

基于 CNN-LSTM 的燃气轮机燃烧室故障预警

周锐, 康英伟

(上海电力大学自动化工程学院, 上海 200090)

摘要:为了解决燃气轮机燃烧室中的故障问题,结合深度学习的优势,在长短期记忆网络(Long Short-term Memory, LSTM)的基础上,提出了一种基于卷积神经网络-长短期记忆网络的燃烧室故障预警方法。首先,根据正常的历史运行数据构建燃烧室的预警模型,再将特征参数输入到预警模型中得到预测值,预测值与实际值之间的偏离度可以反映燃烧室内部工作是否正常。考虑到模型预测结果的非平稳性和非线性等特点,引入滑动窗口法确定故障预警阈值,最后根据确定的预警阈值判断是否出现故障。采用某燃气-蒸汽联合循环发电机组仿真平台对上述模型进行验证。仿真结果表明:该模型相较于 LSTM 预测模型具有更高的精确度,可以及时发现故障征兆,并对燃烧室故障做出有效预警。

关键词:燃烧室;故障预警;LSTM 神经网络;卷积神经网络;预测偏离度;滑动窗口法

中图分类号:TK472 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2024.01.021

[引用本文格式]周锐,康英伟.基于 CNN-LSTM 的燃气轮机燃烧室故障预警[J].热能动力工程,2024,39(1):191-197. ZHOU Rui, KANG Ying-wei. Fault warning of gas turbine combustor based on CNN-LSTM[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(1): 191-197.

Fault Warning of Gas Turbine Combustor based on CNN-LSTM

ZHOU Rui, KANG Ying-wei

(School of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code: 200090)

Abstract: In order to solve the fault problem of gas turbine combustor, a combustor fault early warning method based on convolutional neural network (CNN) and long short-term memory (LSTM) network was proposed combining with the advantage of deep learning. First, a prediction model of the combustor was constructed based on the normal historical operation data. Then, the characteristic parameters were input into the early warning model to obtain the predicted values. The deviation between the predicted and actual values could reflect whether the internal work of the combustor was normal or not, and considering the nonstationary and nonlinear characteristics of the model prediction results, the sliding window method was introduced to determine the fault warning threshold. Finally, whether a fault occurs was judged according to the determined warning threshold. The above model was validated on a gas-steam combined cycle generator unit simulation platform. The simulation results show that the model has higher accuracy than the LSTM prediction model, and can detect the signs of failure in time and make effective early warning of the combustor failure.

Key words: combustor, fault warning, LSTM neural network, convolutional neural network, forecast deviation, sliding window method

收稿日期:2023-04-24; 修订日期:2023-05-19

基金项目:国家自然科学基金项目(61573239);上海发电过程智能管控工程技术研究中心资助项目(14DZ2251100)

Fund-supported Project: National Natural Science Foundation of China (61573239); Shanghai Engineering Research Center for Intelligent Control of Power Generation Process (14DZ2251100)

作者简介:周锐(1998-),男,上海电力大学硕士研究生。

通讯作者:康英伟(1980-),男,上海电力大学副教授。

引 言

燃气轮机是一个复杂的非线性系统,其内部存在很多复杂的部件,每个部件都与燃气轮机的工作性能相互关联^[1]。由于燃气轮机长时间工作在高温、高压以及各种复杂的环境中,其内部部件如果发生损坏,可能会造成故障,导致燃气轮机停机,这会对整个电厂产生较大的经济损失,甚至会引发一些安全事故。燃烧室是燃气轮机中换热功率最高的部件,其功能是将送入的高压空气与天然气混合,再进行点火燃烧,最后将燃烧生成的高温高压烟气送往涡轮推动转子做功^[2]。燃烧室作为燃气轮机的重要部件,其工作状态将直接影响燃气轮机能否正常工作,因此对燃烧室进行故障预警具有重要意义。

现阶段针对燃气轮机的研究主要集中在燃气轮机的故障诊断方面,对燃气轮机的故障预警方面研究较少。随着科学技术的不断进步,对燃气轮机的故障预警也有了一定的研究。文献[1-4]提出应用多元状态估计技术对燃气轮机及其他重要设备进行故障预警,主要是针对这些设备的多个参数进行建模,并通过模型得到参数预测值,再与实际值比较,判断是否出现故障。文献[5-6]提出使用不同的方法来确定燃烧室的预警阈值,之后再深度学习模型对燃烧室进行故障预警,研究表明,最终都取得了合适的预警阈值并且未出现误报情况。文献[7-8]提出将不同的模型与 LSTM 神经网络相融合进行故障预警,此模型的主要功能分为两部分,一部分用于处理数据特征,另一部分是 LSTM 网络模型,用于预测各参数的变化值,研究表明,混合模型的精度相较于单一的 LSTM 网络模型有明显提升。文献[9]提出使用门控循环单元(Gated Recurrent Unit, GRU)构建基线模型的参数趋势分析方法对压气机进行故障预警。文献[10]提出先利用自适应热力建模策略构建热力模型,再利用深度学习进行燃机建模,仿真结果表明,通过此方法可以准确地得到各部件的健康参数。文献[11]提出将故障预警与故障诊断相结合并应用于天然气管道研究中,结果表明,该模型可以准确地对系统故障提前预测并定位。文献[12]提出用贝叶斯算法优化 LSTM

模型的参数,如神经网络层数,神经元个数等,研究结果表明,合适的模型参数能提高 LSTM 模型的预测精度。文献[13-15]提出将 LSTM 和卷积神经网络(Convolutional Neural Network, CNN)结合起来对轴承的使用寿命进行预测,仿真结果表明,混合模型的预测精度优于单一的网络模型。文献[16]提出将 CNN 和 GRU 应用在能源消耗预测的统一框架中,再将其用于预测电量,得到了较好的预测效果。

由于燃烧室处于复杂的工作环境中,各变量之间存在较强的耦合性。传统的机器学习算法和时间序列预测模型对燃烧室各变量的预测效果并不理想。本文选择时间序列预测中应用较为广泛的长短期记忆网络和卷积神经网络,针对燃烧室的数据特征,提出一种 CNN 和 LSTM 神经网络融合的预测模型。仿真结果表明, CNN-LSTM 模型相较于其他模型具有更高的精度,能够用于燃烧室故障预警,实现超前性维修。因此,此方法具有一定的实际应用价值。

1 故障预警模型理论基础

1.1 卷积神经网络

卷积神经网络(CNN)是一种包含卷积运算和特征压缩的多层神经网络,是深度学习领域中常用的算法之一。CNN 主要包含 3 层结构,分别是卷积层、池化层和全连接层^[8]。卷积层对输入样本进行特征处理,卷积运算的主要公式为:

$$\mathbf{x}_k = \sigma\left(\sum_{i=1}^N \mathbf{x}_k \cdot w_{ik} + b_k\right) \quad (1)$$

式中, \mathbf{x}_k —第 k 次卷积计算的输入数据,是由多个变量归一化后组成的二维向量; w_{ik} —第 k 个卷积核做第 i 次运算的权重系数; $\sigma(\cdot)$ —激活函数,大多数情况下选择 sigmoid 作为激活函数; N —输入做卷积运算的样本数量; b_k —第 k 个卷积核的偏置参数。

池化层对卷积层的输出数据进行压缩,只提取数据中最具代表性的那部分数据,实现特征降维,从而降低计算的复杂度,提高计算的效率。首先通过 CNN 神经网络得到样本数据的时间特性,再将数据通过全连接层传递到 LSTM 网络中进行时序预测^[8]。

1.2 长短期记忆网络

LSTM 神经网络是在循环神经网络 (Recurrent Neural Network, RNN) 的基础上加入独特的门控信号发展而来的,弥补了 RNN 处理长序列数据时出现的梯度消失或梯度爆炸等缺陷。LSTM 神经网络自带的隐藏层,不仅与当前时刻的输出有关,还保留了之前所有时刻的部分重要信息,所以能够随着时间持续保留信息^[7]。LSTM 神经网络内部结构如图 1 所示,可以将其分为 3 部分:遗忘门、输入门和输出门。




图 1 LSTM 神经网络内部结构

Fig. 1 Internal structure of LSTM neural network

LSTM 神经网络的工作原理是通过 3 个门控单元来控制信息之间的传递。

遗忘门用于决定要舍弃哪部分信息,其中 f_t 是 t 时刻遗忘门的输出信号,由当前 t 时刻的输入信息 x_t 和 $t-1$ 时刻隐藏层的输出 h_{t-1} 共同决定:

$$f_t = \sigma(w_f x_t + w_f h_{t-1} + b_f) \quad (2)$$

式中: w_f —遗忘门的权重系数; b_f — t 时刻遗忘门的偏置参数; $\sigma(\cdot)$ —sigmoid 激活函数,输出值的范围为 $0 \sim 1$ 。

输入门包含两部分: sigmoid 激活函数在 t 时刻的输出 i_t 和 tanh 激活函数的输出 \tilde{c}_t 。再将遗忘门和输入门的两部分信息共同输入到细胞状态 C_t 中。

$$i_t = \sigma(w_i x_t + w_i h_{t-1} + b_i) \quad (3)$$

$$\tilde{c}_t = \tanh(w_c x_t + w_c h_{t-1} + b_c) \quad (4)$$

$$C_t = f_t C_{t-1} + i_t \tilde{c}_t \quad (5)$$

式中: w_i —输入门的权重系数; w_c — \tilde{c}_t 的权重系数; h_{t-1} — $t-1$ 时刻隐藏层的输出; b_i, b_c —隐藏层和输

入信息的偏置参数; $\tanh(\cdot)$ —双曲正切函数; C_t —更新后的细胞状态。

o_t 为 t 时刻输出门的输出信号,与 t 时刻的记忆细胞 C_t 共同决定输入到 h_t 中的信息,即 t 时刻的隐藏层状态 h_t 是由 o_t 与 C_t 经过运算得到的:

$$o_t = \sigma(w_o x_t + w_o h_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \tanh(C_t) \quad (7)$$

式中: o_t — t 时刻输出门的输出信息; w_o —输出门的权重系数; b_o —输出门偏置参数; h_t — t 时刻隐藏层的输出信息。

1.3 偏离度与滑动窗口法

CNN-LSTM 模型预测值与实际值之间的残差能够反映目标参数的变化。然而,仅通过残差进行故障预警会遗漏很多异常的信息,为了能够准确地得到燃烧室的运行状态,需要相关特征变量的实际值与预测值之间的整体偏离度。欧式距离是判断两个变量之间偏离度的常用方法^[1],在此基础上得到的偏离度函数为:

$$S = \sqrt{\sum_{i=1}^n (y_r - y_p)^2} \quad (8)$$

式中: y_r —第 i 个样本的实际值; y_p —第 i 个样本的预测值。

偏离度越大,两个向量之间的差异性越大;偏离度越小,两个向量之间的相似程度越大。

考虑到模型预测结果的非平稳性和非线性等特点,引入滑动窗口法确定故障预警阈值。利用此方法能够消除燃烧室运行中多种因素的干扰,提高预测结果的准确性。选取合适的滑动窗口宽度,可以迅速捕获数据偏离程度的变化趋势,消除不确定性因素的干扰^[1],提高预测模型的可靠性。

假设在某个时间段内,模型预测数据的偏离度序列一共有 d 个,则 d 个序列的偏离度集合可以表示为:

$$S(\mathbf{X}_{tm}, \mathbf{X}_{est}) = [S_1, S_2, S_3 \cdots S_D \cdots S_d] \quad (9)$$

式中: \mathbf{X}_{tm} — d 个样本的真实值所组成的向量; \mathbf{X}_{est} — d 个样本的预测值所组成的向量。

对这段时间序列设定的滑动窗口宽度为 D ,滑动窗口法如图 2 所示。窗口内 D 个偏离度的平均值计算公式为:

$$\bar{S} = \frac{1}{D} \sum_{i=1}^d S_i \quad (10)$$

式中： S_i —第 i 个时间序列的偏离度值 ($D < d$)。




图 2 滑动窗口法

Fig.2 Sliding window method

根据计算得到的偏离度平均值来确定预警阈值 S_{AN} 。燃烧室正常运行状态下的平均偏离度的最大值为 S_M ，则燃烧室故障预警阈值的计算公式为：

$$S_{AN} = K S_M \quad (11)$$

式中： K —常数项，此数值由操作人员的经验来确定，一般大于 0.9^[2]。

2 燃烧室故障预警分析

2.1 故障预警流程

利用建立好的故障预警模型，分析并得到预测数据，计算预测值与实际值之间的偏离度，并利用滑动窗口法得到预警阈值，之后根据预警阈值来确定设备是否存在潜在故障。若燃烧室在运行过程中的偏离度小于预警阈值，则认定燃烧室处于正常运行；若偏离度超过预警阈值，则认定燃烧室可能会出现故障，此时模型会发出报警信号，提醒运行人员检修。图 3 为燃烧室故障预警流程。

2.2 燃烧室常见故障

燃烧室故障的出现都会伴随某些特性变化，这些变化会影响到燃烧室的状态参数，但是无法直接观测到^[7]。所以就需要通过提取特征参数，建立预测模型，监测模型输出的预测值和实际值之间的残差来判断是否会出现故障。根据现阶段使用燃气轮机的经验以及对排气温度与燃烧室燃烧的分析，可

以将故障分析概括为：

(1) 燃料喷嘴堵塞。由于燃气轮机长时间运行，空气燃烧产生的杂质可能会吸附在喷嘴，减小喷嘴和管道的内径，将影响到天然气流量和燃烧室压力，最终导致透平排温异常。

(2) 火焰筒裂纹。压气机的排气进入到燃烧室中，会使燃烧室喷嘴火焰不稳定，最终导致透平排温异常。

(3) 燃烧室喷嘴积碳。燃烧室内部空气与燃料混合燃烧后产生的杂质附着在燃烧室内部，影响燃烧室内部压力，最终导致透平排温异常。

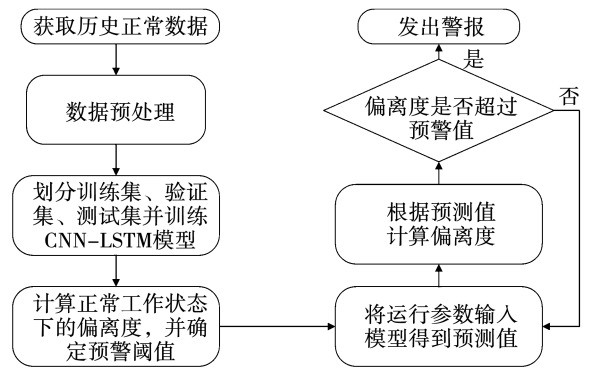


图 3 燃烧室故障预警流程

Fig.3 Combustor fault warning process

综上所述，燃烧室的几种常见故障均会影响到透平排气温度，因此透平排气温度是燃烧室故障预警的重要变量之一。

2.3 特征量选取与数据采集

在实现故障预警之前，特征量的选取尤为关键，应选取与故障具有相关性的特征量。燃气轮机发电功率表征着机组整体的运行状况，当燃烧室出现故障时，做功不稳定，从而减弱燃气轮机的做功能力，影响燃气轮机效率。燃烧室内部发生剧烈的化学反应，当出现故障时，不稳定燃烧会导致压力波动，因此燃烧室压力是表征燃烧室故障的重要变量之一^[2]。天然气流量和调节阀开度共同决定燃烧室内部的燃烧情况，而压气机出口的排气会进入燃烧室燃烧，所以压气机的出口温度、天然气流量以及调节阀的开度也应该作为输入的特征参数。燃烧室火焰温度信号包含某些故障信息，但无法直接安装温度传感器来测量其内部火焰温度的变化趋势，常用

的方法就是通过测量透平的排气温度来间接反映燃烧室内部的性能变化情况。

综上所述,选取表 1 中的 7 个变量用于燃烧室正常运行状态的建模。其中,透平排气温度是反映燃烧室温度变化的重要变量,所以将其作为模型的目标变量。相关变量的取值可在燃气轮机仿真机平台上进行,仿真机组选择三菱 M701F4 型燃气轮机,组成燃气-蒸汽联合循环机组。仿真系统运行稳定后,可以通过 TCS 燃气轮机操作站直接读出相关变量,TCS 操作站界面如图 4 所示。

表 1 燃气轮机相关变量

Tab. 1 Gas turbine related variables

参 数	数 值
燃烧室压力/MPa	1.7
透平排气温度/°C	668
天然气流量/ $\text{m}^3 \cdot \text{h}^{-1}$	81 218
压气机出口温度/°C	423
燃气轮机功率/MW	312
压比	14
燃料控制阀开度/%	80

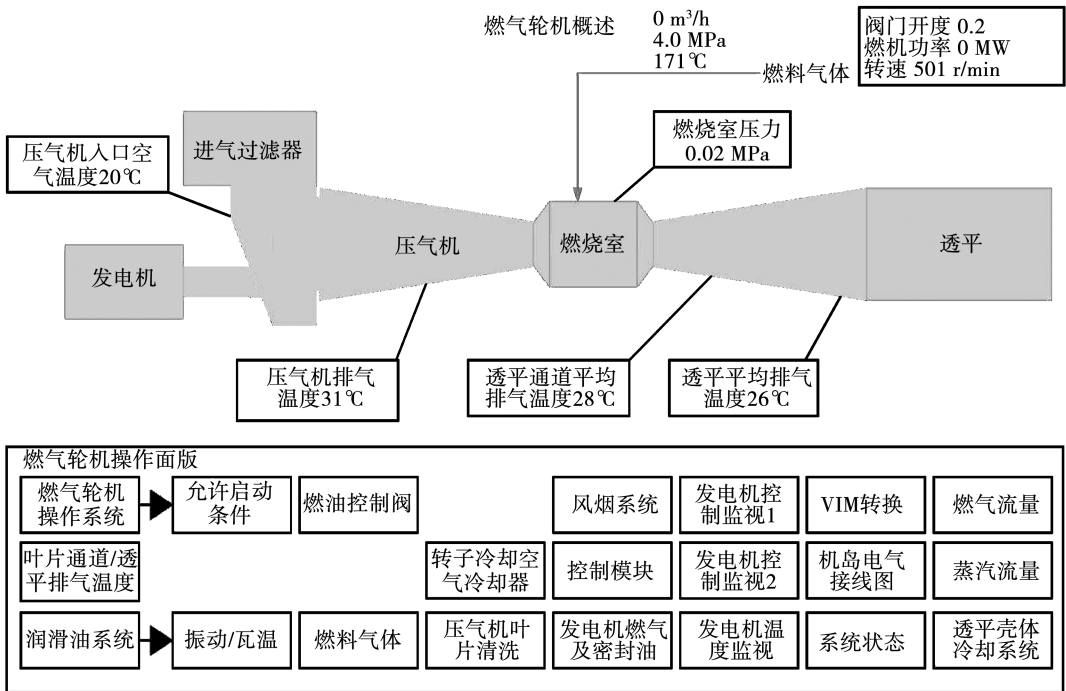


图 4 仿真平台燃气轮机操作站 TCS

Fig. 4 TCS operating station of gas turbine simulation platform

3 仿真分析

3.1 数据预处理

在对 CNN-LSTM 模型进行训练之前,由于被选择数据之间的量纲不同,各数据之间的绝对值差异也较大,因此必须先对所有数据进行预处理。数据的归一化处理既能够降低不同数据之间的差异性,也能在一定程度上提高模型预测的准确性^[15]:

$$x_{\text{std}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (12)$$

式中: x —归一化前的数据; x_{std} —归一化后的数据; x_{min} —样本数据中 x 的最小值; x_{max} —样本数据中 x

的最大值。

将归一化后的数据转化为适用于监督学习的数据格式,即根据设置的时间步长来切分数据,把数据切分成相同长度的向量。假设时间步长为 n ,则 $\mathbf{X}_i = [x_i(t_0), x_i(t_1), \dots, x_i(t_{n-1})]$,则下一个样本序列整体后移一个时刻,即 $\mathbf{X}_{i+1} = [x_i(t_1), x_i(t_2), \dots, x_i(t_n)]$ 。

3.2 模型预测结果分析

以透平排气温度为目标变量,建立燃烧室故障预警模型,利用燃烧室正常运行状态下的数据建模,选择表 1 中的 7 个变量作为输入数据共计建模 26 281 组,其中 60% 的数据作为训练集,20% 的数据

作为验证集,20%的数据作为测试集。迭代次数设置为 100 次,学习率设置为 0.01,在多次的训练后,得到最终的预测模型,用此模型对划分好的验证集和测试集进行验证,同时再与其他几种时间序列预测模型进行对比,预测结果对比如图 5 所示。由图 5 可知,CNN-LSTM 模型的预测效果优于其他模型。




图 5 预测结果对比

Fig.5 Comparison of prediction results




图 6 CNN-LSTM 模型残差绝对值

Fig.6 Absolute value of CNN-LSTM model residuals

CNN-LSTM 模型残差绝对值如图 6 所示。从图 6 可以看出,CNN-LSTM 预测模型残差绝对值较低,残差范围均保持在 0~2 之间。接下来使用以下 3 种常见的模型评价指标来评估各模型的精确度,最终结果如表 2 所示。

常见的 3 种模型评价指标为:

(1) 均方根误差 δ_{RMSE}

$$\delta_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_r - t_p)^2} \quad (13)$$

(2) 平均百分比误差 δ_{MAPE}

$$\delta_{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{t_r - t_p}{t_r} \right| \quad (14)$$

(3) 平均绝对误差 δ_{MAE}

$$\delta_{MAE} = \frac{1}{N} \sum_{i=1}^N |t_r - t_p| \quad (15)$$

式中: N —样本数量。

表 2 误差分析

Tab.2 Error analysis

预测模型	MAE	MAPE	RMSE
CNN	1.200	0.009 8	22.94
LSTM	1.140	0.002 6	18.09
ANN	0.830	0.009 3	18.23
ARIMA	0.995	0.117 2	18.16
CNN-LSTM	0.890	0.002 2	18.08

由表 2 可知,每种预测模型的评价指标,CNN-LSTM 模型的 RMSE 为 18.08,MAPE 为 0.002 3,MAE 为 0.89,相比于其他预测模型明显降低,而 MAE 仅仅是略高于 ANN 模型 0.06。综上所述,提出的 CNN-LSTM 预测模型的精度更高,可以进行故障预警。

3.3 故障预警结果分析

已知燃气轮机在某一时刻出现燃烧室积碳,此故障可以通过燃气轮机操作站 TCS 仿真平台设置。燃烧室在此故障隐患下运行一段时间后,随着燃烧室喷嘴积碳逐渐增多,出现燃烧异常,引发燃烧室熄火,最终导致燃气轮机停机,在此之前燃烧室处于正常工作状态。

为验证预测模型的有效性,选取故障发生前一段时间内的 1 000 个运行数据进行分析。设置滑动窗口的大小为 10,根据式(11)可得预警阈值为 2.3。

燃烧室故障预警如图 7 所示。燃烧室在第 250 个点的时候发生故障并发出警报,通过 CNN-LSTM 模型的预测,透平平均排气温度的偏离度绝对值在第 182 个点时超过预警阈值,在燃烧室发生故障之前,提前 68 个点发出预警,及早发现了故障隐患,避免引起燃气轮机的非正常停机。




图 7 燃烧室故障预警

Fig. 7 Combustor fault warning

4 结 论

通过仿真平台得到燃烧室的各变量,利用 CNN-LSTM 建立燃烧室正常运行过程中的模型,之后使用偏离度和滑动窗口法确立预警阈值。一旦发现预测值和实际值之间的偏差值超出设置的阈值,系统就会发出报警信息,降低燃气轮机的停机风险。最后将此方法应用到仿真中,得到结论:

(1) 采用传统的时序预测模型时,往往容易忽视样本数据中隐藏的关联信息,而 CNN-LSTM 模型能够较好地解决上述难题,结合了卷积神经网络和长短期记忆网络的特点,被应用在多个领域中。

(2) 在预测准确性方面,用数据集对许多单独和混合的机器学习以及深度学习模型进行仿真,这些模型包括 ARIMA、ANN、CNN、LSTM 和 CNN-LSTM。在对这些模型进行深入分析后,主张使用 CNN-LSTM 模型作为最优模型,适用于真实情况中的预警问题。

(3) 在不同模型的对比实验中,CNN-LSTM 模型的各项评价指标均高于其他预测模型,同时也能够提前 68 个点发出预警,有助于及时开展设备维修工作,提高燃气轮机的稳定性,降低经济损失。

参考文献:

[1] 陆永卿,涂 雷,茅大钧. 基于 MSET 的压气机故障预警研究[J]. 上海电力大学学报,2021,37(2):133-137.
LU Yong-qing, TU Lei, MAO Da-jun. Research on compressor fault early warning based on MSET[J]. Journal of Shanghai University of Electric Power, 2021, 37(2):133-137.

[2] 黄 伟,张泽发. 基于多元状态估计的燃烧室故障预警研究[J]. 汽轮机技术,2020,62(1):38-42.
HUANG Wei, ZHANG Ze-fa. Early warning of combustion chamber faults based on multivariate state estimation[J]. Turbine Technology, 2020, 62(1):38-42.

[3] 黄 伟,张泽发. 基于相似度分析的电站燃气轮机燃烧室故障预警研究[J]. 上海电力大学学报,2020,36(3):220-224.
HUANG Wei, ZHANG Ze-fa. Research on early warning of gas turbine combustion chamber based on similarity analysis[J]. Journal of Shanghai University of Electric Power, 2020, 36(3):220-224.

[4] 高泽明,张 斌,闫宗良. 基于 MSET 的一次风机故障预警算法研究[J]. 自动化应用,2021,62(6):64-67.
GAO Ze-ming, ZHANG Bin, YAN Zong-liang. Research on the early warning algorithm of a fan fault based on MSET [J]. Automation Applications, 2021, 62(6):64-67.

[5] 李峻辉,黄 伟. 基于 GRA-DeepAR 的燃气轮机燃烧室故障预警研究[J]. 上海电力大学学报,2023,39(1):19-24,32.
LI Jun-hui, HUANG Wei. Research on gas turbine combustion chamber fault warning based on GRA-DeepAR [J]. Journal of Shanghai University of Electric Power, 2023, 39(1):19-24,32.

[6] 黄 伟,张泽发. 基于多元线性回归与时间序列分析的燃烧室故障预警研究[J]. 汽轮机技术,2021,63(3):212-214.
HUANG Wei, ZHANG Ze-fa. Early warning of combustion chamber faults based on multiple linear regression and time series analysis [J]. Turbine Technology, 2021, 63(3):212-214.

[7] 彭道刚,姬传晨,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 Dao-gang, JI Chuan-sheng, TU Xuan, et al. Research on gas turbine compressor fault warning based on LSTM-SVM [J]. Journal of Power Engineering, 2021, 41(5):394-399.

[8] 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 Ting-ting, GAO Qian, LI Hao-qian, et al. Coal mill fault warning technology based on CNN-LSTM network [J]. Thermal Power Generation, 2022, 51(10):122-129.

[9] 王 贺,柳玉宾. 燃气轮机运行初期故障诊断与预警研究[J]. 热力透平,2021,50(4):266-269,275.
WANG He, LIU Yu-bin. Research on initial fault diagnosis and early warning of gas turbine [J]. Thermal Turbine, 2021, 50(4):266-269,275.

[10] 靳尧飞,应雨龙,李靖超,等. 基于模型与数据混合驱动的燃气轮机气路故障诊断方法[J]. 热力发电,2021,50(9):66-71,93.
JIN Yao-fei, YING Yu-long, LI Jing-chao, et al. A gas path circuit diagnosis method for gas turbine based on model and data hybrid drive [J]. Thermal Power Generation, 2021, 50(9):66-71,93.