中向量数量小于预设阈值,则继续选取出现 6 次的向量加入 D ,以此类推,直至 D 中向量数量大于预设阈值。

可以看出,步骤 3 中得到的历史正常状态集合即为采用常规等距抽样法构建的记忆矩阵,该集合中向量数量通常较多,若直接用于计算将会降低模型的计算速度。

3 常规 MSET 算法的有效性验证

上述 MSET 算法改进方法的前提条件是正常工作下 MSET 模型能够对各参数进行准确估计,下面将验证这一前提条件是否成立。

选取该 660 MW 超临界火电机组 2019 年 11 月 ~

2020 年 9 月一次风机 A 的正常运行数据,采样周期为 5 min,剔除异常值和空值后共有 20 630 组样本,构成该一次风机的历史正常运行数据库。设定主特征参数划分等分 n 为 100,设定其余特征参数划分等分 b 设定为 50,基于上述特征参数构建的历史正常状态集合中共包含 10 413 组样本。

历史正常运行数据库中一次风机各监测参数的均值和标准差如表 2 所示。

表 2 一次风机各监测参数的均值和标准差
Tab.2 Mean value and standard deviation of various monitoring parameters of primary air fan

参 数	均值	标准差
轴承温度 1/℃	57.225	2.282
轴承温度 2/℃	57.242	3.231
轴承温度 3/℃	55.750	2.819
轴承温度 4/℃	55.866	2.277
轴承温度 5/℃	56.531	2.651
轴承温度 6/℃	57.969	2.979
轴承温度 7/℃	56.153	2.565
轴承温度 8/℃	54.930	2.298
轴承温度 9/℃	56.483	2.380
轴承温度 10/℃	53.610	4.072
轴承温度 11/℃	53.844	2.875
轴承温度 12/℃	53.422	2.126
电机前轴承温度/℃	61.966	1.721
电机后轴承温度/℃	61.143	1.720
X 向振速/mm·s ⁻¹	0.694	0.115
Y 向振速/mm·s ⁻¹	0.370	0.032
出口风温/℃	35.644	7.596
风机润滑油压/kPa	111.760	7.637
电机润滑油压/kPa	153.307	11.028
润滑油温/℃	31.337	3.960
动叶开度/%	42.619	7.420
电机电流/A	86.826	7.402
出口风压/kPa	8.231	0.604
出口风量/t·h ⁻¹	224.317	23.807

从表 2 可以看出,一次风机各监测参数存在多种不同的量纲,且部分参数的数值也存在量级上的差别,若直接用于计算会影响权值向量 W 的计算结果。因此,采用 z-score 标准化对历史正常运行数据

库中的各参数进行标准化处理,计算式为:

$$x_{z,i} = \frac{x_i - \mu_i}{\sigma_i}$$

(12)

式中: μ_i —参数的均值; x_i —参数标准化前的值;
 $x_{z,i}$ —参数标准化后的值。

选取该一次风机历史正常运行数据库中除历史正常状态集合外的共计 10 217 组样本构成验证集,采用动态记忆矩阵和常规 MSET 算法对验证集中各样本进行预测。计算过程中发现,验证集中所有样本的动态记忆矩阵中向量的数量都在 1 000 以下,远小于历史正常状态集合中向量的数量。采用各参数估计值与实测值的相对偏差和绝对偏差指标对计算结果进行评价,验证集中各参数的最大相对偏差和最大绝对偏差计算结果如表 3 所示。

表 3 验证集中各参数的估计偏差

Tab. 3 Estimated deviation of each parameter in validation set

参 数	最大相对偏差/%	最大绝对偏差
轴承温度 1/℃	1.26	0.691
轴承温度 2/℃	1.27	0.736
轴承温度 3/℃	1.33	0.722
轴承温度 4/℃	1.15	0.665
轴承温度 5/℃	1.34	0.803
轴承温度 6/℃	1.30	0.772
轴承温度 7/℃	1.56	0.889
轴承温度 8/℃	1.15	0.600
轴承温度 9/℃	1.35	0.770
轴承温度 10/℃	1.42	0.759
轴承温度 11/℃	1.52	0.822
轴承温度 12/℃	1.01	0.540
电机前轴承温度/℃	1.21	0.736
电机后轴承温度/℃	0.64	0.399
X 向振速/mm·s ⁻¹	1.89	0.014
Y 向振速/mm·s ⁻¹	1.09	0.005
出口风温/℃	1.98	0.917
风机润滑油压/kPa	0.81	0.974
电机润滑油压/kPa	0.80	1.405
润滑油温/℃	1.85	0.553
动叶开度/%	1.95	1.089
电机电流/A	1.23	1.387
出口风压/kPa	1.84	0.165
出口风量/t·h ⁻¹	1.79	4.966

从表 3 可以看出,常规 MSET 模型预测得到的各参数的最大相对偏差均在 2% 以内。一次风机轴承温度 1 ~ 12、电机前/后轴承温度、润滑油温和出口风温,其最大绝对偏差均小于 1 ℃。一次风机润滑油压和电机润滑油压的最大偏差仅为 0.974 和 1.405 kPa。而电机电流、出口风压、出口风量、动叶开度和轴承振速等参数在设备正常运行过程中不可避免地存在轻微波动,其最大绝对偏差基本与正常波动幅度相当。

由此可以看出,基于设备多重特征参数所构建的历史正常状态集合和动态记忆矩阵能较好地覆盖历史正常运行数据库中的各种运行工况点。正常工况下,常规 MSET 算法可以对各参数进行较为准确的估计,保证各参数的相对偏差和绝对偏差均在工程允许范围内,也充分表明 MSET 算法改进方法的前提条件成立。

4 异常工况预测结果对比

4.1 一次风机动叶开度异常工况

从该一次风机的验证集中随机选取 300 个样本,从第 151 个样本开始,人为使动叶开度阶跃为原来正常值的两倍,在运行过程中构成动叶开度发生异常突变工况测试集。分别采用常规 MSET 算法和改进后的 MSET 算法对此动叶开度异常工况进行计算,根据计算结果统计加阶跃变化的后 150 个样本各参数的平均绝对偏差,如表 4 所示,表中动叶开度的绝对偏差由不同算法的估计值和未加阶跃变化的值计算得到。

从表 4 可以看出,对于一次风机动叶开度异常工况,MSET 算法的两种改进方法均能有效降低动叶开度异常对其他正常参数预测结果的影响,并可显著提升动叶开度应达值的估计精度。对于轴承温度 1 ~ 12、电机前/后轴承温度、轴承 Y 向振速、润滑油压和出口风压这些在历史正常运行数据库中分布离散程度较小的参数(特征为表 2 中参数的标准差与均值相比较小),两种改进后的 MSET 算法预测结果的精度相当。而对于在历史正常运行数据库中分布较离散的出口风量、润滑油温、出口风温、轴承 X 向振速和电机电流,采用方法 II 改进后的 MSET 算法的平均绝对偏差明显小于改进方法 I。

表 4 动叶开度异常工况下不同算法的平均绝对偏差

Tab.4 Mean absolute deviation of different algorithms under abnormal condition of moving blade opening

参 数	常规 MSET	改进方法 I	改进方法 II
轴承温度 1/℃	0.589 3	0.030 8	0.036 8
轴承温度 2/℃	0.713 4	0.040 6	0.041 2
轴承温度 3/℃	0.609 1	0.038 5	0.040 0
轴承温度 4/℃	0.563 2	0.045 8	0.052 9
轴承温度 5/℃	0.686 4	0.040 2	0.043 1
轴承温度 6/℃	0.627 1	0.042 8	0.043 3
轴承温度 7/℃	0.624 9	0.045 2	0.047 5
轴承温度 8/℃	0.533 0	0.025 6	0.034 0
轴承温度 9/℃	0.663 1	0.033 1	0.046 3
轴承温度 10/℃	0.618 2	0.047 3	0.046 3
轴承温度 11/℃	0.573 6	0.042 2	0.045 3
轴承温度 12/℃	0.489 4	0.021 9	0.026 5
电机前轴承温度/℃	0.476 7	0.025 7	0.040 2
电机后轴承温度/℃	0.303 0	0.025 0	0.039 2
X 向振速/ $\text{mm}\cdot\text{s}^{-1}$	0.019 6	0.007 8	0.002 4
Y 向振速/ $\text{mm}\cdot\text{s}^{-1}$	0.012 8	0.002 5	0.001 5
出口风温/℃	1.033 1	0.279 6	0.114 6
风机润滑油压/kPa	0.422 1	0.070 4	0.075 8
电机润滑油压/kPa	1.222 0	0.114 6	0.101 7
润滑油温/℃	0.758 1	0.128 3	0.073 5
动叶开度/%	10.792 7	0.713 5	0.575 4
电机电流/A	1.409 4	0.4390	0.244 4
出口风压/kPa	0.071 3	0.016 5	0.010 2
出口风量/ $\text{t}\cdot\text{h}^{-1}$	4.172 2	1.396 2	0.512 3

图 1 为一次风机动叶开度异常工况下,3 种 MSET 算法计算得到的动叶开度、出口风量和出口风温绝对偏差的变化趋势。由图 1 可知,对于未加阶跃变化的前 150 个样本点,采用方法 II 改进后的 MSET 算法的绝对偏差与常规 MSET 算法相近,而在部分偏差相对较大的峰值处,采用方法 I 改进后的 MSET 算法的绝对偏差明显大于其他两种算法。对于加阶跃变化后的 150 个样本点,采用方法 I 改进后的 MSET 算法的绝对偏差也比改进方法 II 大,部分样本处采用方法 I 改进后的 MSET 算法的绝对偏差甚至大于常规 MSET 算法。




图 1 动叶开度异常工况下不同算法绝对偏差的变化

Fig.1 Variations of absolute deviation of different algorithms under abnormal condition of moving blade opening

从表 4 和图 1 还可以看出,尽管异常参数动叶开度为一次风机的特征参数,但改进后的 MSET 算法仍能对测试集中加动叶开度阶跃变化后的样本进行较为准确的估计。由此可见,对于观测向量特征参数异常的工况,本文提出的动态记忆矩阵构建方法也能从历史正常状态集合中提取出有效的状态向量。

4.2 一次风机轴承温度异常工况

仍以前文选取的 300 个样本为研究对象,从第 101 个样本开始为一次风机轴承温度 1 测点增加 $0.1 \times (m - 100) \text{ }^{\circ}\text{C}$ (m 为样本的编号)的正偏移量,构成轴承温度异常工况测试集。然后,分别采用常规 MSET 算法和改进后的 MSET 算法对该异常工况进行状态估计,并统计测试集中轴承温度累计偏移量相对较大的后 100 个样本各参数的平均绝对偏差,如表 5 所示,表中轴承温度 1 的绝对偏差由各算法估计值与未加累计偏移量的值计算得到。

表 5 轴承温度异常工况下不同算法的平均绝对偏差
Tab.5 Mean absolute deviation of different algorithms under abnormal condition of bearing temperature

参 数	常规 MSET	改进方法 I	改进方法 II
轴承温度 1/ $^{\circ}\text{C}$	1.660 9	0.033 4	0.039 1
轴承温度 2/ $^{\circ}\text{C}$	0.439 2	0.034 1	0.037 4
轴承温度 3/ $^{\circ}\text{C}$	0.386 0	0.024 7	0.029 4
轴承温度 4/ $^{\circ}\text{C}$	0.372 7	0.023 1	0.032 8
轴承温度 5/ $^{\circ}\text{C}$	0.338 5	0.019 4	0.024 3
轴承温度 6/ $^{\circ}\text{C}$	0.349 5	0.026 3	0.032 2
轴承温度 7/ $^{\circ}\text{C}$	0.323 5	0.026 4	0.031 6
轴承温度 8/ $^{\circ}\text{C}$	0.314 4	0.018 1	0.027 3
轴承温度 9/ $^{\circ}\text{C}$	0.337 7	0.033 8	0.047 4
轴承温度 10/ $^{\circ}\text{C}$	0.532 9	0.038 3	0.043 8
轴承温度 11/ $^{\circ}\text{C}$	0.382 1	0.037 5	0.042 1
轴承温度 12/ $^{\circ}\text{C}$	0.421 0	0.020 3	0.030 1
电机前轴承温度/ $^{\circ}\text{C}$	0.404 8	0.022 9	0.031 9
电机后轴承温度/ $^{\circ}\text{C}$	0.361 4	0.040 7	0.056 3
X 向振速/ $\text{mm}\cdot\text{s}^{-1}$	0.023 5	0.009 0	0.002 0
Y 向振速/ $\text{mm}\cdot\text{s}^{-1}$	0.012 6	0.002 8	0.002 1
出口风温/ $^{\circ}\text{C}$	0.692 1	0.180 4	0.089 9
风机润滑油压/ kPa	0.798 4	0.108 9	0.101 4
电机润滑油压/ kPa	0.712 3	0.112 0	0.098 6
润滑油温/ $^{\circ}\text{C}$	0.344 1	0.087 7	0.048 7
动叶开度/ $\%$	1.365 8	0.450 2	0.181 0
电机电流/ A	0.784 5	0.165 9	0.145 3
出口风压/ kPa	0.112 6	0.021 7	0.013 0
出口风量/ $\text{t}\cdot\text{h}^{-1}$	3.723 9	1.280 6	0.478 0

从表 5 可以看出,对于一次风机轴承温度异常工况,相较常规 MSET 算法,两种改进后的 MSET 算法均能明显提升对一次风机各参数的估计精度,且对于在历史正常运行数据库中分布较离散的出口风

量、润滑油温、出口风温、轴承 X 向振速和动叶开度,改进方法 II 相较于改进方法 I 能够提供更接近实测值的估计结果。

图 2 为一次风机轴承温度异常工况下,通过 3 种 MSET 算法计算得到的轴承温度 1、出口风量和动叶开度绝对偏差的变化趋势。图 2 与图 1 类似,对于出口风量和动叶开度绝对偏差相对较大的样本点,采用方法 II 改进后的 MSET 算法的绝对偏差明显小于方法 I。




图 2 轴承温度异常工况下不同算法绝对偏差的变化
Fig.2 Variations of absolute deviation of different algorithms under abnormal condition of bearing temperature

从上述两个异常工况的对比结果可以看出,在 MSET 算法的非线性运算符中引入权重系数可以提升异常工况下各参数应达值的估计精度,但改进方法Ⅱ在计算权重系数时引入了参数的标准差,既考虑了各参数偏差又兼顾了数据分布特性,因此在处理异常工况下分布较为离散的监测参数时,改进方法Ⅱ表现出了更为优异的性能。

5 故障预警与异常参数定位

现有文献大多采用观测向量和估计向量的相似度或整体残差作为评价指标开展故障预警工作^[11-16],这些指标综合考虑了设备所有参数估计值与实测值之间的偏差,虽然可以实现故障预警,但无法根据预警指标定位具体的故障参数。由于采用方法Ⅱ改进后的 MSET 算法可以较为准确地估计异常工况下设备各参数的正常应达值,为此,本文提出采用设备各参数估计值与实测值之间的绝对残差进行展故障预警与定位方法,绝对残差 ε_i 计算式为:

$$\varepsilon_i = |x_{i,obs} - x_{i,est}| \tag{13}$$

为降低设备运行过程中外界随机因素干扰等造成的误报警,采用滑动窗口法对各参数的残差序列进行平均值滤波处理,假设滑动窗口宽度为 N ,则输出结果为窗口内连续 N 个残差的平均值:

$$\bar{\varepsilon}_i = \frac{1}{N} \sum_{i=1}^N \varepsilon_i \tag{14}$$

为确保故障预警的可靠性,采用验证集中各参数的最大估计残差确定预警阈值:

$$\varepsilon_{i,y} = p\varepsilon_{i,max} \tag{15}$$

式中: $\varepsilon_{i,y}$ —参数的预警阈值; $\varepsilon_{i,max}$ —验证集中参数的最大估计残差; p —预警阈值系数,根据现场经验确定,一般不小于 1。

图 3、图 4 分别为一次风机动叶开度和轴承温度异常工况下动叶开度和轴承温度 1 的实测值、估计值和绝对残差的变化趋势。图中估计值由采用方法Ⅱ改进后的 MSET 算法计算得到,实测值为人为增加阶跃变化或累计偏移量后的值,动叶开度和轴承温度 1 的预警阈值分别为 3% 和 2℃,该阈值根据表 3 中最大绝对残差乘以一定预警阈值系数并取整处理后得到。

从图 3 可以看出,在未加阶跃变化的前 150 个样本中,一次风机动叶开度的估计值与实测值基本

一致,动叶开度的绝对残差远小于预警阈值。在第 151 个样本点处,动叶开度发生突变,计算得到的绝对残差也超出预警阈值,据此发出报警信号并锁定异常参数为动叶开度。此外,通过实时计算实测值和估计值的偏差,还能直观地确定动叶开度偏离其应达值的数值。




图 3 动叶开度估计值、实测值与绝对残差的变化趋势

Fig.3 Variation trend of estimated value, measured value and absolute deviation of moving blade opening

从图 4 可以看出,一次风机轴承温度 1 的绝对残差在第 125 个点样本处首次超过了预警阈值,此时轴承温度 1 的值为 59.8℃,而 DCS 报警定值为 90℃,若采用 DCS 的报警方法,现场人员很难及时发现一次风机轴承温度 1 的异常。




图 4 轴承温度 1 估计值、实测值与绝对残差的变化趋势

Fig.4 Variation trend of estimated value, measured value and absolute deviation of bearing temperature 1

采用的故障预警方法可以及时检测出一次风机的异常状况,并能够直观显示故障参数及其偏离应达值的程度。这种方法与火电厂常用的报警系统处理异常的方法相似,但通常 DCS 仅提供限幅报警功能,在发出报警后,需要现场人员调取历史数据才能确定异常参数偏离正常值的数值。

6 结 论

(1) 基于多重特征参数的动态记忆矩阵构建方法,在大幅度降低记忆矩阵规模的前提下仍能有效覆盖历史正常运行工况,并可适应特征参数异常的故障工况。

(2) 引入两种权重系数对 MSET 算法的非线性运算符进行改进,通过对比分析不同故障工况的仿真结果,确定了性能最优的 MSET 算法改进方法,改进后的 MSET 算法可显著提升异常工况下各参数应达值的估计精度。

(3) 基于改进后的 MSET 算法对各参数的估计残差进行一次风机故障的预警与定位,通过实时监测各参数的估计残差,不仅可实现故障的提前预警,还能够直观地确定异常参数及其偏离应达值的程度。

参考文献:

[1] 欧阳子区,王宏帅,吕清刚,等. 煤粉锅炉发电机组深度调峰技术进展[J]. 中国电机工程学报,2023,43(22):8772-8790.
OUYANG Ziqu, WANG Hongshuai, LYU Qinggang, et al. Research progress on deep peak shaving technology of pulverized coal-fired boiler power unit[J]. Proceedings of the CSEE, 2023, 43(22): 8772-8790.

[2] 刘 硕,马兆兴,刘金鑫,等. 面向新能源消纳的新型电力系统优化运行策略[J]. 湖南电力,2024,44(2):59-66.
LIU Shuo, MA Zhaoxing, LIU Jinxing, et al. Optimal operation strategies of new power system aimed at renewable energy system consumption[J]. Hunan Electric Power, 2024, 44(2): 59-66.

[3] 吕当振,宾谊沅,李文军,等. 600 MW 超临界机组锅炉轴流风机并列与过程控制技术[J]. 中国电机工程学报, 2020, 40(17):5574-5582.
LYU Dangzhen, BIN Yiyuan, LI Wenjun, et al. The parallel and process control technology of axial flow fans in a 600 MW super-critical boiler[J]. Proceedings of the CSEE, 2020, 40(17):

5574-5582.

[4] 王锡辉,朱晓星,陈厚涛,等. 燃煤机组辅机设备运行健康状态在线评估方法及应用[J]. 中国电机过程学报,2022,42(7):2597-2605.
WANG Xihui, ZHU Xiaoxing, CHEN Houtao, et al. Application of an online evaluation method for operating health status of auxiliary equipment in coal-fired power plants[J]. Proceedings of the CSEE, 2022, 42(7): 2597-2605.

[5] 杨婷婷,张 蓓,吕 游,等. 基于 MSET 的电站风机故障预警技术研究[J]. 热能动力工程,2017,32(9):63-68.
YANG Tingting, ZHANG Bei, LYU You, et al. Research on early fault warning technology of fan in power plant based on MSET method[J]. Journal of Engineering for Thermal Energy and Power, 2017, 32(9): 63-68.

[6] 彭道刚,姬传晟,涂 焯,等. 基于 LSTM-SVM 的燃气轮机压气机故障预警研究[J]. 动力工程学报,2021,41(5):394-399.
PENG Daogang, JI Chuansheng, TU Xuan, et al. Research on gas turbine compressor fault early warning based on LSTM-SVM[J]. Journal of Chinese Society of Power Engineering, 2021, 41(5): 394-399.

[7] 魏书荣,张 鑫,符 杨,等. 基于 GRA-LSTM-stacking 模型的海上双馈风力发电机早期故障预警与诊断[J]. 中国电机工程学报,2021,41(7):2373-2382.
WEI Shurong, ZHANG Xin, FU Yang, et al. Early fault warning and diagnosis of offshore wind DFIG based on GRA-LSTM-stacking model[J]. Proceedings of the CSEE, 2021, 41(7): 2373-2382.

[8] MIN J H, KIM D W, PARK C Y. Demonstration of the validity of the early warning in online monitoring system for nuclear power plants[J]. Nuclear Engineering and Design, 2019, 349: 56-62.

[9] LI Wei, PENG Minjun, YANG Ming, et al. Design of comprehensive diagnosis system in nuclear power plant[J]. Annals of Nuclear Energy, 2017, 109: 92-102.

[10] 韩万里,茅大钧,印琪民. 基于 PCA 和多元状态估计的引风机故障预警[J]. 热能动力工程,2020,35(1):91-97.
HAN Wanli, MAO Dajun, YIN Qimin. Induced draft fan fault warning based on PCA and multivariate state estimation technique[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(1): 91-97.

[11] 安吉振,乔世超,陈 衡,等. 基于多元状态估计和向量相似度的电站磨煤机故障智能预警研究[J]. 热力发电,2022, 51(12):64-71.
AN Jizhen, QIAO Shichao, CHEN Heng, et al. Research on intelligent early warning of coal mill failure in power station based on multi-state estimation and vector similarity[J]. Thermal Power Generation, 2022, 51(12): 64-71.

[12] 蔡吉磊,茅大均,李玉珍. 基于改进 HAC 和 MSET 的给水泵故障预警方法[J]. 热能动力工程,2023,38(8):176-184.
CAI Jilei, MAO Dajun, LI Yuzhen. Feed water pump fault early warning method based on improved HAC and MSET [J]. Journal of Engineering for Thermal Energy and Power, 2023, 38(8): 176-184.

[13] 王 博,吴智群. 电站风机故障智能预警技术的应用研究[J]. 热能动力工程,2017,32(10):66-70.
WANG Bo, WU Zhiqun. Study of applications of the intelligent fault early-warning technology for fans in power plants[J]. Journal of Engineering for Thermal Energy and Power, 2017, 32(10): 66-70.

[14] 余兴刚,宾谊沅,陈 文,等. 基于改进 MSET 的一次风机故障预警及诊断方法[J]. 机电工程,2023,40(4):535-541.
YU Xinggang, BIN Yiyuan, CHEN Wen, et al. Early warning and diagnosis of primary fans based on improved MSET[J]. Journal of Mechanical & Electrical Engineering, 2023, 40(4): 535-541.

[15] 张凤丽,潘 辉,王金江. 基于多元状态估计的热交换器多参数关联预警方法[J]. 化工学报,2022,73(2):814-826.
ZHANG Fengli, PAN Hui, WANG Jinjiang. Multi-parameter correlation early warning method of heat exchanger based on multivariate state estimation [J]. CIESC Journal, 2022, 73(2): 814-826.

[16] 李 刚,仇晨光,曹 帅,等. 基于稳健状态估计的设备状态预警研究[J]. 热力发电,2020,49(11):1-7.
LI Gang, QIU Chenguang, CAO Shuai, et al. Early warning of equipment state based on robust state estimation [J]. Thermal Power Generation, 2020, 49(11): 1-7.

[17] 刘双白,朱龙飞,仇晓智,等. 基于加权 AAKR 算法的发电设备状态预警技术研究[J]. 热能动力工程, 2020, 35(7): 235-241.
LIU Shuangbai, ZHU Longfei, QIU Xiaozhi, et al. Study of power equipment condition early warning technology based on weighted AAKR algorithm [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(7): 235-241.

[18] BARALDI P, MAIO F D, TURATI P, et al. Robust signal reconstruction for condition monitoring of industrial components via a modified auto associative kernel regression method[J]. Mechanical Systems and Signal Processing, 2015, 60(61): 29-44.

[19] 牛玉广,李晓斌,张佳辉. 基于多元状态估计与自适应阈值的电站辅机故障预警[J]. 动力工程学报, 2019, 39(9): 717-724.
NIU Yuguang, LI Xiaobin, ZHANG Jiahui. Early fault warning for auxiliary equipment of power plants based on multivariate state estimation and adaptive threshold [J]. Journal of Chinese Society of Power Engineering, 2019, 39(9): 717-724.

[20] 王梓齐. 基于正常行为建模的风电机组状态监测方法研究[D]. 保定:华北电力大学,2023.
WANG Ziqi. Research on condition monitoring method of wind turbine based on normal behavior modeling [D]. Baoding: North China Electric Power University, 2023.

(王治红 编辑)