

DOI: 10.19666/j.rlfed.202212177

基于多元状态估计-层次分析法的磨煤机故障预警

吴涛¹, 王毅¹, 刘震², 罗睿¹, 刘帆帆²,

李郁¹, 李明昊¹, 石磊¹

(1.西安热工研究院有限公司, 陕西 西安 710054;

2.上海海事大学物流科学与工程研究院, 上海 201306)

[摘要] 针对当前火电机组频繁进行深度调峰、灵活性运行、节能降耗等背景下发电设备故障频发的现象, 提出了多元状态估计-层次分析法的磨煤机故障预警方法。首先基于斯皮尔曼相关性分析对磨煤机特征参数进行降维, 采用等距抽样方法从大量磨煤机历史数据中抽取部分样本归一化后形成记忆矩阵; 随后利用多元状态估计算法根据记忆矩阵和观测向量计算出对应的估计向量, 采用层次分析法对特征参数赋予不同的权重, 并计算观测向量和估计向量之间的融合相似度, 基于自适应阈值的方法对磨煤机故障进行预警; 最后以某辊式中速磨煤机实际故障数据为例, 验证了该方法的有效性。结果表明, 该方法对磨煤机故障预警具有较少的漏报率和误报率, 可以在一定程度上减少磨煤机实际发生故障的概率。

[关键词] 磨煤机; 故障预警; 多元状态估计; 层次分析法; 斯皮尔曼相关性分析

[引用本文格式] 吴涛, 王毅, 刘震, 等. 基于多元状态估计-层次分析法的磨煤机故障预警[J]. 热力发电, 2023, 52(5): 14-21.
WU Tao, WANG Yi, LIU Zhen, et al. Coal mill fault warning based on multi-state estimation-analytic hierarchy process[J]. Thermal Power Generation, 2023, 52(5): 14-21.

Coal mill fault warning based on multi-state estimation-analytic hierarchy process

WU Tao¹, WANG Yi¹, LIU Zhen¹, LUO Rui¹, LIU Fanfan², LI Yu¹, LI Minghao¹, SHI Lei¹

(1. Xi'an Thermal Power Research Institute Co., Ltd., Xi'an 710054, China;

2. Institute of Logistics Science and Engineering, Shanghai Maritime University, Shanghai 201306, China)

Abstract: In view of the frequent failure of power generation equipment under the background of frequent deep peak regulation, flexible operation, energy saving and consumption reduction of thermal power units, a coal mill fault warning method based on multiple state estimation-analytic hierarchy process is proposed. Firstly, based on the characteristic parameters of coal mill Spearman correlation analysis for dimension reduction, equidistant sampling method is used to extract some samples from a large number of coal mill history data memory matrix, after normalization, memory matrix is formed. Then, multi-state estimation algorithm is adopted to calculate the corresponding memory estimated vector according to the memory matrix and the observation vector. The characteristic parameters are given different weights by using analytic hierarchy process (AHP), and the fusion similarity between the observed vector and the estimated vector is calculated, and the fault warning of coal mill is carried out based on the adaptive threshold method. Finally, the actual fault data of a roller medium speed coal mill is taken as an example to verify the effectiveness of the method. The results show that, this method has less misalarm rate and false alarm rate for coal mill fault warning, which can reduce the actual fault probability of coal mill to a certain extent.

Key words: coal mill; fault warning; multi-state estimation; AHP; Spearman correlation analysis

收稿日期: 2022-12-15

基金项目: 中国华能集团有限公司总部科技项目 (HNKJ20-H74)

Supported by: Science and Technology Project of China Huaneng Group Co., Ltd. (HNKJ20-H74)

第一作者简介: 吴涛 (1993), 男, 硕士, 工程师, 主要研究方向为电站信息化及智能化应用, wutaox@tpri.com.cn.

为实现电力低碳转型、新能源快速发展、全面提升电网深度调峰和消纳新能源的能力,煤电机组正在向智慧化、灵活性转变^[1-3],这一过程相比于机组设计之初需要频繁进行高低负荷切换以及低负荷长期运行,这种运行方式会导致机组主辅机的安全可靠下降。磨煤机是燃煤火力发电机组中重要的辅机设备之一,由于其结构复杂、运行环境恶劣、运行负荷频繁切换或长期低负荷运行,导致磨煤机故障频发^[4]。

设备故障预警是指根据设备实时状态监测数据,在设备故障发生前或者故障发展初期,基于某种方法判断出设备有发生故障的倾向并提前发出预警信号^[5]。当前设备故障预警方法主要分为:物理模型法、概率模型法和状态预测法。物理模型法也即故障特征法或阈值预警法,是指通过统计分析对设备的关键参数或组合参数设置合理的阈值,当参数值逾越阈值即发出预警信号。文献[6]针对发动机轴承故障,将飞机上现有的传感器信息(如转子转速、振动、润滑系统信息等)与轴承损伤累计模型和发动机运行环境结合起来,实现了发动机轴承故障预测。这种方法建模相对比较复杂,需要较多的相关设备运行维护经验,且实际应用时效果并不十分理想。概率模型法是指根据设备历史不同状态下参数的分布情况,计算在当前参数时设备处于各种状态的概率。文献[7]针对齿轮箱的4种故障类型,采用改进后的概率神经网络建立了预警模型,将模型输出的概率值作为判断齿轮箱处于何种状态下的依据,并与RBF神经网络和BP神经网络结果进行了对比。文献[8-10]利用支持向量机对设备状态进行概率预测达到预警的目的。这种方法需要对具体设备有较丰富的运行维护经验且需要大量的标签数据。状态预测法是指先预测设备当前的状态,然后与设备实际的状态进行对比,当预测状态与实际状态偏差较大时对设备进行预警,采用的算法主要有神经网络^[11-12]、多元状态估计技术(multivariate state estimation technique, MSET)^[4,13-14]和时间序列预测^[15-16]等,其中多元状态估计算法可以在设备故障的发展初期发现异常,实时性较好,准确性与记忆矩阵的构建、估计向量和实际向量的偏离度计算方法、阈值设定有较强的关联性。

一般采用MSET做设备故障预警时都不会涉及到特征参数的权重,但往往存在一些参数容易受到环境影响导致数值分布方差较大,以及每个特征参

数对于设备状态预测的重要性和测量可靠性不相同,导致预测结果不稳定。因此本文提出用层次分析法(AHP)为不同的特征参数赋予不同的权重以改善预测结果不稳定的问题。

1 多元状态估计技术

MSET是一种非线性、非参数建模方法,最早由阿贡国家实验室研发出来并应用于核电故障监测^[17],该算法兼具较好的实时性、快速性和准确性,现已被应用于计算机软件老化检测^[17]、风机故障预警^[14]和卫星故障检测^[18]等诸多领域中。

首先需要从历史数据中挑选出若干典型的有效观测向量形成历史矩阵,该矩阵包含的向量尽可能少,同时还要几乎能代表设备所有工况下的正常运行状态。将历史矩阵进行归一化后形成记忆矩阵 D , D 是一个大小为 $n \times m$ 的矩阵, n 表示设备状态的 n 个特征数量, m 表示观测向量的数量。磨煤机在时刻 j 有包含 n 个特征的观测向量 X_j :

$$X_j = [x_{1j}, x_{2j}, \dots, x_{nj}]^T \quad (1)$$

式中: x_{ij} 为磨煤机特征 i 在时刻 j 的观测值。

记忆矩阵 D 为:

$$D = [X_1, X_2, \dots, X_m] = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \vdots & \vdots & & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (2)$$

对于某一时刻的观测向量 X_{obs} ,其估计向量 X_{est} 为:

$$\begin{aligned} X_{\text{est}} &= D \cdot W = \\ D \cdot [w_1, w_2, \dots, w_m]^T &= \\ w_1 X_1 + w_2 X_2 + \dots + w_m X_m \end{aligned} \quad (3)$$

式中: W 为权值向量,表示观测向量与记忆矩阵的相似程度。 W 可通过最小化观测向量与估计向量之间的残差求得,即:

$$W = (D^T \cdot D)^{-1} \cdot (D^T \cdot X_{\text{obs}}) \quad (4)$$

由于记忆矩阵中有许多观测向量线性相关导致 $(D^T \cdot D)$ 不可逆,式(4)不能直接求解,所以一般采用非线性运算符 \otimes 求解,非线性运算符有许多种,但不同的非线性运算符对MSET模型的性能影响很小^[4],大多采用欧氏距离计算:

$$\otimes(X, Y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

式中： x_i 为观测向量 \mathbf{X} 的第 i 个特征观测值； y_i 为观测向量 \mathbf{Y} 的第 i 个特征观测值。

将式(5)代入式(4)得到权值向量 \mathbf{W} 后，再代入式(3)得到观测向量 \mathbf{X}_{obs} 的估计向量 \mathbf{X}_{est} 为：

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

2 层次分析法

AHP 是一种定性分析与定量计算相结合的综合评价方法。AHP 不需要大量的历史数据，只需要决策者利用自己的经验判断各因素之间的重要程度，因此能够为一些多目标复杂问题且难以定量计算的问题提供一种简洁实用的决策方法。判断矩阵元素标度方法见表 1。

表 1 判断矩阵元素标度方法

Tab.1 The method of judging the scale of matrix elements

标度	含义
1	表示两个因素相比，具有同等重要性
3	表示两个元素相比，一个因素比另一个因素稍微重要
5	表示两个元素相比，一个因素比另一个因素明显重要
7	表示两个元素相比，一个元素比另一个元素强烈重要
9	表示两个元素相比，一个元素比另一个元素极端重要
2, 4, 6, 8	上述两相邻判断的中值
倒数	因素 i 与 j 比较的判断 a_{ij} ，则因素 j 与因素 i 的判断 $a_{ji}=1/a_{ij}$

层次分析法将与目标决策有关的元素按照元素间的隶属关系或影响关系进行不同层级的聚集组合，形成一个多层次的分析结构模型，即：最高层（目标层）、中间层（准则层）和最底层（方案层），然后根据表 1 对每层中各个元素对上一层某元素的重要程度进行简单的比较和计算，得到判断矩阵 \mathbf{A} ，并验证矩阵 \mathbf{A} 的一致性。对判断矩阵 \mathbf{A} 求解特征值 λ ， $\lambda = \max\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ ，计算一致性判断指标：

$C_{\text{CI}} = \frac{\lambda - n}{n - 1}$ ，根据随机一致性指标 R_{RI} （表 2）计算

一致性比率 $C_{\text{CR}} = \frac{C_{\text{CI}}}{R_{\text{RI}}}$ ，当 $C_{\text{CR}} < 0.1$ 时，认为矩阵 \mathbf{A}

的不一致程度在容许范围之内，通过一致性检验，否则重新构造判断矩阵 \mathbf{A} 。判断矩阵 \mathbf{A} 通过一致性检验后，计算矩阵 \mathbf{A} 的所有特征值以及对应的特征向量，选取最大特征值 λ 对应的特征向量 $\mathbf{w} = \{w_1, w_2, \dots, w_n\}^T$ 作为该层元素对上一层某元素的权重。

表 2 随机一致性指标

Tab.2 The random consistency index

n	1	2	3	4	5	6	7	8	9
R_{RI}	0	0	0.58	0.90	1.12	1.24	1.32	1.41	1.45

3 相似度和动态阈值计算

3.1 相似度计算

观测向量通过 MSET 计算出来估计向量，观测向量与估计向量的各特征参数存在不同程度的偏离，需要将各特征参数的偏离程度融合并定量的表示出来，即 2 个向量的相似度，该相似度可以表征磨煤机的运行状态。相似度计算一般采用欧式距离、曼哈顿距离、夹角余弦和切比雪夫距离等，由于比较 2 个向量之间的相似程度需要考虑 2 个维度：2 个向量的直线距离和 2 个向量夹角，因此本文将欧氏距离与夹角余弦结合起来形成初步融合距离，然后将 AHP 算法得到的权重一并融合，得到融合距离 s ：

$$s = \frac{1}{1 + \frac{o_s}{0.5\cos(\mathbf{X}, \mathbf{Y}) + 0.5}} \quad (7)$$

$$o_s = \sqrt{\sum_{i=1}^m (w_i (x_i - y_i))^2} \quad (8)$$

$$\cos(\mathbf{X}, \mathbf{Y}) = \frac{\sum_{i=1}^m (x_i \times y_i)}{\sqrt{\sum_{i=1}^m (x_i)^2} \times \sqrt{\sum_{i=1}^m (y_i)^2}} \quad (9)$$

式中： o_s 为观测向量与估计向量之间的欧氏距离； w_i 为向量权重，该权重由层次分析法计算得出； \mathbf{X} 和 \mathbf{Y} 分别为观测向量和估计向量。 s 值范围为(0,1]， s 值越接近于 1 表明 2 个向量越相似，说明磨煤机运行状态越正常。

3.2 动态阈值计算

阈值的设定对判断磨煤机设备是否正常运行至关重要。由于磨煤机工况较为复杂、涉及的特征参数较多、部分测点值易受环境及磨煤机负荷快速频繁变化干扰，固定阈值很容易导致漏报或误报。因此本文采用了自适应动态阈值作为磨煤机运行状态的判断准则以减少漏报或误报次数。

根据切比雪夫不等式，对任意具有有限数学期望和有限方差的随机变量 x ，给定误检率 $\alpha = \frac{1}{n^2}$ ，

则该随机变量 x 的正常区间为 $[\mu_x - n\sigma_x, \mu_x + n\sigma_x]$ ， μ_x 、 n 、 σ_x 分别为 x 的均值、带宽系数和均方差， n 的大小与 x 的分布规律有关。但磨煤机相似度是计算值，不是测量值，难以确定其分布规律，本文按经验取 n 为 5。所以磨煤机在正常运行时，观测向量与估计

向量间的相似度在所有 T 个时刻的取值区间为 $[\mu_{s,T}-5\sigma_{s,T}, \mu_{s,T}+5\sigma_{s,T}]$, 其中:

$$\mu_{s,T} = \frac{1}{T} \sum_{i=1}^T s_i \quad (10)$$

$$\sigma_{s,T} = \sqrt{\frac{1}{T-1} \sum_{i=1}^T (s_i - \mu_{s,T})^2} \quad (11)$$

对式(8)和式(9)采用迭代法推导得:

$$\mu_{s,T+1} = \frac{1}{T+1} s_T + \frac{T}{T+1} \mu_{s,T-1} \quad (12)$$

$$\sigma_{s,T+1} = \sqrt{\frac{T-1}{T} (\sigma_{s,T})^2 + \frac{1}{T+1} (s_{T+1} - \mu_{s,T})^2} \quad (13)$$

这样得到的相似度均值和方差不仅是随时刻 T 变化的动态值, 而且每次只需要用到 T 时刻的均值、方差和 $T+1$ 时刻的相似度即可得到 $T+1$ 时刻的相似度均值和方差, 相比于式(10)和式(11)大幅减少了计算量。

由于 s 越大代表磨煤机运行状态越健康, 且值为 $(0, 1]$, 所以把相似度正常取值范围的下限 $\mu_{s,T}-5\sigma_{s,T}$ 作为动态阈值。

4 基于 MSET-AHP 的磨煤机故障预警实例

某 350 MW 发电机组的辊式中速磨煤机于 2017 年 11 月 16 日 07:59:45 发生堵煤故障引起跳闸。本文利用 11 月 16 日 12:00:00 至跳闸时间的 292 785 条数据 (数据间隔为 1 s) 对 MSET-AHP 模型的有效性进行了验证分析: 将前 280 800 条数据作为模型的训练集, 该数据集包含了磨煤机 168 h 的运行数据, 基本覆盖了全工况下的运行状态, 保证从中抽取形成的记忆矩阵能基本表示全工况的正常运行状态; 将之后的 10 800 条数据作为测试集; 最后的 1 185 条数据作为验证集。

4.1 特征值选择

磨煤机故障相关变量的适当选取对 MSET 建模至关重要, 直接关系到判断磨煤机运行状态的准确性, 进而影响到磨煤机故障预警效果。与该磨煤机相关的故障相关变量见表 3。

由于变量较多, 考虑用相关性分析对其降维。首先对各变量进行 KS 检验分析^[19], 得到各变量的 P 值均为 0, 即拒绝原假设, 各变量均不符合正态分布。而皮尔逊相关系数分析需要数据满足正态分布, 所以不能用皮尔逊相关系数, 这里采用不需要

数据正态分布的斯皮尔曼相关系数对磨煤机相关变量进行相关性分析, 斯皮尔曼相关系数公式为:

$$\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (14)$$

式中: d_i 为 2 个变量排序后的位次之差; n 为观测样本数。

表 3 磨煤机故障相关变量
Tab.3 The related variables of coal mill failure

序号	相关变量	符号
1	风粉混合物温度/℃	x_1
2	反作用力加载油压/MPa	x_2
3	磨辊加载油压/MPa	x_3
4	磨煤机电流/A	x_4
5	磨煤机一次风压力/kPa	x_5
6	密封风母管压力/kPa	x_6
7	一次风与密封风差压/kPa	x_7
8	磨煤机出入口差压/ kPa	x_8
9	油箱油温/℃	x_9
10	一次风流量/(t·h ⁻¹)	x_{10}
11	电机轴承温度/℃	x_{11}
12	减速机推力瓦温/℃	x_{12}
13	减速机油池油温/℃	x_{13}
14	实际功率/MW	x_{14}

所有变量的相关性分析如图 1 所示, 相关性系数的绝对值大于 0.8 时, 表明 2 个变量有显著的线性相关关系。由图 1 可知, x_5 与 x_8 、 x_7 与 x_8 、 x_9 、 x_{12} 、 x_{13} 两两间的相关性系数均大于 0.8, 因此将 x_5 、 x_7 、 x_9 、 x_{12} 去除, 将剩下的 10 个变量作为磨煤机故障预警的特征参数。

4.2 构建记忆矩阵

为消除量纲对计算结果的影响, 在构建记忆矩阵前对剩余的 10 个变量进行归一化处理, 归一化公式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

式中: x_{\min} 和 x_{\max} 分别是变量 x 的最小值和最大值。

基于等距抽样的方法从归一化后的 n 行 m 列训练集中抽取部分数据作为记忆矩阵 D , 等距抽样法即对观测向量中某个变量每相隔一定距离取一个数, 对 n 个变量重复该操作, 最后把重复的观测向量去除即得到记忆矩阵。本文对所选 10 个变量进行抽样, 每隔 0.01 的距离抽取一条数据 (选取条件为误差小于 0.001), 具体流程如图 2 所示。




图 1 spearman 相关性分析
Fig.1 Spearman correlation analysis

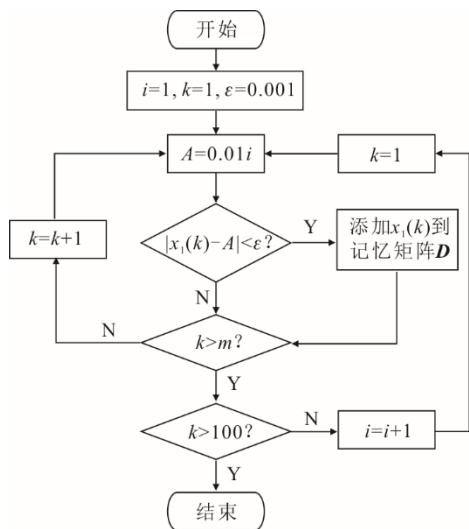


图 2 以 x_1 变量为例构建记忆矩阵
Fig.2 The memory matrix construction by taking x_1 variable as an example

4.3 构建 AHP 判断矩阵并计算变量权重

建立磨煤机故障预警层次结构模型如图 3 所示。结构模型共 3 层，目标层为磨煤机故障，准则

层为测点信息量、测量可靠性，方案层为所有相关变量。

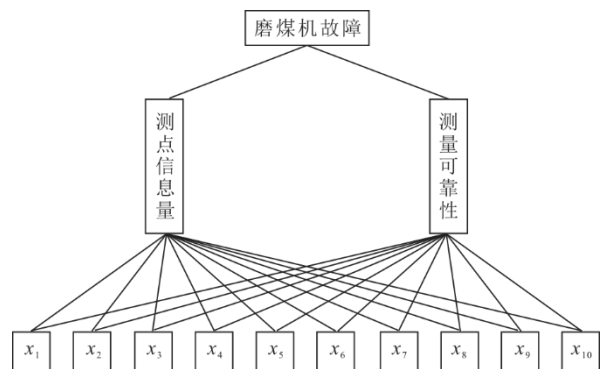


图 3 磨煤机故障预警层次结构
Fig.3 Hierarchical structure of the coal mill fault warning

根据图 3 形成 3 个判断矩阵分别为式(16)一式(18)。第 2 层相对于第 1 层的判断矩阵为：

$$A = \begin{bmatrix} 1 & 2 \\ 1/2 & 1 \end{bmatrix} \quad (16)$$

第 3 层相对于测点信息量的判断矩阵为：

$$B_1 = \begin{bmatrix} 1 & 1/3 & 1/3 & 1/5 & 1 & 1 & 1 & 1/5 & 1/3 & 1/3 \\ 3 & 1 & 1 & 1/2 & 3 & 3 & 3 & 1/2 & 1 & 1 \\ 3 & 1 & 1 & 1/2 & 3 & 3 & 3 & 1/2 & 1 & 1 \\ 5 & 2 & 2 & 1 & 5 & 5 & 5 & 1 & 2 & 2 \\ 1 & 1/3 & 1/3 & 1/5 & 1 & 1 & 1 & 1/5 & 1/3 & 1/3 \\ 1 & 1/3 & 1/3 & 1/5 & 1 & 1 & 1 & 1/5 & 1/3 & 1/3 \\ 1 & 1/3 & 1/3 & 1/5 & 1 & 1 & 1 & 1/5 & 1/3 & 1/3 \\ 5 & 2 & 2 & 1 & 5 & 5 & 5 & 1 & 2 & 2 \\ 3 & 1 & 1 & 1/2 & 3 & 3 & 3 & 1/2 & 1 & 1 \\ 3 & 1 & 1 & 1/2 & 3 & 3 & 3 & 1/2 & 1 & 1 \end{bmatrix} \quad (17)$$

第 3 层相对于测量可靠性的判断矩阵为:

$$B_2 = \begin{bmatrix} 1 & 1/5 & 1/5 & 1/7 & 1/3 & 1/3 & 1 & 1/5 & 1/5 & 1/5 \\ 5 & 1 & 1 & 1/3 & 3 & 3 & 5 & 1 & 1 & 1 \\ 5 & 1 & 1 & 1/3 & 3 & 3 & 5 & 1 & 1 & 1 \\ 7 & 3 & 3 & 1 & 5 & 5 & 7 & 3 & 3 & 3 \\ 3 & 1/3 & 1/3 & 1/5 & 1 & 1 & 3 & 1/3 & 1/3 & 1/3 \\ 3 & 1/3 & 1/3 & 1/5 & 1 & 1 & 3 & 1/3 & 1/3 & 1/3 \\ 1 & 1/5 & 1/5 & 1/7 & 1/3 & 1/3 & 1 & 1/5 & 1/5 & 1/5 \\ 5 & 1 & 1 & 1/3 & 3 & 3 & 5 & 1 & 1 & 1 \\ 5 & 1 & 1 & 1/3 & 3 & 3 & 5 & 1 & 1 & 1 \\ 5 & 1 & 1 & 1/3 & 3 & 3 & 5 & 1 & 1 & 1 \end{bmatrix} \quad (18)$$

上述 3 个判断矩阵均通过一致性检验, 利用特征值法求得判断矩阵 A 、 B_1 、 B_2 对应的权重分别为:

$$A_w = [0.67, 0.33]^T \quad (19)$$

$$B_{1w} = [0.04, 0.11, 0.11, 0.20, 0.04, 0.04, 0.04, 0.2, 0.11, 0.11]^T \quad (20)$$

$$B_{2w} = [0.02, 0.12, 0.12, 0.28, 0.05, 0.05, 0.02, 0.12, 0.12, 0.12]^T \quad (21)$$

据此得到 10 个相关变量的最终权重为:

$$w = [B_{1w}, B_{2w}] \cdot A_w = [0.330, 1.120, 1.120, 2.283, 0.410, 0.410, 0.330, 1.754, 1.120, 1.120]^T \quad (22)$$

4.4 磨煤机故障预警策略

将 4.3 节构成的记忆矩阵和 4.1 节的测试集观测向量代入式(6)计算出对应的估计向量。本文以磨煤机电流测点为例, 其观测值、估计值及相对误差随样本序号 (即时间) 的变化如图 4 所示。

磨煤机相似度值随时间变化的曲线如图 5 所示。由图 5 可知, 相似度值最低在 0.7 左右, 为减少模型的误报率, 同时尽可能最小化漏报率, 因此设定一个固定阈值 0.7, 当动态阈值小于 0.7 时不更新。




图 4 磨煤机电流估计
Fig.4 Estimation of coal mill current

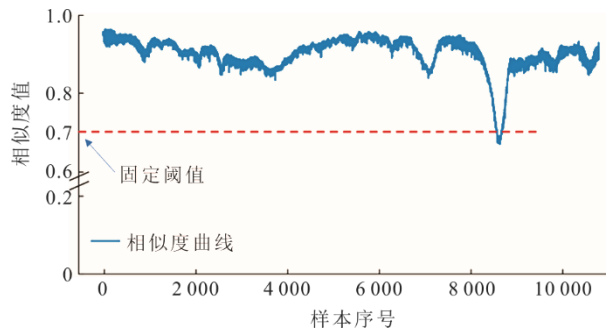


图 5 测试集磨煤机相似度值
Fig.5 The similarity of coal mill in the test set

根据 3.2 节的动态阈值 $\mu_{s,T}-5\sigma_{s,T}$ 计算方法,在测试集中(共 10 800 条数据)应用 MSET 方法和 MSET-AHP 方法,发现 MSET 方法误报次数为 102 次,而 MSET-AHP 方法误报次数为 98 次,相比于 MSET 方法减少误报 4 次。

同理得到故障集的相似度值和动态阈值随时间的变化曲线,具体如图 6 和图 7 所示,图 6 采用的是 MSET 方法,图 7 采用的是 MSET-AHP 方法。在图 6 中可以观察到当样本序号到 1 008 时,MSET 模型发出预警信号,而图 7 中样本序号到 992 时 MSET-AHP 模型发出预警信号,即 MSET-AHP 模型比 MSET 模型提前 10 s 发现磨煤机故障征兆。磨煤机实际发生故障 1 185,即本文模型可以提前 193 s 发现磨煤机故障征兆。




图 6 MSET 方法对磨煤机故障预测

Fig.6 Fault prediction of the coal mill by MSET method

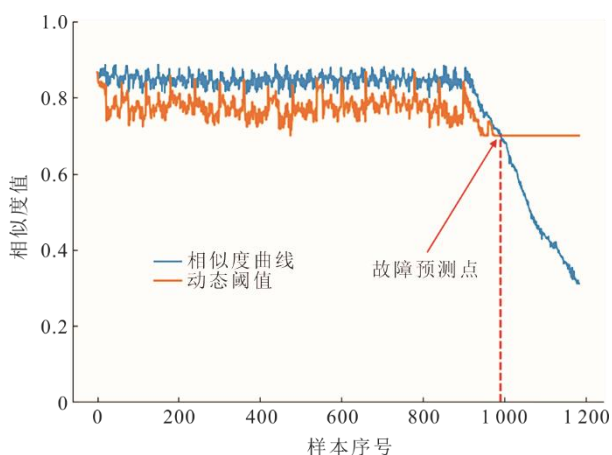


图 7 MSET-AHP 方法对磨煤机故障预测

Fig.7 Fault prediction of the coal mill by MSET-AHP method

5 结 论

本文采用 MSET-AHP 方法对磨煤机故障预警

进行建模,经过某辊式磨煤机发生故障的实例分析证明。

1) 该模型能有效提前 193 s (即 3 min 以上)发现磨煤机故障先兆,对于减少磨煤机故障实际发生率具有重要意义。

2) 采用斯皮尔曼相关性分析对相关变量进行降维,可以保证在尽量准确计算估计向量的同时提升模型的计算效率

3) 动态阈值结合固定阈值的方法可以同时减少预警模型的漏报率和误报率。

4) 基于层次分析法对 10 个相关变量进行权重赋值,更科学的考虑了每个变量对磨煤机故障的影响和测量的可靠性,相比于原来的 MSET 方法减少了一定程度的漏报率和误报率。

[参 考 文 献]

- [1] 国家能源局. 关于提升电力系统调节能力的指导意见[EB/OL]. (2018-03-23)[2022-08-10]. http://www.gov.cn/xinwen/2018-03/23/content_5276855.htm. National Energy Administration. About improving power system adjustment ability of guidance[EB/OL]. (2018-03-23)[2022-08-10]. http://www.gov.cn/xinwen/2018-3/23/content_5276855.htm.
- [2] 赵书强, 吴杨, 李志伟, 等. 考虑风光出力不确定性的电力系统调峰能力及经济性分析[J]. 电网技术, 2022, 46(5): 1752-1761. ZHAO Shuqiang, WU Yang, LI Zhiwei, et al. Analysis of power system peaking capacity and economy considering uncertainty of wind and solar output[J]. Power System Technology, 2022, 46(5): 1752-1761.
- [3] 罗睿, 王毅, 仇璐珂, 等. 发电机状态辨识的空间排序熵模型研究[J]. 热力发电, 2022, 51(6): 159-166. LUO Rui, WANG Yi, QIU Luke, et al. Research on spatial permutation entropy model for generator state identification[J]. Thermal Power Generation, 2022, 51(6): 159-166.
- [4] 陈星宇. 基于多元状态估计的中速磨煤机运行状态诊断和故障预警研究[D]. 杭州: 浙江大学, 2021: 1. CHEN Xingyu. Research of early fault warning of coal medium speed mill based on multivariate state estimation technique[D]. Huangzhou: Zhejiang University, 2021: 1.
- [5] 刘涛. 基于多元状态估计的电站风机故障预警研究及系统开发[D]. 北京: 华北电力大学, 2016: 1. LIU Tao. Research and development of early fault warning of fan in power plant based on multivariate state estimation technique[D]. Beijing: North China Electric Power University, 2016: 1.
- [6] ORSAGH R F, ROEMER M J, SHELDON J S, et al. A comprehensive prognostics approach for predicting gas turbine engine bearing life[C]//International Gas Turbine Institute. Proceedings of the ASME Turbo Expo 2004: Power for Land, Sea, and Air. 2004: 777-785.
- [7] 付芹. 基于 PNN 模型的机械设备状态预警和故障诊断方法研究[D]. 西安: 西安建筑科技大学, 2010: 1. FU Qin. Research on state warning and fault diagnosis of mechanical equipment based on PNN-model[D]. Xi'an:

- Xi'an University of Architecture and Technology, 2010: 1.
- [8] 陈利, 蒋维东, 杨礼. 支持向量数据描述法在变压器故障预警中的应用[J]. 西南民族大学学报(自然科学版), 2008(3): 568-571.
CHEN Li, JIANG Weidong, YANG Li. The application of support vector data description for the fault prewarning of power transform[J]. Journal of Southwest Minzu University (Natural Science Edition), 2008(3): 568-571.
- [9] 耿广震. 支持向量机在发电设备故障诊断中的应用研究[D]. 天津: 天津大学, 2016: 1.
GENG Guangzhen. Application of support vector machine in fault diagnosis of power generation equipment[D]. Tianjin: Tianjin University, 2016: 1.
- [10] 鹿卫国, 戴亚平, 高峰. 一种基于概率分布估计的水电机组故障预警方法[J]. 中国电机工程学报, 2005, 25(4): 96-100.
LU Weiguo, DAI Yaping, GAO Feng. A hydroelectric-generator unit fault early warning method based on distribution estimation[J]. Proceedings of the CSEE, 2005, 25(4): 96-100.
- [11] 章雅楠. 基于神经网络的轴承故障预警方法研究[D]. 保定: 华北电力大学, 2021: 1.
ZHANG Yanan. Research on early warning methods of bearing failure based on neural network[D]. Baoding: North China Electric Power University, 2021: 1.
- [12] 顾军民, 陈思函, 马永光. 基于 RBF 神经网络的风电机组变桨系统故障预警[J]. 电力科学与工程, 2020, 36(12): 37-43.
GU Junmin, CHEN Sihan, MA Yongguang. Research on fault early warning of wind turbine pitch system based on RBF neural network[J]. Electric Power Science and Engineering, 2020, 36(12): 37-43.
- [13] 王博. 基于多元状态估计的电站风机故障预警方法研究与应用[D]. 西安: 西安热工研究院有限公司, 2017: 1.
WANG Bo. Research and application on early fault warning of power plant fans based on multivariate state estimation technique[D]. Xi'an: Xi'an Thermal Power Research Institute Co., Ltd., 2017: 1.
- [14] 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 Qinmin. 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.
- [15] 王成. 基于记忆网络的时间序列多步预测算法研究[D]. 北京: 北京交通大学, 2020: 1.
WANG Cheng. Research on multi-step forecasting algorithm of time series based on memory network[D]. Beijing: Beijing Jiaotong University, 2020: 1.
- [16] 杨婷婷, 高乾, 李浩千, 等. 基于卷积神经网络-长短时记忆神经网络的磨煤机故障预警[J]. 热力发电, 2022, 51(10): 122-129.
YANG Tingting, GAO Qian, LI Haoqian, et al. Coal mill fault early warning technology based on CNN-LSTM network[J]. Thermal Power Generation, 2022, 51(10): 122-129.
- [17] VAIDYANATHAN K, GROSS K. MSET performance optimization for detection of software aging[C]// Proceedings of the IEEE Symposium on Computer-Based Medical Systems. 2003: 1.
- [18] SUN P, JIN G. Research on satellite fault detection method based on MSET and SRPRT[C]// Proceedings of the International Conference on Wireless and Satellite Systems. 2020: 33-45.
- [19] 李国汉, 王可人, 金虎. 一种基于 KS 距离的 OFDM 子载波数估计法[J]. 计算机工程, 2012, 38(21): 100-102.
LI Guohan, WANG Keren, JIN Hu. An OFDM sub-carrier number estimation method based on KS distance[J]. Computer Engineering, 2012, 38(21): 100-102.

(责任编辑 邓玲惠)