

高抗机械健康状态不确定性量化混合预测模型*

赵子强¹, 张孝远¹, 邵锐¹, 汤会增²

(1. 河南工业大学电气工程学院 郑州, 450001)

(2. 国网河南省电力公司直流中心 郑州, 450048)

摘要 为实现特高压并联电抗器(高抗)机械异常的早期预警,首先,基于高抗内部结构和振动机理设计了振动在线监测系统,从振动信号中提取并优选了与高抗内部机械状态高度关联的特征,构建了高抗机械健康指数;其次,充分考虑高抗的多变工况及复杂运行环境,提出一种高抗机械健康状态混合预测模型,采用卷积神经网络挖掘高抗健康状态特征形成特征向量,输入到双向门控循环单元网络进行训练;然后,引入自注意力机制突出健康状态特征的重要信息,并采用分位数回归实现健康状态趋势的不确定性量化预测;最后,将所提方法应用于某 1 000 kV 高抗机械健康状态预测。结果表明:相比于高斯过程回归及其他方法,所提方法取得了最小的平均预测区间带宽、平均预测区间中心偏差值和最大的平均预测区间分数,能够提早预警高抗可能出现的机械异常。

关键词 特高压并联电抗器;机械健康状态;不确定性量化;健康指数;混合预测模型

中图分类号 TH165; TM472

引言

特高压并联电抗器在电网中发挥着补偿输电线路容性无功、降低有功损耗、抑制过电压及优化电压分布等重要作用^[1-2],但因高抗内部特殊结构,其振动强度较大。长期过量振动可能导致铁心松动、屏蔽帽断裂等机械故障,对设备的运行健康状态、周围环境及电网安全稳定运行产生严重影响。因此,对高抗机械健康状态进行评估和预测,提前预警可能发生的机械故障,对保障特高压电网安全稳定运行具有重要意义。

传统的高抗故障检测常采用超声波局放检测和油色谱分析方法^[3],但都难以检测其早期机械故障。不少学者针对高抗机械振动问题开展了研究,主要集中在高抗振动机理分析方面。张鹏宁等^[4]建立了磁-机械场耦合模型,仿真分析了高抗铁心振动特性分布规律。郭佳熠等^[5]仿真研究了气隙结构对高抗铁心振动的影响规律。文献[6-7]指出,高抗振动由铁心硅钢叠片的磁致伸缩效应、铁心饼与气隙交界处的麦克斯韦及绕组受力引起。由于高抗运行时内部环境较为复杂,仿真分析方法很难精准模拟实际运行状态。同时,天气及电磁环境因素也可能对高抗运行产生影响,使得基于机理分析的方法无法完

全满足现场运行安全保障的需求。

作为大型充油设备,高抗内部的机械振动会通过油箱中的油及固体部件传播到油箱表面,当内部结构件发生机械故障时会导致箱体局部产生相应的振动频率分量。油箱表面的振动信号包含其内部机械健康状态的丰富信息^[8],为此,一些学者开展了基于高抗实测振动信号分析的故障诊断研究。吴金利等^[9]通过研究高抗表面振动信号的时域和频域分布特性,综合多种机器学习方法实现高抗机械故障诊断。Hou等^[10]采用先进信号分解方法提取高抗振动信号特征,并利用改进概率神经网络诊断高抗机械故障的种类和程度。上述方法本质上解决了一类模式识别问题,足量的故障样本是其成功的关键,但现场故障样本的获取往往十分困难,而现场运维人员迫切需要依据大量健康运行数据来评估设备实时运行健康状态及其发展趋势^[11]。朱明等^[12]基于高抗表面振动信号的频谱叠加特征,搭建了高抗健康评估模型,得到了与油色谱检测法和超声波局放法一致的健康评估结果,但是该研究并未对高抗的健康状态进行预测,且不加区分地将所有观测位置的振动信号的频谱叠加起来会引入冗余影响,增加了计算量。高树国等^[8]构建了高抗的门控循环神经网络(gated recurrent unit, 简称 GRU)声振预测模型,可

* 河南省自然科学基金资助项目(232300421207);河南工业大学自科创新基金计划资助项目(2022ZKCJ04)

收稿日期:2024-02-20;修回日期:2024-10-08

有效识别高抗油箱内部的潜在缺陷和突发状况,但没有构建起高抗机械健康状态的健康指数(health index, 简称 HI),因此在机械健康状态的综合量化评估和预测方面尚存在不足。此外,高抗在实际运行中受多变工况及复杂运行环境的影响,其振动存在随机性、模糊性等不确定性^[13]。上述研究所采用的点预测方法,仅仅给出未来时刻的一个确定预测值,无法反映健康状态的不确定性。因此,有必要针对高抗机械健康状态指数的构建及健康趋势的不确定性预测开展进一步研究。

笔者提出一种基于振动信号分析的高抗机械健康状态不确定量化混合预测模型。首先,充分考虑高抗内部振动机理,设计了振动状态监测系统;其次,基于振动信号分析,利用经过极端提升树算法(extreme gradient boosting, 简称 XGBoost)筛选的与高抗内部机械健康状态高度相关的特征构建了 HI;然后,在获取的历史 HI 曲线上,利用卷积神经网络(convolutional neural network, 简称 CNN)的空间特征提取能力、双向门控循环单元(bi-gated recurrent unit, 简称 BiGRU)对 HI 数据长期依赖关系的双向捕捉能力和自注意力机制(self-attention mechanism, 简称 SAM)对特征重要信息的突出关注,来预测高抗未来的机械健康状态,并采用分位数回归(quantile regression, 简称 QR)模型输出其不确定性,所提模型简称为 QR-SAM-CNN-BiGRU;最后,将所提模型应用于我国某特高压变电站的高抗实际运行中,通过对比实验验证了其有效性。

1 高抗机械健康指数构建

1.1 高抗内部结构和振动机理分析

本研究分析的高抗型号为 BKDF-240000/1000,采用自然油循环强迫风冷冷却方式,其具体参数见表 1。1 000 kV 高压套管采用 GOE2600 型套管。高抗内部结构示意图如图 2 所示,主要包括铁轭、绕组、铁轭压紧系统和气隙等结构。其中,绕组材料为铜,铁轭材料为硅钢,气隙材料为大理石,铁心与箱壁之间为变压器油。该高抗于 2008 年 6 月出厂,2009 年 1 月 6 日投运,为我国首台套投运的特高压并联电抗器,其机械健康状态趋向老化,迫切需要评估其机械健康状态并进行适时维护。

研究表明,特高压并联电抗器的振动主要由其内部铁心受到的麦克斯韦力和磁致伸缩引起^[14]。因为高抗的工作磁通密度较低,一般磁致伸缩力远小

表 1 高抗具体参数表

Tab.1 Specific parameters of UHV shunt reactor

参数	数值
额定容量/Mvar	240
额定电压/kV	635.1
额定电流/A	377.9




图 1 高抗内部结构示意图

Fig.1 Schematic diagram of the internal structure of ultra-high voltage shunt reactor

于麦克斯韦力引起的振动,所以高抗振动主因是麦克斯韦力。麦克斯韦力是铁心饼与气隙界面处的一种面应力,其可以通过麦克斯韦应力张量积分^[15]进行计算,即

$$F_{\max} = \int_s T_{\max} dS = \int_s \left[BH - \frac{1}{2} \mu^2 H^2 I \right] dS \quad (1)$$

其中: T_{\max} 为麦克斯韦应力张量; B 为界面处的电磁感应强度矩阵; H 为磁场强度矩阵; μ 为磁导率矩阵; I 为单位矩阵;积分面为铁心饼与气隙的交界面。

由于在一个工频激励周期中铁心内主磁通变化 2 次方向,故磁致伸缩力和麦克斯韦力的主频率均为 100 Hz,因此高抗振动主要以 100 Hz 为基频,其他振动成分也以 100 Hz 的整数倍分布。因为高抗特殊的内部结构,从油箱表面监测到的振动信号受电磁、结构及油等耦合影响。铁心振动主要通过 2 条途径传至油箱表面:①振动产生后经固体连接结构传递到油箱外壳,属于固固耦合;②通过固液耦合传递至绝缘油,然后从绝缘油经液固耦合传递至油箱外壳^[6]。

1.2 高抗振动在线监测系统

高抗振动在线监测系统如图 2 所示。该系统采用小型化、模块化及分体式结构设计,主要由信号线、通讯线、振动加速度传感器、现地柜体及云端服务器等组成。振动加速度传感器直接通过强力胶水或螺纹固定在高抗外壳,灵敏度为 100 mV/g,具备 12 位分辨率以及 100 kS/s 的采样率,采集数据通过 4G 无线网络传输至云端。笔者提出的 HI 构建、机械健康状态预测等应用布置在云端服务器。

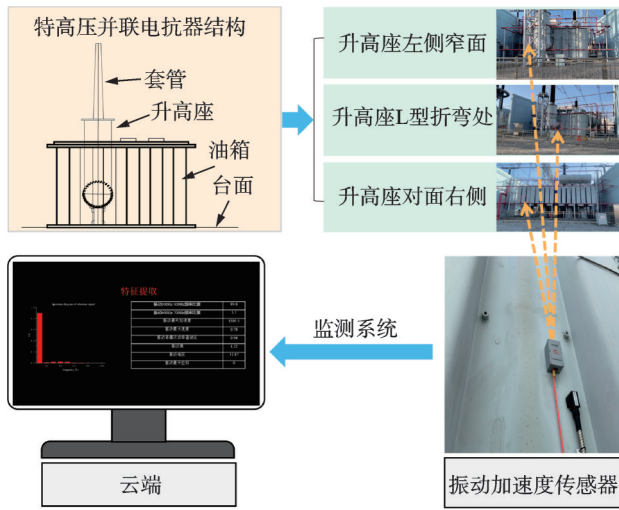


图2 高抗振动在线监测系统

Fig.2 Vibration online monitoring system for ultra-high voltage shunt reactors

为更好地感知高抗内部的机械振动情况,需要精心选择加速度传感器在油箱表面的固定位置。结合高抗振动机理及其传播路径分析,经现场反复测试,最终安装了3个振动加速度传感器。第1个传感器安装在最接近高抗铁心位置的升高座L型折弯处;另外2个传感器分别安装在升高座左侧窄面和升高座对面右侧位置。

1.3 振动信号特征分析

当高抗出现内部结构件及自身铁芯绕组松动等机械异常时会加剧铁芯振动,导致整体振动形态发生变化。高抗异常振动通常与基频100 Hz及其倍频耦合,以基频的倍频出现。根据高抗振动特性和以往的振动测量经验,其振动频率一般不超过2 kHz^[8]。因此,本研究首先提取振动100~300 Hz频率比重(F_1)、400~700 Hz频率比重(F_2)、800~2 000 Hz频率比重(F_3),其计算式为

$$F_1 = \sum_{i=1}^3 a_{100i}^2 / \sum_{i=1}^{20} a_{100i}^2 \quad (2)$$

$$F_2 = \sum_{i=4}^7 a_{100i}^2 / \sum_{i=1}^{20} a_{100i}^2 \quad (3)$$

$$F_3 = \sum_{i=8}^{20} a_{100i}^2 / \sum_{i=1}^{20} a_{100i}^2 \quad (4)$$

其中: a 为各频率分量的幅值; a^2 为某频率分量的能量。

为揭示高抗振动频率分布的变化,本研究计算了振动熵特征(F_4),即

$$F_4 = \left| \sum_{i=1}^{20} p_{100i} \log_2 p_{100i} \right| \quad (5)$$

其中: p_{100i} 为各频率分量占2 000 Hz内所有频率分量的比重。

振动熵反映了振动各频段的分布紊乱情况,其值越低,频率分布越集中;反之频率分布越紊乱。

此外,还保留了传感器直接测得的振动最大加速度(F_5)、振动最大速度(F_6)、振动最大位移(F_7)及振动电压(F_8)。研究表明,直流偏磁下磁致伸缩特性会发生改变,导致铁心振动加剧^[16]。因此,为避免高抗出现直流偏磁以及系统结构被强电磁干扰,还分析了奇次功率(F_9)、偶次功率(F_{10})、振动总功率(F_{11})、振动奇偶次功率谐波比(F_{12})和50 Hz频率比重(F_{13})等特征,其定义分别为

$$F_9 = \sum_{i=1}^{20} a_{100i-50}^2 / L \quad (6)$$

$$F_{10} = \sum_{i=1}^{20} a_{100i}^2 / L \quad (7)$$

$$F_{11} = F_9 + F_{10} \quad (8)$$

$$F_{12} = \sum_{i=1}^{20} a_{100i-50}^2 / \sum_{i=1}^{20} a_{100i}^2 \quad (9)$$

$$F_{13} = a_{50}^2 / \sum_{i=1}^{20} a_{100i}^2 \quad (10)$$

其中: L 为采样频率。

1.4 健康指数构建

为进一步揭示能够表达高抗内部机械健康状态的本征特征,采用XGBoost模型^[17]对上述13个特征进行特征重要性排序。XGBoost算法原理如下:在每个决策树中,通过衡量每个属性分割点改进性能度量的量来确定属性的重要性。对于每个决策树的节点,属性的重要性由其对应分割点的改进量进行加权,并记录其出现次数^[18]。如果一个属性对分割点改进性能度量越大,则其权重越大,即越重要。对于每个属性,在所有提升树中对其结果进行加权求和并平均,最终得到该属性的重要性得分,即Fscore,其计算式为

$$Fscore = |M| \quad (11)$$

其中: M 为所有特征分类到节点的集合。

应用1.1节所述的1 000 kV高抗历史监测数据,对各特征的重要性得分进行可视化分析。特征重要性排序如图3所示。由图可见,振动400~700 Hz比重和振动100~300 Hz比重特征变量的重要性得分远高于其他变量,这2个特征的重要性得分占比之和为80.07,超过了80%。文献[19]采用随机森林方法对特征重要性进行排序,并选择了

Fscore之和大于80%的特征作为最终特征。本研究借鉴这一结论,选择 F_1 、 F_2 构建高抗机械HI,即

$$h = \frac{f_1}{f_1 + f_2} a + \frac{f_2}{f_1 + f_2} b \quad (12)$$

其中: f_1 为振动400~700 Hz的Fscore; f_2 为振动100~300 Hz的Fscore; a 为高抗振动400~700 Hz监测值; b 为高抗振动100~300 Hz监测值。

为说明所构建HI的合理性,采用某段包含1次现场记录机械异常的监测数据进行HI计算。高抗历史健康指数曲线示例如图4所示。由图可见,HI波动剧烈,存在较大的不确定性。图中红色标注的点对应于现场监测的异常报警,虚线为采用3倍方差的统计准则所制定的阈值,其可以检测出该异常,验证了所提HI反映高抗内部机械健康状态的有效性。




图3 特征重要性排序

Fig.3 The ranking of feature importance




图4 高抗历史健康指数曲线示例

Fig.4 An example of a historical HI curve for the ultra-high voltage shunt reactor

2 高抗机械健康状态预测模型

2.1 模型总体架构

笔者提出一种基于QR-SAM-CNN-BiGRU的高抗健康状态混合预测模型,该模型包含输入层、CNN层、BiGRU层、SAM层和QR输出层,其结构如图5所示。模型充分利用了CNN、BiGRU及SAM的各自优势。其中,CNN模型的卷积层和池化层可隐性挖掘出高抗机械HI数据的空间特征;BiGRU网络所拥有的双向循环结构会对上一时刻

的输出有选择地保留并与当前时刻数据融合,能更好地捕捉HI序列的时间依赖关系;SAM进一步为BiGRU的隐藏层输出分配权重,通过挖掘全部时间序列中每一时刻信息的重要度,减少高抗历史机械HI数据的丢失,进一步提升模型预测性能;最后,采用QR实现健康状态的不确定性量化预测。

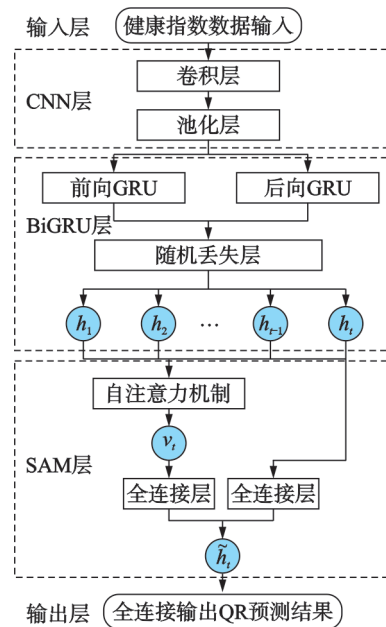


图5 QR-SAM-CNN-BiGRU结构图

Fig.5 Structure diagram of QR-SAM-CNN-BiGRU

2.2 BiGRU

BiGRU是对GRU的改进,其输出受时间序列前向状态和后向状态的共同影响,能够有效兼顾高抗机械健康状态的历史与未来对当前时刻的影响,更有利于提取高抗机械健康状态数据深层特征。BiGRU结构如图6所示。其中: x_t, x_{t-1}, x_{t+1} 为输入; h_t, h_{t-1}, h_{t+1} 为反向GRU共同作用的隐藏状态。




图6 BiGRU结构图

Fig.6 Structure diagram of BiGRU

BiGRU网络具体计算公式为

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \quad (13)$$

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t+1}) \quad (14)$$

$$h_t = W_t \vec{h}_t + U_t \overleftarrow{h}_t + b_t \quad (15)$$

其中: $\vec{h}_t, \overleftarrow{h}_t$ 分别表示 t 时刻正、反向输出的隐藏层状态; h_t 表示网络输出的隐藏层状态; W_t, U_t 为对应的输出权重; b_t 为偏置向量。

2.3 SAM

SAM^[20]作为一种资源分配机制,可挖掘历史HI序列节点与预测节点之间的关联性,从而影响权重,突出健康状态趋势的关键影响因子,避免长时间的HI序列上的信息丢失^[21]。SAM的数学表达式为

$$\begin{cases} Q = XW_q \\ K = XW_k \\ V = XW_v \\ A_{\text{attention}}(X) = \text{softmax}\left(\frac{QK^T}{\sqrt{D_k}}\right)V \end{cases} \quad (16)$$

其中: X, Q, K 和 V 分别为输入向量、查询向量、键向量和值向量; W_q, W_k 和 W_v 为对应权重; $\sqrt{D_k}$ 为确保训练过程稳定的缩放因子; softmax 为激活函数。

2.4 分位数回归模型

QR^[22]把传统的均值回归推广到分位数回归,其不需要假设残差满足正态分布、随机独立及方差齐同等条件,因此更加灵活和稳健。同时,QR可用于研究解释变量和响应变量条件分位数之间的关系,描述响应变量的全局特征。本研究将SAM-CNN-BiGRU模型的输出经全连接层与线性QR结合,实现高抗健康状态预测的不确定性量化。线性QR回归模型可表示为

$$Q_{P_i}(\tau|x_i) = \beta(\tau)x_i \quad (i=1, 2, \dots, n) \quad (17)$$

其中: x_i 为第 i 个自变量; P_i 为第 i 个因变量; $Q_{P_i}(\tau|x_i)$ 为 P_i 在 x_i 下的第 τ 个分位数; $0 < \tau < 1$; $\beta(\tau)$ 为回归系数向量。

3 应用实例

3.1 实验设置

为验证所提方法的有效性,选取1 000 kV高抗在2021年12月21日监测数据中的一段来进行实验,该段数据共有2 084个采样点。实验所用计算平台为Windows11操作系统,CPU型号为Intel i5-1155G7,处理器主频为2.50 GHz,内存容量为

16 G,采用Python 3.9.12软件,基于Pytorch深度学习框架进行模型训练,Pytorch版本为1.11.0。数据按照9:1划分训练集与测试集。训练过程采用Adam自适应优化器,学习率为0.000 5,Epochs训练次数为500。CNN层中激活函数为ReLU,QR取95%分位数。所提模型结构参数设置见表2。其中:padding为卷积操作在边界的填充大小。

表2 所提模型结构参数设置

Tab.2 Parameters setting of the proposed model

结构名称	参数设置
CNN	卷积核大小为7, padding=3
BiGRU(1)	神经元个数为128
BiGRU(2)	神经元个数为128
BiGRU(3)	神经元个数为128
随机丢失层	丢弃率为0.2

为充分评估所提模型的优越性,进行了对比实验,参与比较的方法有高斯过程回归(Gaussian process regression,简称GPR)、QR-BiGRU和QR-CNN-BiGRU。GPR是一种基于贝叶斯框架的回归模型,可输出预测结果的不确定性量化结果^[23]。为验证所提模型采用CNN模块进行空间特征提取的必要性,将所提方法与文献[24]的QR-BiGRU方法进行了对比。为论证模型采用SAM的必要性,将所提方法与不采用SAM的QR-CNN-BiGRU进行了比较。QR-BiGRU和QR-CNN-BiGRU的学习率、优化器及最大迭代次数等超参数与所提模型相同。

3.2 评价指标

采用以下3个指标对预测结果进行评价:①预测区间归一化平均带宽(prediction interval normalized average width,简称PINAW);②平均区间分数(average interval score,简称AIS);③平均预测区间中心偏差(mean prediction interval center deviation,简称MPICD)。

3.2.1 PINAW

PINAW是对区间预测有效性的一种度量,其越小越优^[25]。预测区间不宜过宽,越宽包含的有价值信息越少,实用性越差。PINAW的计算式为

$$\text{PINAW} = \frac{1}{nR} \sum_{i=1}^n (U(x_i) - L(x_i)) \quad (18)$$

其中: n 为预测样本总数; R 为目标值的范围; $U(x_i), L(x_i)$ 分别为预测区间的上、下限。

3.2.2 AIS

AIS 定义为所有区间估计点的区间分数均值,其综合考虑了区间覆盖率和区间宽度,是对预测区间的综合评价^[25-26],其值越大越优。AIS 的计算式为

$$AIS = \frac{1}{n} \left\{ \begin{aligned} &\sum_{i=1}^n -2a\delta(x_i) - 4(L(x_i) - y_i) \quad (y_i < L(x_i)) \\ &\sum_{i=1}^n -2a\delta(x_i) \quad (y_i \in (L(x_i), U(x_i))) \\ &\sum_{i=1}^n -2a\delta(x_i) - 4(L(x_i) - y_i) \quad (y_i > U(x_i)) \end{aligned} \right. \quad (19)$$

其中: a 为置信区间宽度; $\delta(x_i) = U(x_i) - L(x_i)$,为第 i 个预测区间的宽度; y_i 为第 i 个评估点的真实值。

3.2.3 MPICD

MPICD 指标衡量了预测区间中心与真实值的偏差^[27],其值越小越优。MPICD 的计算式为

$$MPICD = \frac{1}{n} \sum_{i=1}^n \left| \frac{U(x_i) + L(x_i)}{2} - y_i \right| \quad (20)$$

3.3 实验结果与分析

将上述 4 种方法分别应用在高抗振动监测系统实测的历史数据上,基于 3 个通道数据分别进行机械健康状态预测。限于篇幅,以一通道数据为例分析实验结果。

不同方法对某高抗健康状态区间预测对比如图 7 所示。其中:黑色曲线代表 HI 真实值;不同颜色覆盖区域表示各模型的预测区间。由图可以看出,在区间覆盖情况、区间宽度等方面,所提方法在 4 个模型中均是最优的。

不同预测模型在 3 个指标上的柱状图对比如图 8 所示。由图可见,所提模型的 PINAW、AIS 和 MPICD 分别为 0.052 5、-0.002 8 和 0.001 5,取得了最小的 PINAW、MPICD 值以及最大的 AIS 值。这说明本研究所提模型能够在保持较高区间覆盖率的前提下,得到更窄的预测区间。

进一步分析参与对比的各个模型的情况。没有引入 SAM 的 QR-CNN-BiGRU 的性能劣于所提模型,但显著优于 QR-BiGRU 和 GPR,取得了次优的结果。这一方面说明引入 SAM 机制,通过为高抗机械健康状态历史信息中的关键信息赋予更大权重,保留并突出重要时空信息,可以提高模型预测的精度;另一方面,相对于没有采用 CNN 模块的

QR-BiGRU 模型,QR-CNN-BiGRU 的预测性能得到大幅提高,证明了模型采用 CNN 模块的必要性,说明借助于 CNN 的局部特征提取和学习能力,可使区间预测性能进一步提升,减少了高抗健康状态区间预测的不确定性。此外,尽管 GPR 模型常被用于进行不确定性量化预测^[23],但从本研究的对比实验可见,不做任何改进的 GPR 取得了最劣的区间预测效果,尤其是在健康状态数据急剧波动时段(图 7 中采样点 150 和 200 附近),预测区间宽度明显变宽,这可能是由于浅层模型无法很好地拟合数据特征,且其性能高度依赖于核函数的选择和相应的超参数,从而导致精度较差。

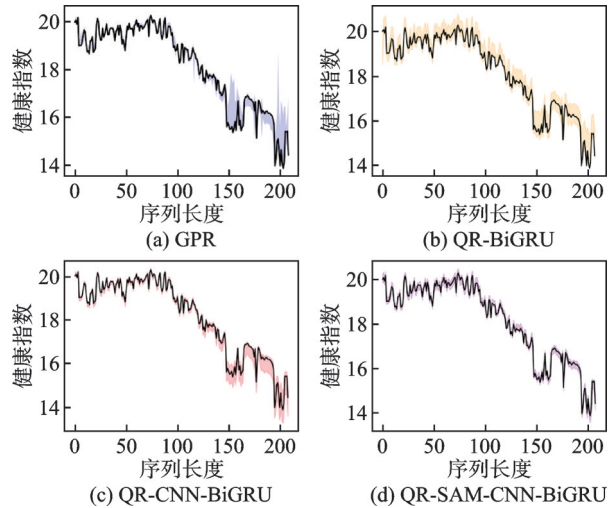


图 7 不同方法对某高抗健康状态区间预测对比

Fig.7 Comparison of different methods for the prediction of an ultra-high voltage shunt reactor health state interval

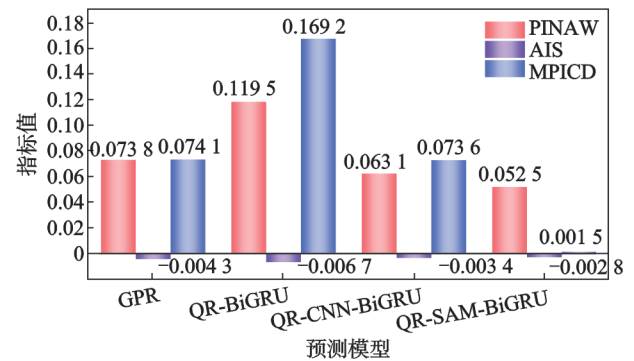


图 8 不同预测模型在 3 个指标上的柱状图对比

Fig.8 Results of the bar chart comparison of different interval prediction models on the three indicators

综上所述,本研究所提方法能够以最窄的区间宽度和最全的区间覆盖预测某 1 000 kV 高抗的机械健康状态,并能合理给出其不确定性的量化,验证了所提预测模型的可靠性和优越性。

4 结 论

1) 充分考虑高抗内部振动机理,基于油箱表面振动信号分析,经特征初选和优选构建的HI可以较好地反映高抗内部的机械健康情况。

2) 多变工况和复杂运行环境使得高抗机械HI呈现一定的不确定性,利用CNN的特征提取能力、SAM机制对重要信息的关注能力和BiGRU网络对HI序列时间依赖关系的双向捕获能力,可准确预测高抗未来健康趋势,采用的QR模型可实现HI区间预测。

3) 通过在某1 000 kV高抗上验证,所提模型取得了最小的PINAW、MPICD值及最大的AIS值,表明所提方法能够在复杂影响因素下预测出高抗健康状态趋势,并合理量化其不确定性,可为特高压变电站现场高抗运行安全主动维护提供决策依据。

参 考 文 献

- [1] 马宏忠,侯鹏飞,严岩,等.高压电抗器绕组和铁芯机械故障的混沌特性分析与特征识别[J].电力自动化设备,2022,42(5):204-211.
MA Hongzhong, HOU Pengfei, YAN Yan, et al. Chaotic characteristic analysis and feature recognition of mechanical failure of high voltage reactor winding and iron core[J]. Electric Power Automation Equipment, 2022, 42(5): 204-211.(in Chinese)
- [2] 高树国,孟令明,张玉焜,等.采用振动传感阵列的高压并联电抗器铁芯松动故障诊断方法[J].振动工程学报,2023,36(3):875-884.
GAO Shuguo, MENG Lingming, ZHANG Yukun, et al. Fault diagnosis method for core loose of high voltage shunt reactor using vibration sensing array[J]. Journal of Vibration Engineering, 2023, 36(3): 875-884.(in Chinese)
- [3] ARIAS-VELÁSQUEZ R M, MEJÍA-LARA J V. Methodology for failure analysis in shunt reactor by electromagnetic influence caused by high vibration in overload condition[J]. Engineering Failure Analysis, 2019, 104: 589-608.
- [4] 张鹏宁,李琳,聂京凯,等.考虑铁心磁致伸缩与绕组受力的高压并联电抗器振动研究[J].电工技术学报,2018,33(13):3130-3139.
ZHANG Pengning, LI Lin, NIE Jingkai, et al. Study on the vibration of high voltage shunt reactor considering of magnetostriction and winding force[J]. Transactions of China Electrotechnical Society, 2018, 33(13): 3130-3139.(in Chinese)
- [5] 郭佳熠,耿江海,律方成,等.基于气隙结构的特高压并联电抗器铁芯减振技术[J].高电压技术,2021,47(11):3892-3901.
GUO Jiayi, GENG Jianghai, LÜ Fangcheng, et al. Vibration reduction technology of UHV shunt reactor core based on air gap structure[J]. High Voltage Engineering, 2021, 47(11): 3892-3901.(in Chinese)
- [6] 周兵,王延召,胡静竹,等.并联电抗器振动特性及声功率级计算[J].高电压技术,2019,45(11):3685-3692.
ZHOU Bing, WANG Yanzhao, HU Jingzhu, et al. Vibration characteristics and acoustic power level calculation of shunt reactors[J]. High Voltage Engineering, 2019, 45(11): 3685-3692.(in Chinese)
- [7] ROSSI M, LE-BESNERAIS J. Vibration reduction of inductors under magnetostrictive and maxwell forces excitation[J]. IEEE Transactions on Magnetics, 2015, 51(12): 1-6.
- [8] 高树国,汲胜昌,孟令明,等.基于在线监测系统与声振特征预测模型的高压并联电抗器运行状态评估方法[J].电工技术学报,2022,37(9):2179-2189.
GAO Shuguo, JI Shengchang, MENG Lingming, et al. Operation state evaluation method of high-voltage shunt reactor based on on-line monitoring system and vibro-acoustic characteristic prediction model[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2179-2189.(in Chinese)
- [9] 吴金利,马宏忠,吴书煜,等.基于振动信号的高压并联电抗器故障诊断方法与监测系统研制[J].电测与仪表,2020,57(1):113-120.
WU Jinli, MA Hongzhong, WU Shuyu, et al. Fault diagnosis method and monitoring system of high voltage parallel reactor based on vibration signal[J]. Electrical Measurement & Instrumentation, 2020, 57(1): 113-120.(in Chinese)
- [10] HOU P F, MA H Z, JU P, et al. Intelligent diagnosis method for mechanical faults of high-voltage shunt reactors based on vibration measurements[J]. Machines, 2022, 10(8): 627.
- [11] 刘雪,成玮,周康宁,等.多源信息融合的核电循泵轴承健康状态增量评估[J].振动、测试与诊断,2024,44(4):690-696.
LIU Xue, CHENG Wei, ZHOU Kangning, et al. Incremental health state assessment of guide bearing in nuclear circulating water pump with multi-signal fusion network[J]. Journal of Vibration, Measurement & Diagnosis, 2024, 44(4): 690-696.(in Chinese)
- [12] 朱明,黄勤清,齐用卡,等.基于振动信号总离散频谱

- 的高压并联电抗器健康评估方法[J]. 电测与仪表, 2023, 60(8): 114-120.
- ZHU Ming, HUANG Qinqing, QI Yongka, et al. Healthy assessment method of high voltage shunt reactor based on total discrete spectrum of vibration signal [J]. *Electrical Measurement & Instrumentation*, 2023, 60(8): 114-120.(in Chinese)
- [13] SI X S, WANG W B, HU C H, et al. Estimating remaining useful life with three-source variability in degradation modeling[J]. *IEEE Transactions on Reliability*, 2014, 63(1): 167-190.
- [14] GHOSH M K, GAO Y H, DOZONO H, et al. Proposal of maxwell stress tensor for local force calculation in magnetic body[J]. *IEEE Transactions on Magnetics*, 2018, 54(11): 1-4.
- [15] 郭佳熠, 王博闻, 律方成, 等. 大型油浸式并联电抗器内外部振动测点数据相关性分析[J]. 华北电力大学学报(自然科学版), 2020, 47(6): 75-82, 90.
- GUO Jiayi, WANG Bowen, LÜ Fangcheng, et al. Data correlation analysis on internal and external vibration measurement points of large oil-immersed shunt reactor [J]. *Journal of North China Electric Power University (Natural Science Edition)*, 2020, 47(6): 75-82, 90. (in Chinese)
- [16] 张艳丽, 王佳音, 白保东, 等. 直流偏磁磁场对硅钢片磁致伸缩特性的影响分析[J]. 中国电机工程学报, 2016, 36(15): 4299-4307.
- ZHANG Yanli, WANG Jiayin, BAI Baodong, et al. Influence analysis of dc biased magnetic field on magnetostrictive characteristics of silicon steel sheet [J]. *Proceedings of the CSEE*, 2016, 36(15): 4299-4307. (in Chinese)
- [17] CHEN T Q, GUESTRIN C. XGBoost: a scalable tree boosting system [C] // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2016: 785-794.
- [18] 廖彬, 王志宁, 李敏, 等. 融合 XGBoost 与 SHAP 模型的足球运动员身价预测及特征分析方法[J]. 计算机科学, 2022, 49(12): 195-204.
- LIAO Bin, WANG Zhining, LI Min, et al. Integrating XGBoost and SHAP model for football player value prediction and characteristic analysis [J]. *Computer Science*, 2022, 49(12): 195-204.(in Chinese)
- [19] 崔兆亿, 耿秀丽. 基于随机森林和量子粒子群优化的 SVM 算法[J]. 计算机集成制造系统, 2023, 29(9): 2929-2936.
- CUI Zhaoyi, GENG Xiuli. Support vector machine algorithm based on random forest and quantum particle swarm optimization [J]. *Computer Integrated Manufacturing Systems*, 2023, 29(9): 2929-2936.(in Chinese)
- [20] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [DB/OL]. (2016-05-19) [2024-02-17]. <https://arxiv.org/abs/1409.0473>.
- [21] 蒋明峰, 支明豪, 李杨, 等. 基于自注意力机制生成对抗网络的超分辨率磁共振图像重建[J]. 中国科学: 信息科学, 2021, 51(6): 959-970.
- JIANG Mingfeng, ZHI Minghao, LI Yang, et al. Super-resolution reconstruction of Mr image with self-attention based generate adversarial network algorithm [J]. *Science in China : Information Sciences*, 2021, 51(6): 959-970.(in Chinese)
- [22] KOENKER R, BASSETT G. Regression quantiles [J]. *Econometrica*, 1978, 46(1): 33-50.
- [23] ROMAN D, SAXENA S, ROBU V, et al. Machine learning pipeline for battery state-of-health estimation [J]. *Nature Machine Intelligence*, 2021, 3(5): 447-456.
- [24] MA X P, DU H D, WANG K Y. An efficient QR-BiMGM model for probabilistic PV power forecasting [J]. *Energy Reports*, 2022, 8: 12534-12551.
- [25] WANG J Z, WANG S, ZENG B, et al. A novel ensemble probabilistic forecasting system for uncertainty in wind speed [J]. *Applied Energy*, 2022, 313: 118796.
- [26] LIAN C, ZHU L Z, ZENG Z G, et al. Constructing prediction intervals for landslide displacement using bootstrapping random vector functional link networks selective ensemble with neural networks switched [J]. *Neurocomputing*, 2018, 291:1-10.
- [27] LIAN C, ZENG Z G, WANG X P, et al. Landslide displacement interval prediction using lower upper bound estimation method with pre-trained random vector functional link network initialization [J]. *Neural Networks: the Official Journal of the International Neural Network Society*, 2020, 130: 286-296.



第一作者简介: 赵子强, 男, 1999年8月生, 硕士生。主要研究方向为电力设备健康状态评估研究。

E-mail: 1053437248@qq.com

通信作者简介: 张孝远, 男, 1981年4月生, 博士、教授、博士生导师。主要研究方向为电力设备智慧运维。

E-mail: freedon@haut.edu.cn