

DOI: 10.19666/j.rlfed.202212198

基于改进马氏距离的分布式能源电站设备健康度研究

陈子洋, 彭道刚, 徐春梅, 赵慧荣
(上海电力大学自动化工程学院, 上海 200090)

[摘要] 分布式能源电站以其清洁环保、经济高效得到快速发展, 但其电站设备用于故障诊断的数据较少, 目前急需一种能够预测设备运行健康状态和老化程度的方法。基于此, 提出一种能够分析设备运行状态、获取设备劣化演变趋势的预测模型。首先将设备多维数据进行预处理, 采用层次分析法与高斯混合分布相结合, 定量地构建一种基于改进马氏距离的分布式能源电站设备健康度模型; 然后建立基于改进麻雀算法和长短时记忆神经网络的组合预测模型, 对分布式能源电站设备的劣化情况做趋势预测及相关分析。实验结果表明, 所提出的融合健康度模型在分布式能源电站实际故障数据不足的情况下, 能够在设备出现异常时做出预测。

[关键词] 设备健康度; 改进马氏距离; 高斯混合分布; 麻雀搜索算法; 长短时记忆神经网络

[引用本文格式] 陈子洋, 彭道刚, 徐春梅, 等. 基于改进马氏距离的分布式能源电站设备健康度研究[J]. 热力发电, 2023, 52(8): 188-196. CHEN Ziyang, PENG Daogang, XU Chunmei, et al. Research on equipment health of distributed energy power station based on improved Mahalanobis distance[J]. Thermal Power Generation, 2023, 52(8): 188-196.

Research on equipment health of distributed energy power station based on improved Mahalanobis distance

CHEN Ziyang, PENG Daogang, XU Chunmei, ZHAO Huirong
(College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Distributed energy power stations are developing rapidly because of their cleanliness, environmental protection, economy and high efficiency. However, there are few data used for fault diagnosis of plant equipment, so a method to predict the health state and aging degree of equipment is urgently needed. Based on this, a prediction model which can analyze the running state of equipment and obtain the deterioration trend of equipment is proposed. Firstly, multi-dimensional data of the equipment is preprocessed, and an improved Mahalanobis distance based equipment health model of distributed energy power station is constructed quantitatively by combining the analytic hierarchy process (AHP) with Gaussian mixture distribution. Then, the combined prediction model based on the improved sparrow algorithm and short and long time memory neural network is established to predict the trend and correlation analysis of the deterioration of distributed energy power plant equipment. The experimental results show that the proposed fusion health model can predict equipment anomalies in the case of insufficient actual fault data of distributed energy power stations.

Key words: device health; improved Mahalanobis distance; Gaussian mixture distribution; sparrow search algorithm; long short-term memory neural network

发电设备故障及异常的预警和早期运行方式诊断对电站的安全、环保、经济运行具有重要的意

义^[1]。分布式能源电站相关故障数据较少或相关数据不能完全反映设备故障和老化趋势情况, 无法对

收稿日期: 2022-12-06

基金项目: 国家自然科学基金重大研究计划培育项目(92067105); 上海市“科技创新行动计划”地方院校能力建设专项项目(20020500500)

Supported by: Major Research Program of National Natural Science Foundation of China (92067105); Special Project of “Science and Technology Innovation Action Plan” of Shanghai Municipal University Capacity Building (20020500500)

第一作者简介: 陈子洋(1996), 男, 硕士研究生, 主要研究方向为智能发电、设备故障诊断, 13726936261@163.com。

通信作者简介: 彭道刚(1977), 男, 教授, 主要研究方向为低碳智能发电、智慧能源与能源互联网等, pengdaogang@126.com。

设备运行状况做出正确判断^[2]。目前分布式能源电站仅靠传统的振动和温度监控,而缺少劣化趋势的监测分析和跟踪,所导致设备出现过热引起老化甚至连锁主机跳闸的情况不能提前预知。同时机组现场运行中存在振动值偏高的问题,也缺少有效的诊断手段。

设备运行状态的评估,主要通过综合分析设备的运行情况和设备自身的特征参数,利用健康指数理论构建评估模型^[3]。而分布式能源电站领域缺少相关成熟的故障诊断系统及模式,只能通过设备运行参数间接表征设备当前运行状态及老化趋势。文献[4]采用层次分析法(analytic hierarchy process, AHP)对设备运行状态赋权,从而得到较为科学的评价模型,但AHP更多依赖人们的主观判断,并不能对系统的异常运行状态达到准确识别。文献[5]采用变量健康因子法,但也未能精准识别老化设备临界状态。文献[6]通过时间尺度的非线性模型来拟合设备老化趋势,该方法采用单一健康度指标,未对处在临界健康条件下设备状态进行识别。文献[7]采用高斯混合模型和经验模式分解建立了基于设备健康状况的绩效评估模型。文献[8]将高斯混合模型、动态时间规整及熵权值算法结合,提出了一种基于群体多维特征相似性的故障预警策略。文献[9]采用模糊数学方法综合评价了定性评价难以量化的诸多参数。文献[10]结合双向长短时记忆(LSTM)神经网络和粒子滤波的方法实现了数据预测。

针对目前生产运行和设备健康评估领域存在问题,本文依托上海某分布式能源系统中“燃气内燃机+烟气热水溴化锂冷热水机组”进行研究,建立了针对此体系的健康度评价模型,经过机理分析及参数选取后,建立的健康度评价指标同样可用于分布式能源电站的电制冷机组、燃气真空锅炉等设备中。本文针对内燃机、溴化锂机组(溴机)进行分析,运用AHP结合高斯混合模型,对输入参数获取其各自高斯分量构建设备健康度模型。通过对超限的参数赋予相应权值,使构建的健康度模型更精确地反映设备异常运行状态,同时建立了改进麻雀算法(SSA)优化LSTM神经网络的组合预测SSA-LSTM模型。

1 基于马氏距离设备健康度模型

马氏距离考虑样本在不同类别的不同分布情况,是基于欧氏距离的一种改进,在描述设备健康度时被广泛使用^[11]。马氏距离通过归一化与标准化

数据后能够消除不同量级之间的数据差异,是一种用来评定数据之间相似度的指标,马氏距离计算公式为:

$$d_M(\mathbf{X}_i, \mathbf{Y}_0) = \sqrt{(\mathbf{X}_i - \mathbf{Y}_0) \boldsymbol{\Sigma}^{-1} (\mathbf{X}_i - \mathbf{Y}_0)^T} \quad (1)$$

式中: $\mathbf{X}_i = [x_{i1}, \dots, x_{ik}, \dots, x_{im}]$, \mathbf{X}_i 为当前监测特征的状态矩阵; $\mathbf{Y}_0 = [y_1, \dots, y_k, \dots, y_m]$, \mathbf{Y}_0 为该设备处于完全健康状态下的特征状态矩阵; $\boldsymbol{\Sigma}$ 为多维运行状态 \mathbf{X}_i 和健康态 \mathbf{Y}_0 的协方差矩阵。一般在工程应用中,通常将马氏距离测量相似性范围限制为[0,1]。

构建改进健康度:

$$h(\mathbf{X}_i, \mathbf{Y}_0) = \frac{1}{1 + \sqrt{(\mathbf{W}_1 + \mathbf{W}_2)(\mathbf{X}_i - \mathbf{Y}_0) \boldsymbol{\Sigma}^{-1} (\mathbf{X}_i - \mathbf{Y}_0)^T}} \quad (2)$$

式中: $h(\mathbf{X}_i, \mathbf{Y}_0)$ 表示第 i 步健康度值; \mathbf{W}_1 为通过 AHP 计算得到的权重向量; \mathbf{W}_2 为通过高斯混合分布得出的输入数据上下限值,并对超限的部分附加相应的权重向量。

通过 AHP 得出辅机监测数据的权重参数,通过高斯混合分布确定相应限值,得出的健康度更贴近设备实际健康状态,能够反映出辅机当前所对应的健康水平。

1.1 基于 AHP 权值计算

AHP 是将与决策有关的元素分解成目标、准则、方案等层次,在此基础上进行定性和定量分析的决策方法^[12]。利用 AHP 将权重 \mathbf{W}_1 分为多个故障类型,进而分解为健康度监测参数的若干层次,通过定性指标模糊量化的方法计算层次单排序(权数)和总排序,是一种多方案优化决策的系统方法^[13]。不同的设备其故障发生概率不同,对机组的影响比率也不同,通过对数据的监测,分析影响设备正常运行和对设备正常状态有损耗的状态,是机组安全运行的保证。

分布式能源电站内燃机组基于故障类型的 AHP 模型如图 1 所示。根据 AHP 3 层结构构造判断矩阵,将决策分解为目标层、准则层、方案层 3 个层次,目标层为通过 AHP 求出健康度权重 \mathbf{W}_1 ,准则层为影响设备健康程度的相关参数,方案层为监测的各项具体参数。

图 1 中:老化因素表现在机器性能指标达不到要求,如功率不足、耗油量大、零件磨损等;结构性因素指转速波动、装配不当、动静部件间的碰磨、油路堵塞等;振动因素既有旋转运动引起的振动,又有往复运动产生的振动,还有燃烧时冲击造成的振动;温度因素指系统内温度过高或散热达不到要

求，如冷媒水温度不断升高、制冷量低于设定值、废气温度不达标等。

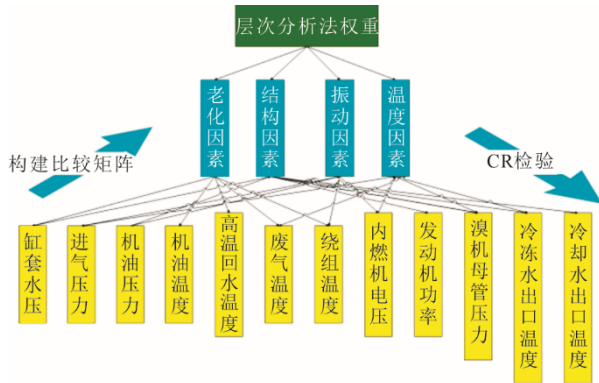


图1 基于故障类型 AHP 模型
Fig.1 AHP model based on fault type

通过各层元素两两对比构建判断矩阵，计算各层次比较矩阵中各元素的相对权重，对比较矩阵的一致性检验，计算系统的合成权重，然后计算各监测参数权重得分。通过 AHP 计算得到权重 W_1 为：

$$W_1 = \left[\begin{matrix} (w_{B_1})^T & (w_{B_2})^T \end{matrix} \right] (w_A)^T \quad (3)$$

$$= [\omega_1, \dots, \omega_j, \dots, \omega_{12}]^T$$

式中： w_A 为最大的特征值对应的特征向量标准化后权重向量； w_{B_1} 与 w_{B_2} 分别为矩阵 B_1 与 B_2 权重向量。

1.2 基于高斯混合分布权重计算

高斯混合模型 (Gaussian mixture model, GMM) 指多个高斯分布函数线性组合，理论上 GMM 可以拟合出任意类型的分布^[14-16]。利用高斯混合模型拟合出正态分布的数据分布，解决输入数据在同一集合的数据包含多个不同分布情况。模拟输入数据的频率分布直方图 (图 2)，根据直方图极值点的个数分为对应的高斯分量，对输入数据高斯分量采用最大期望 (expectation-maximization, EM) 算法进行计算^[17]。对数据进行高斯混合分布计算后的概率密度如图 3 所示。由图 3 可见，每一个高斯分量代表设备某一时段的运行状态。因为求解的各高斯分量不完全服从正态分布，所以利用箱线图法对各高斯分量进行异常值提取，箱线图法利用上下四分位数的计算，消除了各分量间的偏态与尾重，使得对异常值的提取更为精确。

通过对输入数据似然函数求导数得到似然方程，求解似然方程得到各高斯分量对应的期望与方差。将各高斯分量的并集作为该输入数据的上下限，对超出限值的部分增加权重 W_2 ，从而更为精准

地预测设备发生故障可能性。




图2 各高斯分量频率分布直方图
Fig.2 Histogram of frequency distribution of each Gaussian component




图3 输入数据高斯概率密度比较
Fig.3 Gaussian probability density comparison of input data

正态分布法则或 Z 分数方法是以假定数据服从高斯分布为前提，但实际上数据并不严格服从高斯分布。通过高斯混合模型拟合各高斯分量，通过提取上下四分位数 Q_3 与 Q_1 ，将上下四分位数据做差得到四分位距离 I_{QR} ，计算异常健康值阈值 Q_{max} 与 Q_{min} ：

$$\begin{cases} Q_{max} = Q_3 + 1.5 \times I_{QR} \\ Q_{min} = Q_1 - 1.5 \times I_{QR} \end{cases} \quad (4)$$

构建评价矩阵 $Q=(p_{ij})_{n \times m}$ ，其中， $x_s^{(n)}$ 、 $x_x^{(n)}$ 分别为第 n 个特征参数上、下阈值，对于超限数据赋予权重：

$$\omega_k = |p_{ij} - x_s^{(n)}(x_x^{(n)})| / (x_s^{(n)} - x_x^{(n)}) \quad (5)$$

最终，得到 GMM 计算出的权重向量 W_2 为：

$$W_2 = [\omega_1, \dots, \omega_j, \dots, \omega_k]^T \quad (6)$$

2 设备健康度预测模型

2.1 改进的麻雀搜索算法

麻雀搜索算法于 2020 年首次提出，是基于麻雀种群觅食和反捕食行为的一种新型智能优化算法^[18]。

本文首先根据麻雀搜索算法确定 LSTM 神经网络设备健康度预测模型超参数范围, 选取麻雀种群数量为 50。将种群中的麻雀分为发现者与捕食者, 其中发现者与捕食者的身份不固定, 种群中获得能量最高的一部分麻雀自动转为发现者。

萤火虫算法^[19]的原理是萤火虫会向比它更亮的另一只萤火虫移动, 萤火虫个体的亮度随着距离的增加而减少, 如果没有找到一个比给定的萤火虫更亮的个体, 则该萤火虫会随机移动。麻雀搜索算法具有较好的局部搜索能力, 可利用萤火虫算法对麻雀搜索算法寻优后的参数进行扰动, 增强麻雀搜索算法全局搜索能力, 以达到对未来健康度曲线更为快速精准的拟合。

2.2 LSTM 神经网络设备健康度预测模型

LSTM 神经网络基本单元包括输入门、遗忘门和输出门^[20]。本文将提取的特征向量 x_t 、状态记忆单元 c_{t-1} 以及中间输出 h_{t-1} 输入遗忘门, 从而决定状态记忆单元中需要遗忘的健康数据。输入 x_t 分别经过 sigmoid 和 tanh 激活函数后共同决定状态记忆单元中需要保留的向量。中间输出 h_t 由更新后的状态记忆单元 c_t 以及输出门 o_t 共同决定。具体计算公式为:

$$i_t = \sigma(x_t W_{xi} + h_{t-1} W_{hi} + b_i) \quad (7)$$

$$f_t = \sigma(x_t W_{xf} + h_{t-1} W_{hf} + b_f) \quad (8)$$

$$o_t = \sigma(x_t W_{xo} + h_{t-1} W_{ho} + b_o) \quad (9)$$

$$\tilde{c}_t = \tanh(x_t W_{xc} + h_{t-1} W_{hc} + b_c) \quad (10)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (11)$$

$$h_t = o_t \odot \tanh c_t \quad (12)$$

式中: i_t 、 f_t 、 \tilde{c}_t 分别为 t 时间的输入门、遗忘门及候选状态记忆单元; W_{xi} 、 W_{hi} 和 b_i 分别为输入门的权重和偏差; W_{xf} 、 W_{hf} 和 b_f 分别为遗忘门的权重和偏差; W_{xo} 、 W_{ho} 和 b_o 分别为输出门的权重和偏差; W_{xc} 、 W_{hc} 和 b_c 分别为候选状态记忆单元的权重和偏差; $\sigma(\cdot)$ 为 sigmoid 激活函数; \odot 表示按元素相乘^[20]。

对比不同神经元层数的模拟结果, 发现当神经元层数为多层时, 设备健康度预测模型结果更为精准。当神经元层数继续增加, 模型预测速度会明显下降, 综合考虑后选择双层神经元 LSTM 神经网络作为设备健康度预测模型。同时, LSTM 神经网络的学习率也会显著影响设备健康度预测模型的精度^[21], 故选择学习率和一、二层网络神经元数量作为待优化参数。LSTM 神经网络设备健康度预测模型通过将改进健康度数据导入并进行标准归一化,

将健康度数据切分为训练集和测试集, 通过组合预测模型不断迭代对 LSTM 神经网络超参数的自动寻优, 从而构建一种最佳设备健康度预测模型。

2.3 分布式能源设备改进健康度预测模型

以内燃机、溴化锂机组运行数据为例进行分析, 选取历史日数据作为 LSTM 神经网络输入, 通过测试发现: 构建的改进健康度神经网络预测模型中, 以学习率、迭代次数、神经元个数等超参数对预测结果的准确性影响较大。采用改进麻雀搜索算法对 LSTM 神经网络超参数 (学习率、训练次数、2 层 LSTM 层节点数) 进行选取, 以提高预测模型运行精度。图 4 为分布式能源系统 LSTM 神经网络设备健康度预测模型。

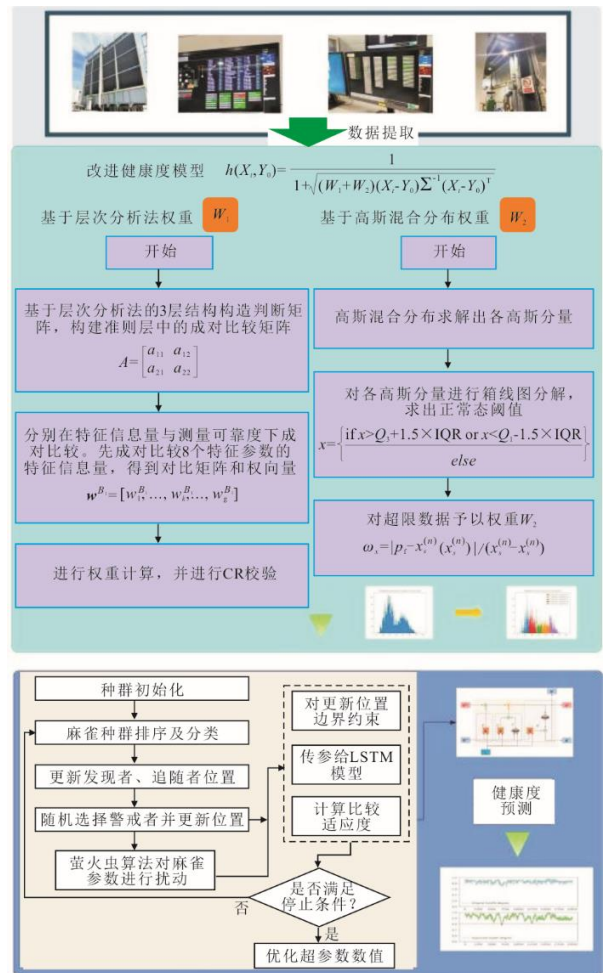


图 4 LSTM 神经网络设备健康度预测模型
Fig.4 Device health prediction model based on LSTM neural network

图 4 中设备健康度预测模型计算时首先进行数据预处理, 采用标准化和归一化方式处理数据, 归一化公式为:

$$x' = \frac{(x - x_{\min})}{(x_{\max} - x_{\min})} \quad (13)$$

式中： x_{\min} 、 x_{\max} 分别为数据 x 中最小和最大值。

然后建立初始麻雀种群数量，选取 20% 种群数量作为优化参数的发现者。根据初始条件确定选取优化超参数上下边界。其中初始化参数包括 LSTM 神经网络学习率、训练次数、第 1 层隐含节点数与第 2 层隐含节点数。将初始化麻雀位置根据适应度函数进行评估，并对麻雀位置进行排序，随机选取 10%~20% 的麻雀进行侦察预警机制动作。

接着通过发现者、追随者以及预警条件公式更新麻雀位置，以边界函数约束超参数并对 LSTM 神经网络超参数进行预测，返回结果通过适应度函数进行位置评估。若当前麻雀位置适应度优于历史最佳位置适应度，则当前麻雀位置代替历史最佳位

置，否则不变^[21]。

利用萤火虫扰动算法对麻雀搜索算法参数进行扰动，将麻雀搜索算法中麻雀利用萤火虫扰动算法进行位置更新，更新后将扰动后的 LSTM 神经网络参数进行传参预测。将扰动后的麻雀与扰动前的麻雀进行对比，如果扰动后麻雀位置更优则更新麻雀位置，迭代达到算法设定的迭代次数，最后将全局最优超参数设为 LSTM 神经网络模型的参数。

3 系统分析及实例验证

3.1 分布式能源系统

上海某分布式能源系统选用 3 台 4 400 kW 燃气内燃发电机组配套 3 台制冷量 4 152 kW 和制热量 4 310 kW 的烟气热水溴化锂机组，三联供效率可达 81.24%。本文以 1 台燃气内燃机和 1 台溴化锂机组为例进行分析，该系统结构如图 5 所示。




图 5 燃气内燃机+溴化锂机组系统结构

Fig.5 System structure of the gas engine + lithium bromide unit

内燃机工作原理是利用燃料在气缸内燃烧产生热能，从而使气体受热膨胀推动活塞移动。其中散热部分由中冷水和高冷水 2 部分组成，中冷水通过内燃机中冷水泵进入内燃机组混合气（燃气和空气）冷却，然后流出，中冷水温度小于 45℃，可直接经过三通阀进入内燃发电机组，这样不停循环；内燃机高冷水则通过高冷水泵进入内燃机冷却润滑油、缸套水、混合气，然后流出，高冷水的温度大于 75℃，可通过三通阀进入溴化锂机组给溴化锂稀溶液预热。

燃烧产生的烟气以及高冷水余热作为驱动热源，利用溴化锂溶液特性以及水作为制冷剂实现溴化锂冷热水机组制冷和制热。吸收器内的溴化锂稀溶液通过吸收器经溶液泵进入换热器，通过内燃发

电机热源加热，将稀溶液蒸发为冷剂蒸汽，稀溶液变为浓溶液，通过溶液喷淋泵喷射在吸收器换热管外，换热管内通入冷却水，使溴化锂溶液温度降低，提高稀释效果。冷剂蒸汽经冷凝器通过冷却水冷凝成液态制冷剂，液态制冷剂通过蒸发器吸收冷却水的热量并蒸发重新进入吸收器，完成循环，系统的输出为发电量、制冷量与制热量^[22]。

3.2 设备健康度运行结果及分析

该分布式能源系统已安全运行 6 年，设备运行老化情况不容忽视。该系统存在的问题有设备老化导致散热能力变差、冷却水温度过高及散热系统噪声过高等，对此通过经验及机理分析以及 GE 公司 JS858-CN 热电联产发电机组及配套 CN61277601-EJ60D 溴化锂机的维护及产品手册，选取相应监测

数据进行问题分析及健康度诊断。

内燃机绕组温度达到最大值会加速设备老化，影响设备正常运行，并对整个机组运行造成安全隐患^[23]。温度达到最大值与发动机过载、不平衡负载、探针损坏、环境温度过高、极限值设置错误等因素有关。通过监测内燃机电压、电流、频率及励磁电压可以对绕组温度进行相关预警。

发电机剧烈震动指在发电机功率改变较小的情况下，负荷快速波动或电流和电压波动较大。造成该现象的因素可能是燃烧用空气比例不正常、火花塞安装区域内有水和湿气、燃气压力波动等。

溴化锂机冷冻水供应温度过高可能与燃气量上下波动、混合气温度快速波动、调节参数设置不理想以及冷却塔散热不充分有关。

根据经验和设备参考手册，并通过对设备进行相关机理分析，选取故障参数计算相应权值^[24]，具体特征参数见表 1。通过监测该参数，构建改进设备健康度模型，根据机理分析及设备参数手册得出各分量相关权重。

表 1 特征参数
Tab.1 characteristic parameter

名称	权值
溴机母管压力 p_m	0.095 2
冷却水出口温度 T_c	0.089 9
冷冻水出口温度 T_f	0.075 3
内燃机电压 V	0.103 3
高温回水温度 T_h	0.119 1
废气温度 T_w	0.061 8
缸套水压 p_c	0.124 9
机油温度 T_e	0.010 5
发动机功率 P	0.082 4
绕组温度 T_c	0.125 3
进气压力 p_a	0.081 1
机油压力 p_o	0.106 4

设备输入数据概率密度如图 6 所示，通过高斯混合分布求出对应高斯分量以及各高斯分量上四分位、均值和下四分位，同时利用箱线原理求出各分量异常值，结果如图 7 所示。规定正常运行限值为 $(\mu-1.96\sigma, \mu+1.96\sigma)$ ，对超出限值的数据赋予权重。

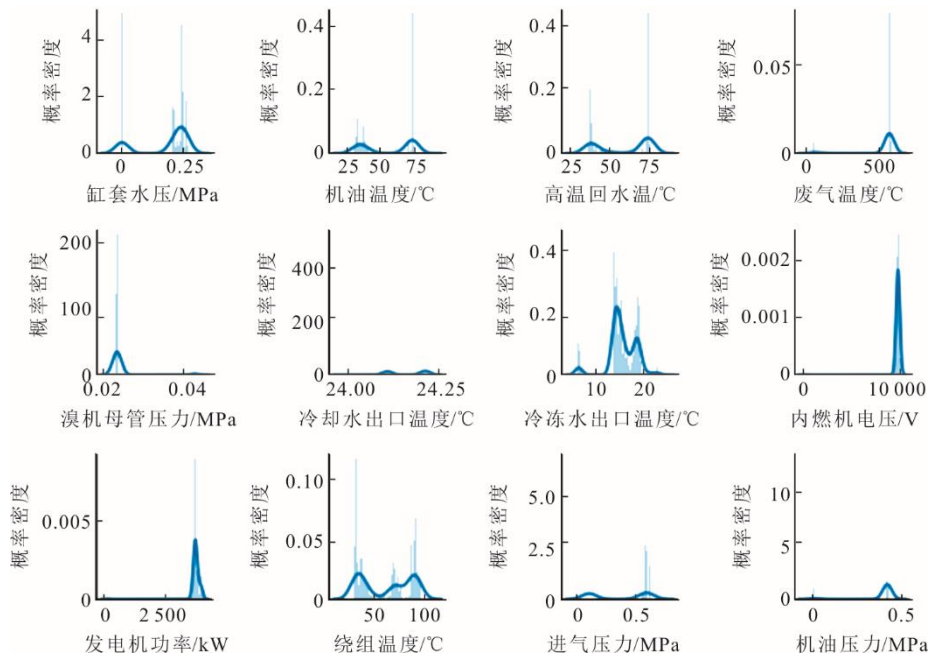


图 6 设备输入数据概率密度
Fig.6 Probability density map of device input data

本文设备健康度模型采用改进原始健康度指标、基于 AHP 得出的故障权重以及经高斯混合分布得出故障权重，使得设备健康度指标更加准确，同时该模型还能够监测到普通马氏距离健康度下无法监测的影响设备健康状态及加速损坏的状态点，使得健康度更加贴近实际运行状态。设备原始

健康度值与改进健康度数据对比如图 8 所示。图 8 中，设备原始健康度为仅通过马氏距离构建的健康度，改进健康度为通过添加 AHP 与高斯混合分布后的健康度。

由图 8 可见，对于出现机组过热现象时间点，改进健康度能够发现此时设备运行中的异常点，经

过查证, 该异常状态点为溴化锂机组散热受到影响, 导致机组过热以及冷冻水温度过高。而原始健康度并未有效识别该异常状态。这充分说明多参数

综合预警模型能较好地跟踪系统运行状态, 也体现了基于 AHP 和高斯混合分布预警阈值在变工况运行条件下具有较好的预测能力。

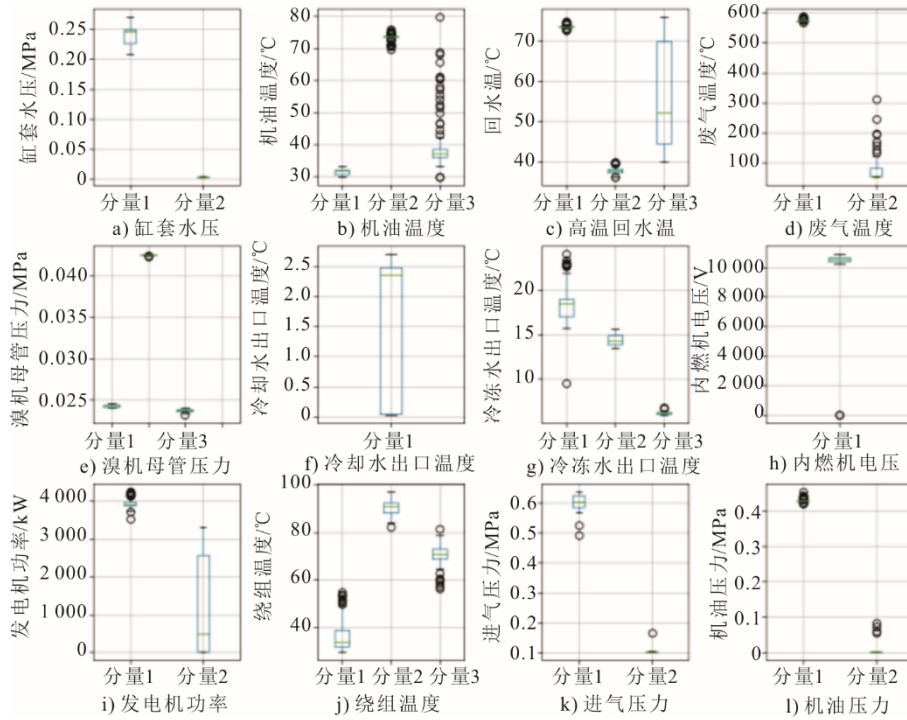


图 7 输入异常数据箱线图

Fig.7 Box diagram of input abnormal data




图 8 设备健康度数据对比

Fig.8 Comparison of device health data

3.3 SSA-LSTM 神经网络预测结果及分析

选择分布式能源电站辅机设备作为验证对象, 选取 2022 年 3 月运行数据进行实例验证, 采样周期为 60 s, 每 12 个历史数据预测未来 1 个数据。将前 80% 数据作为训练集, 后 20% 数据作为测试集, 建立基于 SSA-LSTM 电厂关键辅机健康度预测模

型, 将该模型预测的结果与其他神经网络模型结果进行比较。

为了更好地评价预测模型的精度, 设备健康度预测模型评价指标以拟合优度 R^2 和平均绝对误差作为实验的性能指标^[25]。设 y 为待拟合数值, 其均值为 \bar{y} , 拟合值为 y , 即:

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (14)$$

表 2 为各模型预测结果比较, 图 9 为设备健康度预测算法对比。由表 2 可见, 改进 SSA-LSTM 神经网络模型的拟合优度最大且平均绝对误差最小, 说明其效果最好。

表 2 各模型预测结果对比

Tab.2 Comparison of each model prediction results

模型	拟合优度 R_2	平均绝对误差
CNN-LSTM	0.887 3	0.357 06
SSA-GRU	0.947 2	0.018 51
PSO-LSTM	0.963 8	0.008 96
SSA-LSTM	0.983 5	0.007 09

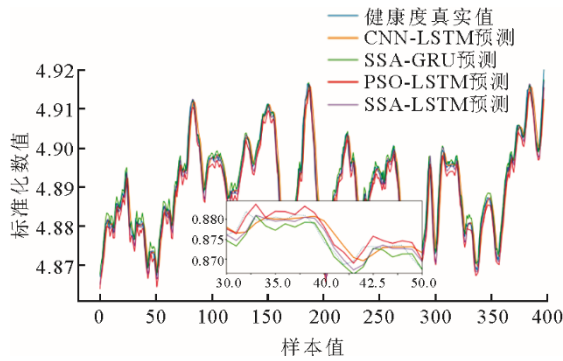


图9 设备健康度预测算法对比

Fig.9 Comparison of device health prediction algorithms

由图9可见,本文改进SSA-LSTM模型与真实值最为接近。比较该模型的拟合优度及平均绝对误差可以发现,改进SSA-LSTM模型拟合效果良好,能够更好地对设备健康程度和老化趋势做出预测。综合以上实验结果可知,相较于其他改进优化算法,本文改进SSA-LSTM模型对设备健康度预测精度有明显提升。

4 结 语

本文以分布式能源站内燃机组为例,在不影响正常运行情况下,通过改进马氏距离,利用AHP与高斯混合分布使健康度指标反映设备运行状态,同时建立了改进SSA-LSTM设备健康度预测模型。

AHP能对设备参数进行危险分层,高斯混合分布能更好地识别设备异常状态,结合2种方法构造的基于改进马氏距离设备健康度模型,能在故障数据缺乏的情况下对设备的安全状态进行监视,能更好指导运维人员进行维护,实现减缓设备老化、节约经济成本的目的。

与其他神经网络模型对比,本文构建的改进SSA-LSTM预测模型,对设备未来健康程度及老化分析的预测更精准,可为设备安全运行及状态检修提供很好的参考。

[参考文献]

[1] 卞韶帅,朱懿灏,刘峻,等.基于大数据挖掘的发电设备状态监测与故障诊断系统的开发与应用[J].电力与能源,2020,41(5):571-574.
BIAN Shaoshuai, ZHU Yihao, LIU Jun, et al. Development and application of power generation equipment condition monitoring and fault diagnosis system based on big data mining[J]. Power & Energy, 2020, 41(5): 571-574.

[2] 刘爱国,张健赞,赵树成,等.我国煤电机组延寿及其经济性研究[J].热力发电,2022,51(7):54-60.
LIU Aiguo, ZHANG Jianyun, ZHAO Shucheng, et al.

Life extension study and economic analysis of coal-fired power units in China[J]. Thermal Power Generation, 2022, 51(7): 54-60.

[3] 杨艳芳,邢亚辉,舒亮,等.基于孪生数据的设备健康度评估方法研究[J].华中科技大学学报(自然科学版),2022,50(6):97-103.
YANG Yanfang, XING Yahui, SHU Liang, et al. Research on equipment health assessment method based on twin data[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2022, 50(6): 97-103.

[4] 白秀春.基于核电站关键设备的状态预警及健康度的研究[D].上海:上海电力大学,2021:1.
BAI Xiuchun. Research on condition warning and health of key equipment in nuclear power plant[D]. Shanghai: Shanghai University of Electric Power, 2021: 1.

[5] 翟立伟,王东辉.基于音频处理技术的轴承劣化预警方法研究[J].仪表技术,2022(3):42-44.
ZHAI Liwei, WANG Donghui. Research on early warning method for bearing deterioration based on audio processing technology[J]. Instrumentation Technology, 2022(3): 42-44.

[6] 杨春波,陶青,张健,等.基于综合健康指数的设备状态评估[J].电力系统保护与控制,2019,47(10):104-109.
YANG Chunbo, TAO Qing, ZHANG Jian, et al. Equipment status evaluation based on comprehensive health index[J]. Power System Protection and Control, 2019, 47(10): 104-109.

[7] KOUBLI E, PALMER D, BETTS T, et al. Inference of missing PV monitoring data using neural networks[C]// 2017 IEEE 44th Photovoltaic Specialists Conference (PVSC). IEEE, 2017.

[8] 刘帅,刘长良,甄成刚,等.基于群体多维相似性的风机齿轮箱预警策略[J].仪器仪表学报,2018,39(1):180-189.
LIU Shuai, LIU Changliang, ZHEN Chenggang, et al. Fault warning strategy of wind turbines gearbox based on group multi-dimensional similarity[J]. Chinese Journal of Scientific Instrument, 2018, 39(1): 180-189.

[9] BING W, WANG S L, LI L. Fuzzy comprehensive evaluation of district heating systems[J]. Energy Policy, 2010, 38(10): 5947-5955.

[10] HUANG C G, YIN X, Huang H Z, et al. An enhanced deep learning-based fusion prognostic method for RUL prediction[J]. IEEE Transactions on Reliability, 2019, 69(3): 1097-1109.

[11] 钱虹,王建棋,徐邦智,等.基于数据驱动建模的核电站一回路管道劣化趋势研究[J].热力发电,2022,51(6):82-88.
QIAN Hong, WANG Jianqi, XU Bangzhi, et al. Research on deterioration trend of primary pipeline in nuclear power plant based on data-driven modeling[J]. Thermal Power Generation, 2022, 51(6): 82-88.

[12] 陈朋永.基于层次分析的GIS运行状态模糊综合评估研究[D].保定:华北电力大学,2013:1.
CHEN Pengyong. Gas insulated switchgear running state comprehensive evaluation based on analytic hierararchy process of fuzzy theory[D]. Baoding: North China Electric Power University, 2013: 1.

[13] 张佳新.入库径流过程预报误差随机模拟模型及应用研究[D].北京:华北电力大学,2021:1.
ZHANG Jiixin. Study on the stochastic simulation model and application of forecast errors in the process of inbound

- runoff[D]. Beijing: North China Electric Power University, 2021: 1.
- [13] BANDINI P A C, PADGETT J E, PAULTRE P, et al. Seismic fragility of bridges: an approach coupling multiple-stripe analysis and Gaussian mixture for multicomponent structures[J]. Earthquake Spectra, 2021, 38(1): 1-29.
- [14] YANG B Y, LIU R N, ZIO E. Remaining useful life prediction based on a double-convolutional neural network architecture[J]. IEEE Transactions on Industrial Electronics, 2019, 66(12): 9521-9530.
- [15] YE L, CHEN Y. Research on initialization on EM algorithm based on Gaussian mixture model[J]. Journal of Applied Mathematics and Physics, 2018, 6(1): 11-17.
- [16] MAJUMDER S. A Gaussian mixture model method for eigenvalue-based spectrum sensing with uncalibrated multiple antennas[J]. Signal Processing, 2022, 192: 108404.
- [17] WEI H, ZHENG W. Image denoising based on improved Gaussian mixture model[J]. Scientific Programming, 2021, 21(8): 451-458.
- [18] 郭玄, 朱凯. 基于 SSA-LSTM 的锂离子电池寿命预测[J]. 电池工业, 2021, 25(3): 131-135.
GUO Xuan, ZHU Kai. Life prediction of lithium-ion battery based on SSA-LSTM[J]. Chinese Battery Industry, 2021, 25(3): 131-135.
- [19] UKASIK S, AK S. Firefly algorithm for continuous constrained optimization tasks[C]//International Conference on Computational Collective Intelligence. Springer, Berlin, Heidelberg, 2009.
- [20] 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.
- [21] 魏鹏飞, 樊小朝, 史瑞静, 等. 基于改进麻雀搜索算法优化支持向量机的短期光伏发电功率预测[J]. 热力发电, 2021, 50(12): 74-79.
WEI Pengfei, FAN Xiaochao, SHI Ruijing, et al. Short-term photovoltaic power generation forecast based on improved sparrow search algorithm optimized support vector machine[J]. Thermal Power Generation, 2021, 50(12): 74-79.
- [22] 于会群, 沈昱, 邱亚鸣, 等. 基于 PSO-DW-DAC 的燃气内燃机溴化锂热电联供系统模型辨识[J]. 热力发电, 2019, 48(12): 38-45.
YU Huiqun, SHEN Yu, QIU Yaming, et al. Model identification of gas internal combustion engine lithium bromide heating-power supply system based on PSO-DW-DAC[J]. Thermal Power Generation, 2019, 48(12): 38-45.
- [23] 葛双瑞. 基于 PHM 的风电机组功率及健康状态预测研究[D]. 沈阳: 沈阳工业大学, 2021: 1.
GE Shuangrui. Research on power and health state prediction of wind turbines based on PHM[D]. Shenyang: Shenyang University of Technology, 2021: 1.
- [24] 李沛峰, 杨勇平, 戈志华, 等. 300 MW 热电联产供热系统分析与能耗计算[J]. 中国电机工程学报, 2012, 32(23): 15-20.
LI Peifeng, YANG Yongping, GE Zhihua, et al. Analysis and calculation on energy consumption of 300 MW CHP heating systems[J]. Proceedings of the CSEE, 2012, 32(23): 15-20.
- [25] 余小兵, 杨利, 居文平, 等. 内燃机余热回收冷热电联供系统性能研究[J]. 热力发电, 2022, 51(2): 49-55.
YU Xiaobing, YANG Li, JU Wenping, et al. Performance analysis on a combined cooling, heating and power system for waste heat recovery of internal combustion engine[J]. Thermal Power Generation, 2022, 51(2): 49-55.

(责任编辑 杜亚勤)

广告目次

《热力发电》.....	封三
海阳市谊合建筑机械有限公司.....	后彩插 1
西安热工研究院有限公司.....	后彩插 2—6
《热力发电》订阅宣传页.....	后彩插 7
上海凯泉泵业(集团)有限公司.....	后彩插 8