

DOI:10.13296/j.1001-1609.hva.2026.02.002

基于时间卷积网络的GIS设备振动信号特征预测

王 谦¹, 蒋西平¹, 龙英凯¹, 张施令¹, 胡 东², 赵仲勇², 杨童亮²

(1. 国网重庆电力公司电力科学研究院, 重庆 401123; 2. 西南大学工程技术学院, 重庆 400715)

摘要: GIS设备振动信号的变化可以反映设备内部的机械状态。为了提高GIS设备振动信号特性的预测精度,文中提出了一种基于分解—预测—重构的组合组测模型。首先,基于GIS历史振动信号,通过傅里叶变换在频域提取振动特征参数;其次,为了尽可能消除振动特征参数序列非平稳特性带来的影响,将归一化后的序列使用经过粒子群算法(PSO)优化后的变分模态分解(VMD)对振动特征参数序列进行分解;最后,将分解得到的一组平稳化模态分量使用时间卷积网络(TCN)进行预测。实验结果表明,文中所提基于PSO-VMD-TCN的组合预测模型预测结果均方根误差和平均绝对百分比误差分别为1.79%与0.13%,在预测精度上优于其他方法,有利于GIS设备前期故障诊断。

关键词: GIS设备; 非平稳特性; 预测模型; 时间卷积网络; 声振特征

Vibration Signal Feature Prediction of GIS Equipment Based on Temporal Convolution Network

WANG Qian¹, JIANG Xiping¹, LONG Yingkai¹, ZHANG Shiling¹, HU Dong²,
ZHAO Zhongyong², YANG Tongliang²

(1. Electric Power Research Institute, State Grid Chongqing Electric Power Company, Chongqing 401123, China; 2. College of Engineering and Technology, Southwest University, Chongqing 400715, China)

Abstract: The variation of vibration signal of GIS equipment can reflect the mechanical condition inside the equipment. For improving the prediction accuracy of vibration signal characteristics of GIS equipment, in this paper a combined group measurement model based on decomposition-forecasting-reconstruction is proposed. First, based on historical vibration signals of GIS, vibration characteristic parameters are extracted in frequency domain by Fourier transform. Then, in order to eliminate as much as possible the influence due to the non-stationary characteristics of the vibration characteristic parameter sequence, the normalized sequence is decomposed by the variational mode decomposition(VMD) optimized by particle swarm optimization(PSO). Finally, the time convolution network(TCN) is used to predict a set of stationary modal components obtained by decomposition. The experimental results show that the root mean square error and the average absolute percentage error of the combined prediction model based on PSO-VMD-TCN proposed in this paper are 1.79% and 0.13%, respectively, which are superior to other methods in prediction accuracy and are conducive to the early fault diagnosis of GIS equipment.

Key words: GIS equipment; non-stationary characteristic; prediction model; temporal convolutional network; vibroacoustic characteristics

收稿日期:2025-07-21; 修回日期:2025-10-02

基金项目:重庆市留学人员回国创业创新支持计划项目(cx2019123)。

Project Supported by Chongqing Support Program for Overseas Students Returning to China(cx2019123).

0 引言

气体绝缘全封闭组合电器(gas insulated switchgear, GIS)因占地面积小、可靠性高,广泛应用于电力系统,并应用于特高压工程中^[1]。但在长期运行过程中, GIS设备的振动会造成内部紧固件铁心、绕组等关键部件的松动。在极端情况下,甚至可能导致严重的设备故障^[2-5]。GIS设备的声振动特征与其内部机械状态^[6]密切相关。当GIS设备内部机械状态发生变化时,会引起局部振幅波动^[7]。因此,可以根据GIS振动信号对GIS设备的运行状态进行评估,这对于维持电力系统的稳定,保证能量的高效传输具有重要意义^[8]。

近年来,研究人员对GIS设备状态评估进行了广泛的研究^[9-11]。徐伟等人提出了一种基于振动信号的GIS设备故障检测方法,可以反映其内部运行状态。文[12]提出了基于递归定量分析的GIS设备振动信号处理方法。然而,该研究只在时域内进行,而没有在频域内进行。文[13]提出了基于振动信号功率谱和马尔可夫链的故障诊断模型,并利用相空间系数识别振动信号的状态特征。但未考虑重构信号在高维空间中的其他敏感特征,导致识别能力有限。文[14]以相位轨迹点 90° 角和非 90° 角的百分比为特征提取标准,提取了振动信号的特征,实现了满意的故障分类。但是,时延和嵌入维数对相位轨迹点角的确定产生了显著影响,特征提取的可靠性较低,文[15]所使用时域卷积神经网络(temporal convolutional networks, TCN)就能够有效快捷的处理时序预测问题,因为时间卷积网络是结合了时间序列建模、卷积、图像处理等诸多优势的一种新型时间序列预测模型。

随着传感器技术和人工智能的发展,深度学习方法越来越多地应用于GIS设备故障诊断和趋势预测。GIS振动特征序列由于多变量影响,存在非平稳特性,上述方法没有考虑非平稳特性对模型预测精度产生的影响,使得上述方法在进一步提升GIS设备振动特征序列预测精度上受到限制。因此,需要对GIS设备非平稳振动特征序列进行平稳化处理。通过对GIS设备原始特征序列进行分解,可以将GIS特征序列存在的非平稳特性尽可能的分解为一组规律性较强的平稳序列。目前对序列分解的手段多种多样,如文[16]中的经验模态分解EMD(empirical mode decomposition),文[17]变分模态分解VMD(variational mode decomposition)等。其中,EMD

分解往往会出现严重的模态混叠而导致分解效果不佳,影响预测精度^[18]。文[17]VMD方法是一种自适应滤波器,很好的解决了EMD在分解过程中所存在问题。

综上所述,为了提高GIS设备振动信号特征预测的精度,文中提出了一种基于分解—预测—重构的组合组测模型。首先,基于GIS历史振动信号,通过傅里叶变换在频域提取振动特征参数;其次,为了尽可能消除振动特征参数序列非平稳特性带来的影响,将归一化后的序列使用经过粒子群算法^[19](PSO)优化后的变分模态分解(VMD)对振动特征参数序列进行分解;最后,将分解得到的一组平稳化模态分量使用时间卷积网络(TCN)进行预测。通过对某变电站GIS设备多通道振动信号的实例分析,验证了文中方法的有效性。

1 PSO-VMD分解模型

1.1 变分模态分解(VMD方法)

VMD分解方法最大的优点是可以自适应分解以及分解分量可以尽可能准正交,可以将非平稳非线性原始序列分解为一组高频低幅、低频高幅等平稳化的有限带宽的固有模态(IMF)^[20],且以相应的中心频率为中心。在VMD的产生过程中,主要涉及到变分约束问题的产生和处理2个层面,其中变分约束问题产生的具体过程包括:①对每个模态采用希尔伯特映射,得到与其有关的解析信息;②对每个模态,可以通过加入指数项的各自所估计的中心频率,将模态的频率转移到基带上;③首先通过对解调信号高斯平滑带宽的计算;④首先得出了一个变分约束问题,然后再通过对二次罚函数项的拉格朗日乘子算子得出了一个非约束问题,见式(1)^[21],最后解决了问题。

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left(\sum_{k=1}^K \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) e^{-j\omega_k t} \right\|_2^2 \right) \\ \text{s.t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式(1)中: u_k 是第 k 个分量函数; ω_k 为第 k 个分量中心频率; $\delta(t)$ 为冲激函数; ∂_t 是对 t 求偏导; $f(t)$ 为原信号;*为卷积运算。

变分模态分解中的变分约束问题实质就是在变分问题的结构下通过搜罗最优解,以此来达到自适应分解的目的。上述变分问题的基础上引入了二次惩罚因子 α 和拉格朗日算子 $\lambda(t)$,构成了扩展的拉格朗日,得到的表达式为

$$L_{u_i, \omega_i, \lambda} = \alpha \sum_{k=1}^K \left\| \partial_i \left\{ \left[\delta(t) + \frac{j}{\pi t} \right] \cdot u_k(t) \right\} e^{-j\omega_i t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (2)$$

通过迭代寻求拉格朗日函数鞍点, 所得鞍点就是式(1)中最优解, 解得 $\hat{u}_k^{n+1}(\omega)$ 及中心频率 ω_k^{n+1} 分别为:

$$\hat{u}_k^{n+1}(\omega) = \left[\hat{f}(\omega) - \sum_{i=1}^{k-1} \hat{u}_i^{n+1}(\omega) + \hat{\lambda}^n(\omega) / 2 \right] \div 1 + 2\alpha(\omega - \omega_k^n)^2 \quad (3)$$

$$\omega_k^{n+1} = \int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega \div \int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega \quad (4)$$

在非负频率区间, 更新 λ

$$\hat{\lambda}^{n+1} = \hat{\lambda}^n + \tau \left[\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (5)$$

对于给定判定精度 $\varepsilon > 0$, 有

$$\sum_{k=1}^K \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 \div \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (6)$$

式(6)中, \hat{u}_k^{n+1} 、 $\hat{f}(\omega)$ 、 $\hat{\lambda}^{n+1}$ 分别为 u_k^{n+1} 、 $f(t)$ 、 λ^{n+1} 所对应的傅里叶变换。

满足式(6)则停止迭代, 否则返回式(3)。

1.2 适应度函数的构造

因为文中需要分解得到平稳化的一组模态分量, 所以选择能够体现序列复杂程度的包络熵^[22]作为 VMD 分解效果的评判标准。即时间序列 $x(j)$ 长度为 N 的包络熵定义为:

$$p_j = a(j) \div \sum_{i=1}^N a(i) \quad (7)$$

$$E_p = - \sum_{j=1}^N p_j \lg p_j \quad (8)$$

式(7)、(8)中: $i, j = 1, 2, \dots, N$; $a(j)$ 为经过 $x(j)$ 希尔伯特解调之后所得到的包络信号, 其中 $a(j)$ 经过归一化后得到 p_j 。

1.3 PSO 算法

粒子群算法属于元启式优化算法的一种。粒子群算法通过粒子来模拟鸟类个体之间相互交流写作, 以此来不断更新粒子的位置与速度, 从而使适应度函数值最小的位置为所要寻找的最优目标解。假设存在一个 D 维可行空间, 粒子种群数为 N , 则第 i 个粒子在空间中的位置可表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, 第 i 个粒子的当前速度为 $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$, 第 i 个粒子的个体最优值为 $P_{best} = (p_{i1}, p_{i2}, \dots, p_{iD})$, 整个搜索空间中的全局最优值为 $g_{best} = (g_1, g_2, \dots, g_D)$ 。与此同时, 根据其所在位置

以及所在群体的个体最优值来更新粒子所处的位置和速度。更新公式为:

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (P_{id}^k - x_{id}^k) + c_2 r_2 (P_{gd}^k - x_{id}^k) \quad (9)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (10)$$

式(9)、(10)中: i 为粒子序号; v_{id}^{k+1} 为粒子下一时刻的速度; ω 为粒子惯性权重; v_{id}^{k+1} 为粒子此时速度; c_1 、 c_2 为粒子更新过程中的学习因子; r_1 、 r_2 取值范围为 $[0, 1]$; P_{id}^k 为此刻粒子最优位置; P_{gd}^k 为迭代后全局最优位置; x_{id}^k 为粒子此刻位置; x_{id}^{k+1} 为粒子下一时刻的位置。具体流程见图1。




图1 PSO-VMD模型算法流程图

Fig. 1 Flow chart of PSO-VMD model algorithm

2 时间卷积神经网络

TCN可以从GIS设备特征序列的历史序列中提取出时间特征。TCN的核心是多层一维CNN。每一次卷积运算都可以看作是一个滤波器。采用多重滤波器提取输入数据的特征。随着层数的增加, 提取的特征越来越抽象, 每个输出元素覆盖的时间跨度也越来越长。与常用的TCN模型^[23-24]不同的是, 文中提出的TCN去除了残差连接和批归一化, 利用因果卷积和扩张卷积降低了网络的复杂性, 达到了较高的精度。4层因果卷积网络与4层扩张因果卷积网络分别见图2、3。




图2 因果卷积网络示意图

Fig. 2 Schematic diagram of causal convolutional network




图3 膨胀卷积结构示意图

Fig. 3 Schematic diagram of dilated convolution structure

扩张型卷积通过调整扩张型因子 d 有选择地获取输入数据,使接收场可以大于核大小 k ,而不增加隐含层数。这意味着其他卷积核比普通CNN的卷积核更稀疏。扩张卷积层的感受野为

$$R_1 = (k-1) \times d + 1 \quad (11)$$

随着扩张卷积层数的增加,感受野可以呈指数级扩展。

图3中,当第 e 个扩张卷积层的扩张因子为 $d=k^{e-1}$ 时,感受野为

$$R_e = k^e \quad (12)$$

与图2中相同核大小和层数的因果卷积网络相比,扩张后的因果卷积网络能达到更大的接受域,覆盖更长的历史数据,使得时间特征提取更加有效,降低了网络的复杂性,提高了预测精度。

3 PSO-VMD-TCN 组合预测模型构建

3.1 PSO-VMD-TCN 预测模型

PSO-VMD-TCN 预测模型流程图见图4。

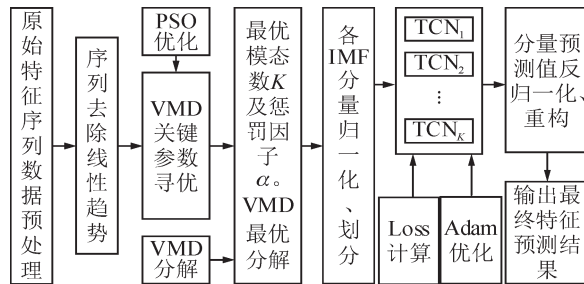


图4 PSO-VMD-TCN 模型预测流程

Fig. 4 PSO-VMD-TCN model prediction flow

PSO-VMD-TCN 预测模型步骤为:①首先,对原始特征序列进行去除病态值、归一化等预处理,处理方法分别见文[25-26]。②使用SMA对VMD进行参数自适应寻优,接着使用最优化VMD对预处理后的特征序列进行分解得到频段不同的各模态分量。③对VMD后各分量分别建立TCN预测模型,TCN预测模型选用Adam优化器更新网络参数。④反归一化预测分量,重构各分量预测结果,输出最终预测结果。

3.2 预测模型评价指标

为了定量分析预测值 \hat{y}_i 与真实值 y_i ,预测模型评价指标选用平均绝对误差(MAE)、绝对百分比误差(MAPE)与均方根误差(RMSE),其表达式为:

$$e_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \quad (13)$$

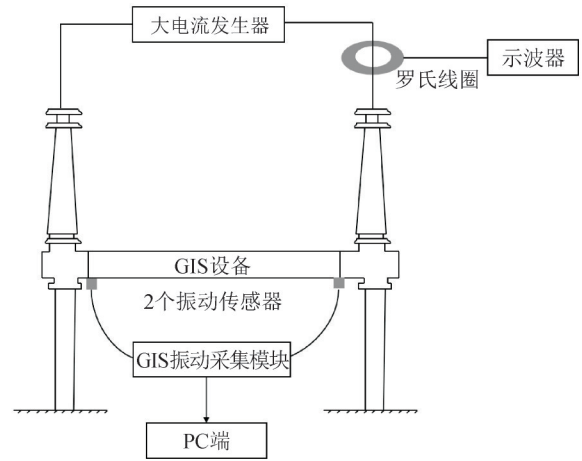
$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{y_i} \times 100\% \quad (14)$$

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (15)$$

4 实验分析

4.1 实验平台

GIS设备振动信号为电气机械振动信号,振动频宽约为10~2 000 Hz,振幅约为0.5~50 μm 。指纹图谱库构建方法见图5。大电流发生器产生约3 kA的大电流,通过罗氏线圈和示波器实现对电流的测量。基于220 kV等级GIS设备真型平台分别模拟触指差程、分子筛器皿松动、屏蔽罩松动、长导体触座松动、隔离开关接触不良5种典型异响振动缺陷。采用上述GIS振动采集模块对振动波形进行采集,并存入PC端,每类缺陷指纹图谱库不低于100张。



(a) 实验设置示意图



(b) 实验设置实景图

图5 指纹图谱库构建平台

Fig. 5 Construction platform of fingerprint database

4.2 实验数据

在GIS不同部位设置了外部连接螺丝松动这类静止机构故障典型的机械故障,通过松开气室之间法兰上的紧固螺钉设置外部连接松动故障。外部连接螺丝松动故障除在故障螺丝上放置了2个传感器外,还在其周边设置了2个测点。实验数据采用频率为125 kHz,4通道。该GIS设备进行全天候采样,采样间隔为1 h,一天内每个通道有24段时域波形。该GIS设备前0.2 s的时域数据见图6。图6(a)-(d)

分别为通道1-4的振动数据,由于是现场测试数据文中数据除了包含基频 100 Hz 的噪声信号,同时也包含 200、300 Hz 等谐波信号。




图6 各通道信号时域图

Fig. 6 Signal time domain diagram of each channel

由于现场数据时域波形较为复杂,文中主要对

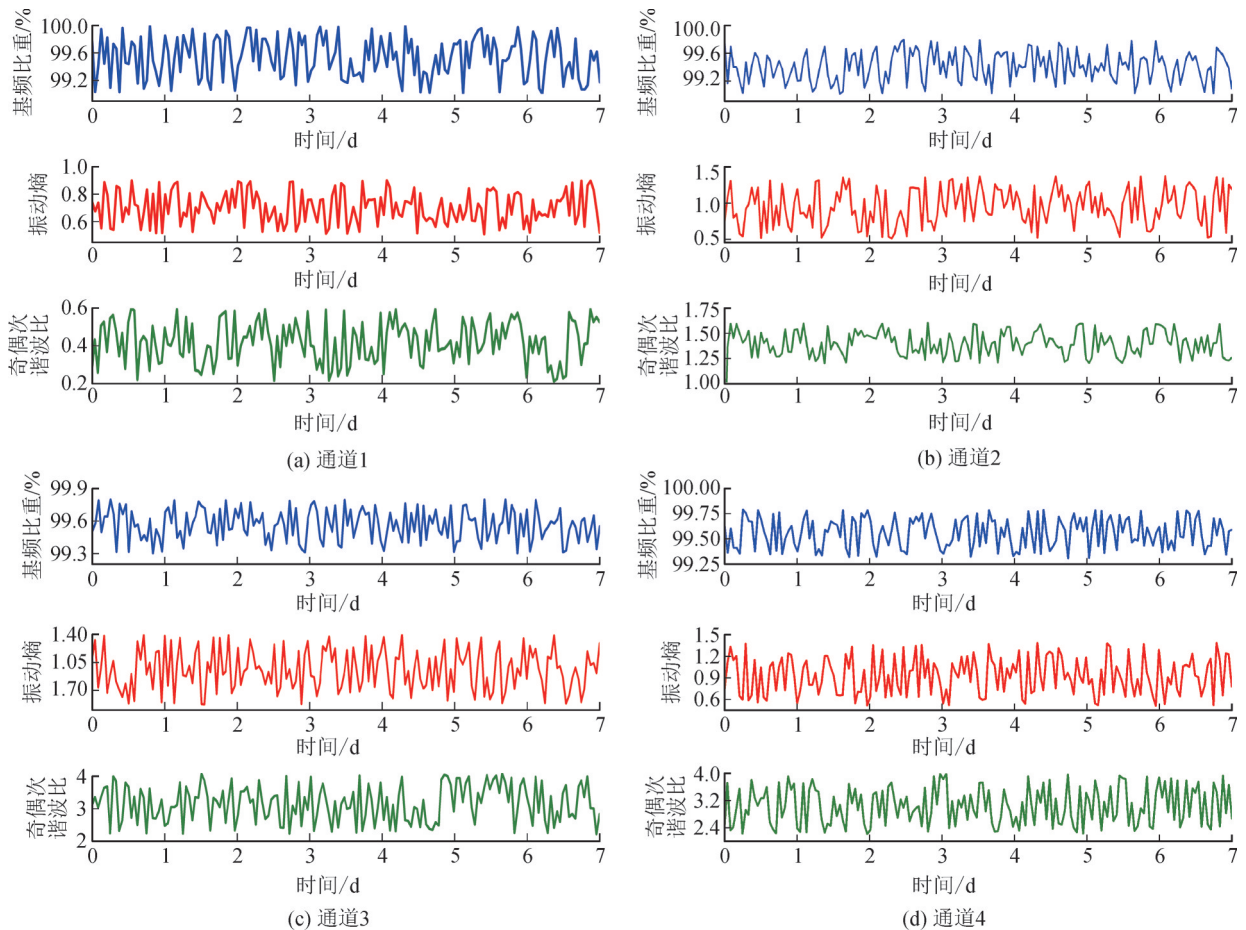


图7 各通道基频比重、振动熵、奇偶次谐波比3种特征

Fig. 7 Three characteristics of fundamental frequency specific gravity, vibration entropy and odd-even harmonic ratio of each channel

频域波形进行预测研究。为了综合衡量其运行状态,对时序数据选取奇偶次谐波比、基频比重、振动熵3种特征参量作为时序预测数据的组成。

各通道奇偶次谐波比、基频比重、振动熵3种特征参量的历史数据见图7,各特征参量历史数据均存在一定程度的波动并且具有一定的时序性。各通道特征值的大小与GIS设备的现场运行状况、环境因素等多种因素有关。

4.3 仿真实验

针对4个通道振动信号构建奇偶次谐波比、基频比重、振动熵3种特征参量共计12条时序数据。训练集与测试集的划分为采用6天的数据作为模型训练集预测未来一天的特征参量,训练集时间序列长度为144,测试集时间序列长度为24。基于文中构建的PSO-VMD-TCN的GIS振动特征预测模型,首先将12条特征数据进行训练集与测试集的划分,将

预处理后的数据使用 PSO-VMD 模型进行最优分解, 然后将分解所得模态分量 IMF 数据送入 TCN 模型中。TCN 模型的超参数范围设置为: 批大小取值范围 [1, 50]; 3 个隐含层节点的个数范围为 [1, 100]; 学习率 0.000 1。PSO-VMD-TCN 模型迭代次数设置为 100 次。使用测试集数据进行测试, 输出预测结果。

GIS 振动信号特征分解与预测结果见图 8-11。其中图 8(a)-(c)、图 9(a)-(c)、图 10(a)-(c)、图 11(a)-(c) 分别为各通道基频比重特征、奇偶次谐波比、振动熵序列经过 PSO-VMD 分解后所得平稳序列的模态分量, 对比图 7 可以看出, 经过 PSO-VMD 分解后, 将原始非平稳序列分解后得到了一组平稳的模态分量。

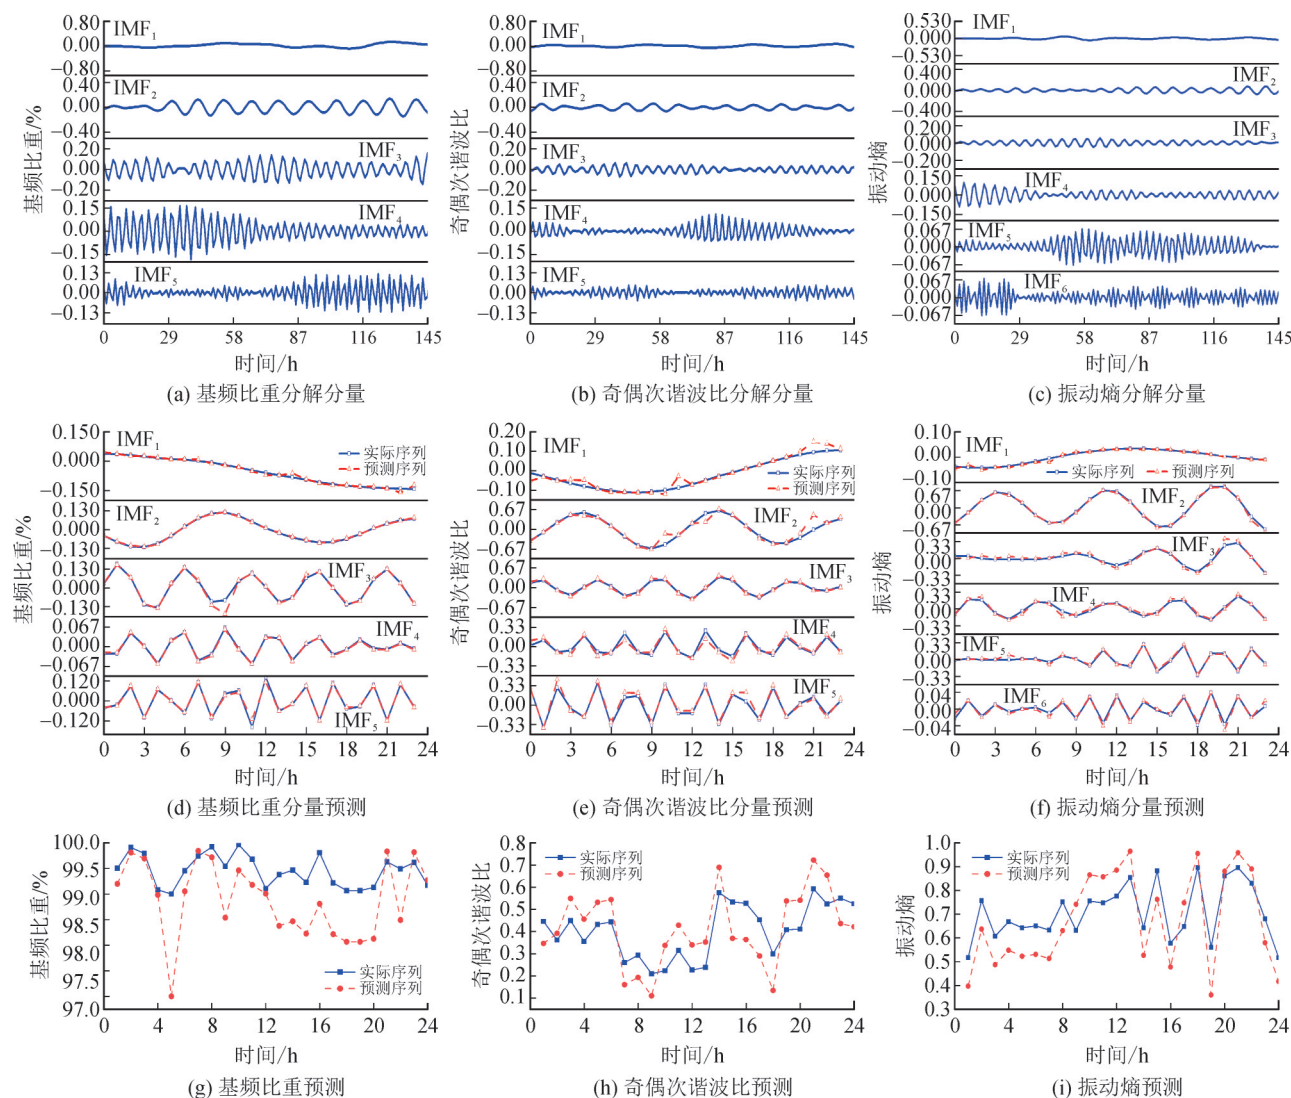


图 8 基于 PSO-VMD-TCN 通道 1 振动特征预测

Fig. 8 Vibration feature prediction of channel 1 based on PSO-VMD-TCN

图 8(d)-(f)、图 9(d)-(f)、图 10(d)-(f)、图 11(d)-(f) 分别为各通道基频比重特征、奇偶次谐波比、振动熵分解后的 IMF 分量预测效果, 可以看出 TCN 预测模型对该时间序列具有良好的预测性能。

图 8(g)-(i)、图 9(g)-(i)、图 10(g)-(i)、图 11(g)-(i) 分别为各通道基频比重特征、奇偶次谐波比、振动熵 IMF 分量预测结果经过反归一化和重构后的最终预测结果, 结果表明, PSO-VMD-TCN 模型能够准确的捕

捉到奇偶次谐波比、基频比重、振动熵 3 种特征参量的历史变化趋势且预测结果与实际结果的数据起伏大致相同。

为了验证文中 PSO-VMD-TCN 预测模型的性能, 选取平均绝对误差(MAE), 均方根误差(RMSE)以及平均绝对百分比误差(MAPE)3 种评价指标进行验证。各特征的预测效果评估见表 1。由表 1 可知, 振动熵在各通道的 MAE 值分别为 0.05、0.06、0.08、0.07。

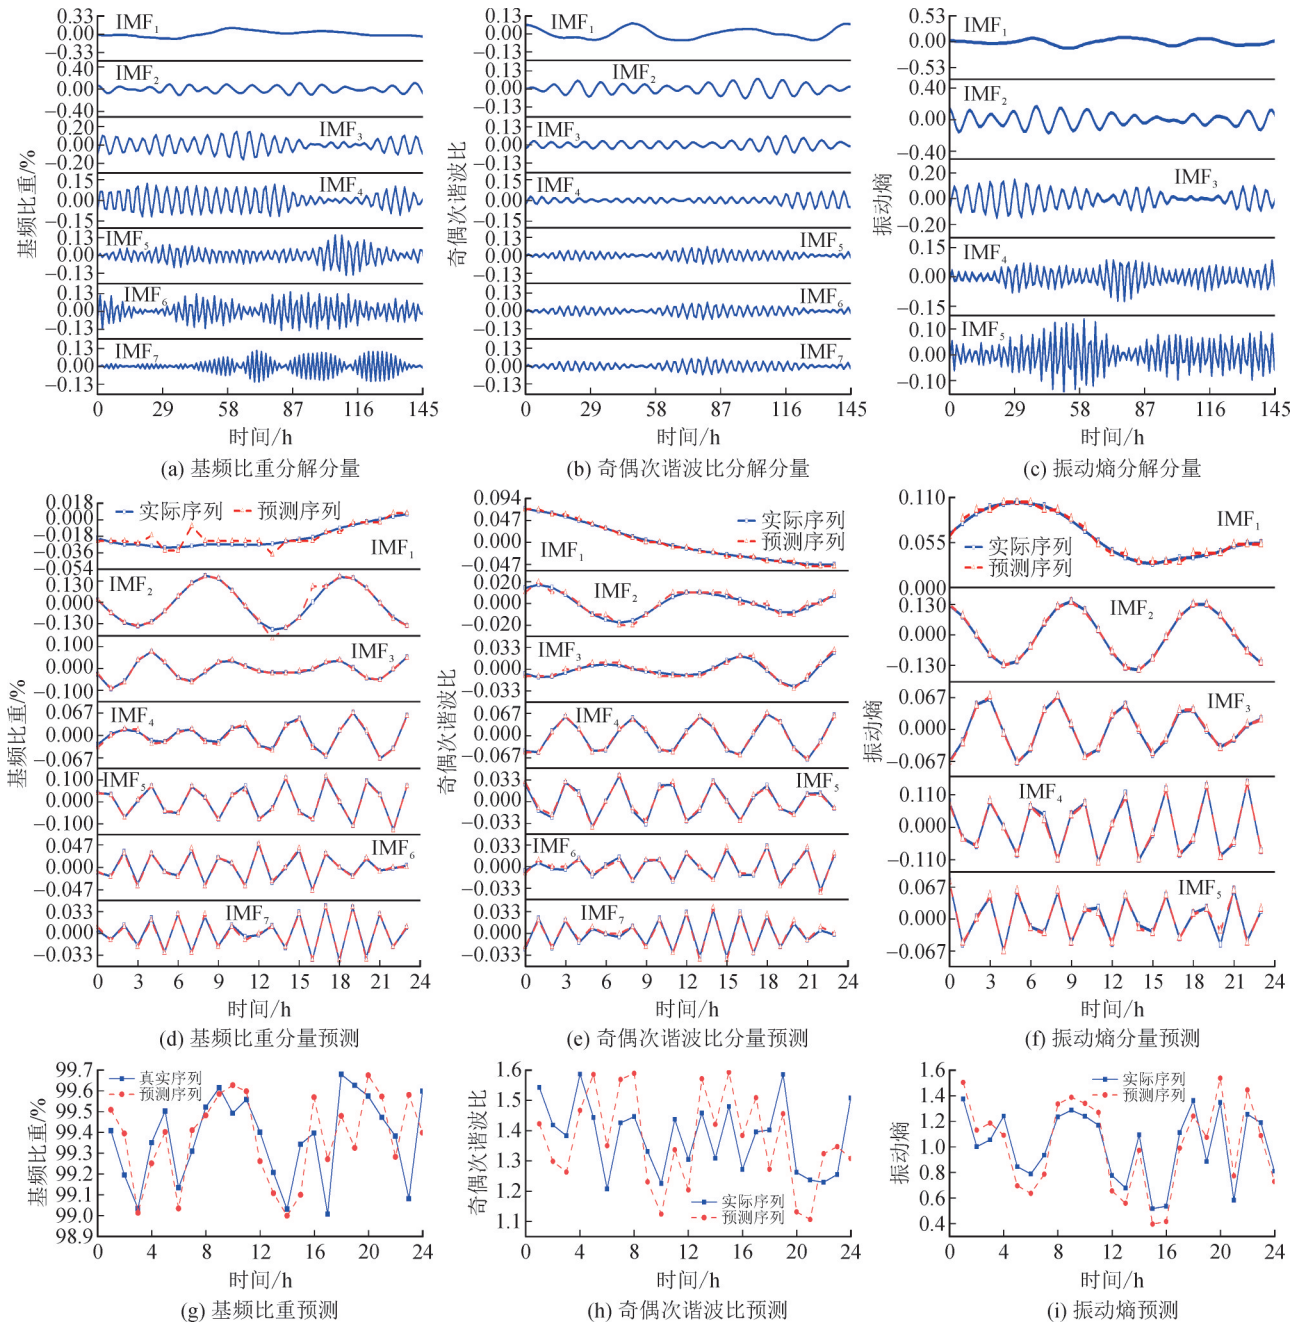


图9 基于PSO-VMD-TCN通道2振动特征预测

Fig. 9 Vibration feature prediction of channel 2 based on PSO-VMD-TCN

振动熵的数值越低表明频谱能量越集中。当GIS设备发生直流偏磁时,振动信号中的奇次谐波分量就会增多,利用该特征判断GIS设备直流偏磁的程度,由表1可知,通道2奇偶次谐波比为的MAPE为0.03%,在各通道的值中最小,但总体误差较低。

4.4 对比分析

为了验证文中方法的优越性,选取TCN,EMD-TCN,EMD-LSTM,BiLSTM以及LSTM 5种模型进行对比实验。预测结果见图12(仅以奇偶次谐波比特

征参数的预测结果展示)。从图12可以看出,PSO-VMD-TCN方法相比于其他方法更加更切合真实数据,相比于其他预测模型文中方法的预测精度更高。

使用不同方法对各通道奇偶次谐波比、基频比重、振动熵3种特征预测结果评价指标见表2。从表2可以看出,EMD-TCN、EMD-LSTM、TCN、BiLSTM、LSTM的MAPE值分别为0.13%、0.14%、0.15%、0.16%、0.16%,相比于上述方法文中所提方法预测精度分别提高了0.12%、0.23%、0.31%、0.36%、0.49%。

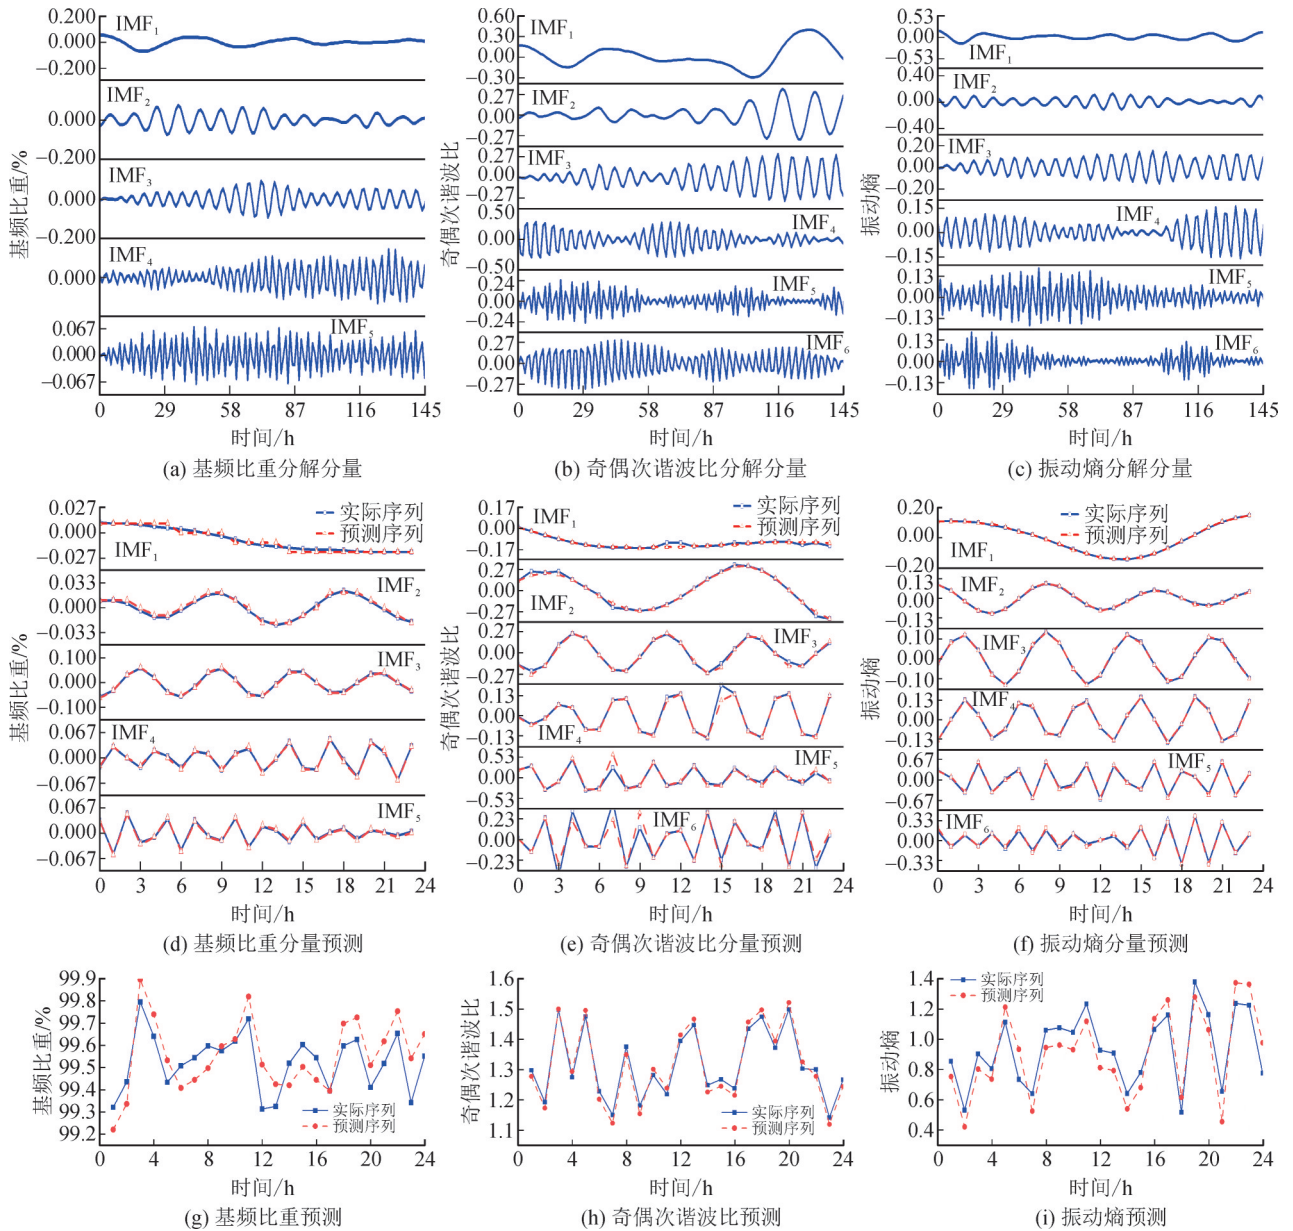
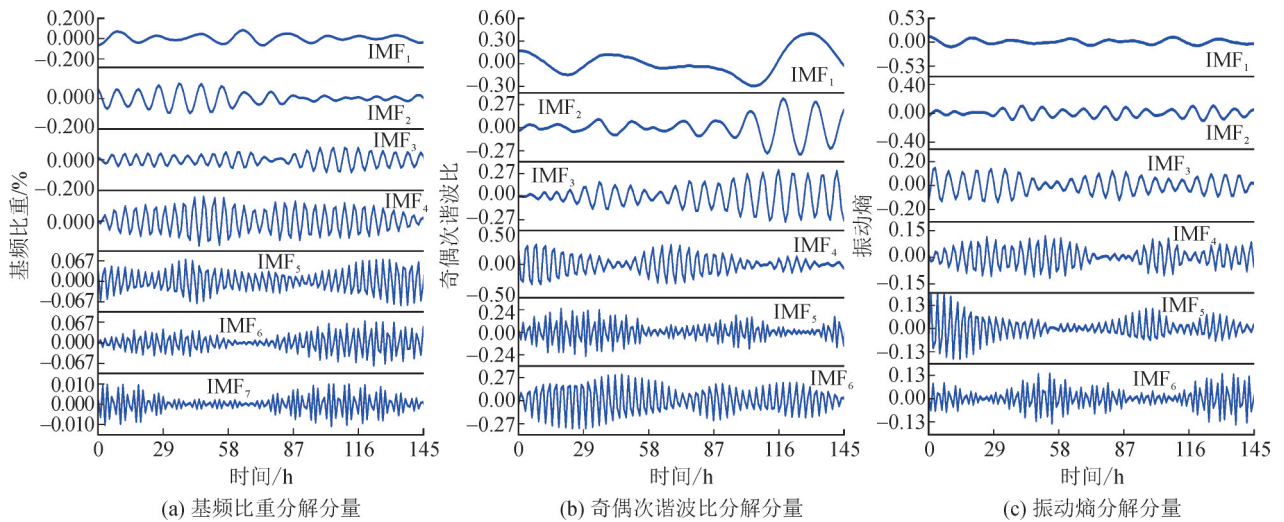


图 10 基于 PSO-VMD-TCN 通道 3 振动特征预测

Fig. 10 Vibration feature prediction of channel 3 based on PSO-VMD-TCN



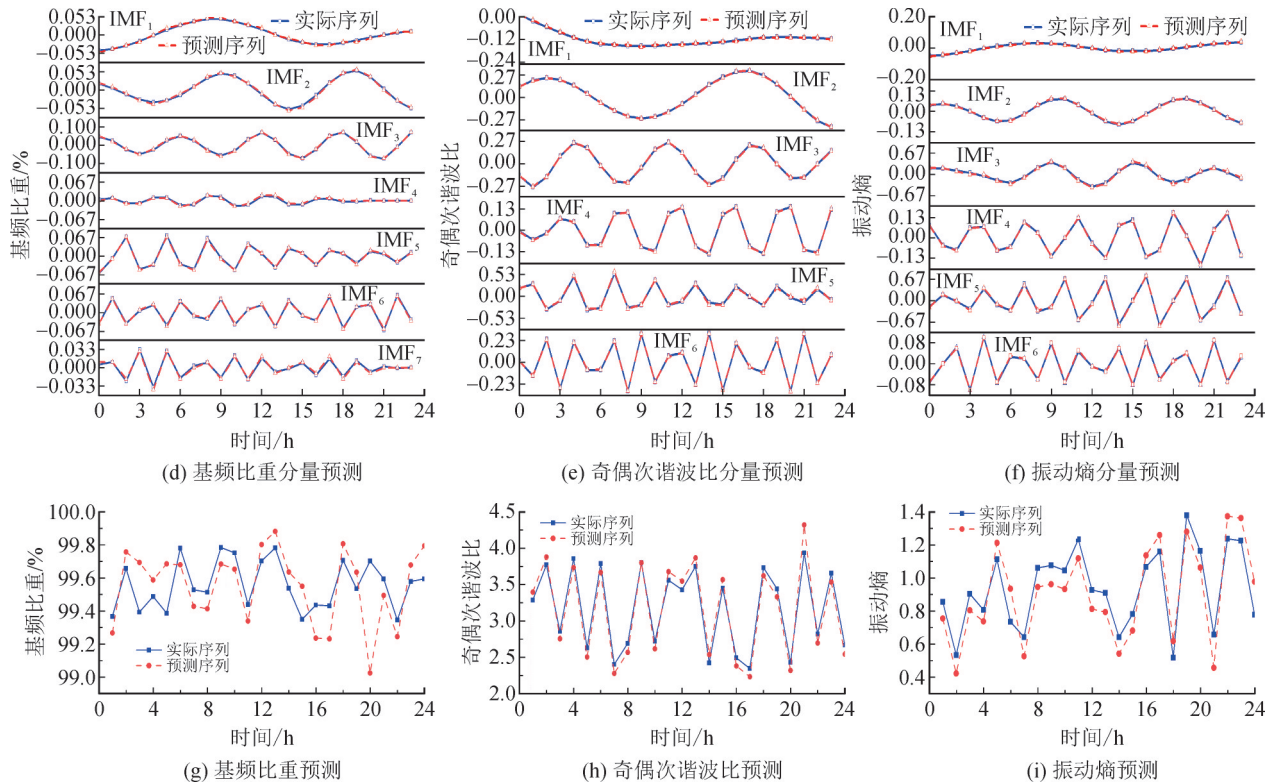


图 11 基于 PSO-VMD-TCN 通道 4 振动特征预测

Fig. 11 Vibration feature prediction of channel 4 based on PSO-VMD-TCN

表 1 各特征的预测效果评估

Table 1 Performance evaluation of fundamental frequency specific gravity prediction

通道	基频比重			振动熵			奇偶次谐波比		
	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$
1	0.08	2.58	0.10	0.05	1.41	0.03	0.04	1.05	0.04
2	0.06	1.67	0.03	0.06	1.63	0.04	0.06	2.43	0.03
3	0.05	1.83	0.05	0.08	1.72	0.09	0.05	1.89	0.06
4	0.07	1.91	0.04	0.07	1.93	0.06	0.04	1.53	0.03

表 2 不同方法的评价指标结果均值及标准差

Table 2 Mean and standard deviation of evaluation index results of different methods

模型	e_{MAE}	e_{RMSE}	$e_{MAPE}/\%$
LSTM	0.24±0.71	4.32±0.67	0.16±0.48
BiLSTM	0.18±0.60	4.02±0.51	0.16±0.32
TCN	0.15±0.39	3.12±0.42	0.15±0.31
EMD-LSTM	0.15±0.47	2.03±0.61	0.14±0.24
EMD-TCN	0.14±0.43	1.79±0.52	0.13±0.14
PSO-VMD-TCN	0.14±0.01	1.79±0.39	0.13±0.02




图 12 不同方法奇偶次谐波特征参量预测

Fig. 12 Prediction of the characteristic parameters of odd and even harmonics by different methods

5 结论

为了提高 GIS 设备振动信号特征预测的精度，文中提出了一种基于分解—预测—重构的组合组

测模型。首先，基于 GIS 历史振动信号，通过傅里叶变换在频域提取振动特征参数；其次，为了尽可能消除振动特征参数序列非平稳特性带来的影响，将归一化后的序列使用经过粒子群算法(PSO)优化后的变分模态分解(VMD)对振动特征参数序列进行分解；最后，将分解得到的一组平稳化模态分量使用

时间卷积网络(TCN)进行预测。通过实例分析某变电站内GIS设备多通道振动信号,实验结果表明:

1)通过PSO-VMD的分解手段对GIS设备振动特征序列进行分解,可以有效解决GIS设备振动特征序列所存在非线性问题对预测结果产生较大误差的影响。

2)基于PSO-VMD-TCN的GIS设备振动特征预测方法能够准确地捕捉对各通道振动信号不同特征的变化趋势,预测误差均值仅为0.13%。

参考文献:

- [1] 张斌斌, 刘晓洲. 变电站GIS设备SF₆在线监测系统分析及应用[J]. 技术与市场, 2019, 26(12): 103-104.
ZHANG Binbin, LIU Xiaozhou. Analysis and application of SF₆ on line monitoring system of substation GIS equipment[J]. Technology and Market, 2019, 26(12): 103-104.
- [2] 孙宇晗, 程永锋, 卢智成, 等. 170 kV中性点电抗器地震模拟振动台试验研究[J]. 振动与冲击, 2018, 37(13): 229-234.
SUN Yuhan, CHENG Yongfeng, LU Zhicheng, et al. Earthquake simulation shaking table tests for a 170 kV neutral reactor[J]. Journal of Vibration and Shock, 2018, 37(13): 229-234.
- [3] 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.
- [4] 王磊磊, 张嵩阳, 姚德贵, 等. 变电站铁心电抗器振动与可听噪声研究综述[J]. 高压电器, 2019, 55(11): 26-33.
WANG Leilei, ZHANG Songyang, YAO Degui, et al. Vibration and audible noise of iron-core reactor in substation: A review[J]. High Voltage Apparatus, 2019, 55(11): 26-33.
- [5] 侯鹏飞, 马宏忠, 吴金利, 等. 基于混沌理论与蝗虫优化K-means聚类算法的电抗器铁芯和绕组松动状态监测[J]. 电力自动化设备, 2020, 40(11): 181-187.
HOU Pengfei, MA Hongzhong, WU Jinli, et al. Looseness status monitoring of reactor core and winding based on chaos theory and K-means clustering algorithm optimized by grasshopper algorithm[J]. Electric Power Automation Equipment, 2020, 40(11): 181-187.
- [6] 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.
- [7] DAS S, SIDHU T S, ZADEH M R D, et al. A novel hybrid differential algorithm for turn to turn fault detection in shunt reactors[J]. IEEE Transactions on Power Delivery, 2017, 32(6): 2537-2545.
- [8] 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. Health assessment method of high voltage shunt reactor based on total discrete spectrum of vibration signals[J]. Electrical Measurement & Instrumentation, 2023, 60(8): 114-120.
- [9] ZHAO Yajun, CHEN Xiaohan, CHENG Xiang, et al. Noninvasive method for online detection of internal winding faults of 750 kV EHV shunt reactors[J]. IEEE Transactions on Dielectrics & Electrical Insulation, 2015(22): 2833-2840.
- [10] JIANG Ning, HAO Baoxing, ZHAO Ruoyu, et al. Application of empirical wavelet transform in vibration signal analysis of UHV shunt reactor[C]//IEEE Milan Power Tech. Milan, Italy: IEEE, 2019: 1-5.
- [11] WU Deng, LIU Hailong, XU Junjie, et al. An improved quantum-inspired differential evolution algorithm for deep belief network[J]. IEEE Transactions on Instrumentation & Measurement, 2020, 69(10): 7319-7327.
- [12] 潘信诚, 马宏忠, 陈明, 等. 基于CRP和RQA的高压并联电抗器振动信号分析[J]. 大电机技术, 2019(3): 62-67.
PAN Xincheng, MA Hongzhong, CHEN Ming, et al. Analysis of vibration signals of high voltage shunt reactor based on CRP and RQA[J]. Large Electric Machine and Hydraulic Turbine, 2019(3): 62-67.
- [13] LI Qingmin, ZHAO Tong, ZHANG Li, et al. Mechanical fault diagnostics of on-load tap changer within power transformers based on hidden markov model[J]. IEEE Transactions on Power Delivery, 2012, 27(2): 596-601.
- [14] HUANG Weidi, GAN Chunbiao. A vector angle method of rolling bearing fault classification by phase-space reconstruction technique[J]. Journal of Testing and Evaluation, 2020, 48(4): 2624-2638.
- [15] 王泽峰, 许辉群, 杨梦琼, 等. 应用时域卷积神经网络的地震波阻抗反演方法[J]. 石油地球物理勘探, 2022, 57(2): 279-286.
WANG Zefeng, XU Huiqun, YANG Mengqiong, et al. Seismic impedance inversion method based on time-domain convolutional neural network[J]. Oil Geophysical Prospecting, 2022, 57(2): 279-286.
- [16] 林琳, 陈志英. 基于粗糙集神经网络和振动信号的高压断路器机械故障诊断[J]. 电工技术学报, 2020, 35(s1): 277-283.
LIN Lin, CHEN Zhiying. Mechanical fault diagnosis of high voltage circuit breakers based on rough set neural networks and vibration signals[J]. Transactions of China Electrotechnical Society, 2020, 35(s1): 277-283.
- [17] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [18] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [19] 朱丽莉, 杨志鹏, 袁华. 粒子群优化算法分析及研究进展[J]. 计算机工程与应用, 2007, 43(5): 24-27.

- ZHU Lili, YANG Zhipeng, YUAN Hua. Analysis and development of particle swarm optimization[J]. Computer Engineering and Applications, 2007, 43(5): 24-27.
- [20] 谢平, 江国乾, 武鑫, 等. 基于多尺度熵和距离评估的滚动轴承故障诊断[J]. 计量学报, 2013, 34(6): 548-553.
- XIE Ping, JIANG Guoqian, WU Xin, et al. Rolling bearing fault diagnosis based on multiscale entropy and distance evaluation[J]. Acta Metrologica Sinica, 2013, 34(6): 548-553.
- [21] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊C均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- LIU Changliang, WU Yingjie, ZHEN Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering[J]. Proceedings of the CSEE, 2015, 35(13): 3358-3365.
- [22] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报, 2015, 49(5): 73-81.
- TANG Guiji, WANG Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing[J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81.
- [23] PANDEY A, WANG Deliang. TCNN: Temporal convolutional neural network for real-time speech enhancement in the time domain [C]//IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton, UK: IEEE, 2019: 6875-6879.
- [24] FARHA Y A, GALL J. MS-TCN: Multi-stage temporal convolutional network for action segmentation [C]//Computer Vision & Pattern Recognition (CVPR). Long Beach, USA: IEEE, 2019: 3570-3579.
- [25] 刘树鑫, 宋健, 刘洋, 等. 交流接触器触头系统运动分析及故障诊断研究[J]. 电工技术学报, 2021, 36(s2): 477-486.
- LIU Shuxin, SONG Jian, LIU Yang, et al. Research on motion analysis and fault diagnosis of contact system of AC contactor[J]. Transactions of China Electrotechnical Society, 2021, 36(s2): 477-486.
- [26] 向玲, 邓泽奇, 赵玥. 基于LPF-VMD和KELM的风速多步预测模型[J]. 电网技术, 2019, 43(12): 4461-4467.
- XIANG Ling, DENG Zeqi, ZHAO Yue. Multi-step wind speed prediction model based on LPF-VMD and KELM[J]. Power System Technology, 2019, 43(12): 4461-4467.
- 王谦(1979—), 男, 硕士, 工程师, 主要从事输变电设备现场试验及状态检修技术研究。
- 杨童亮(1996—), 男, 硕士研究生, 主要从事电力设备在线监测与故障诊断研究(通信作者)(E-mail: 375464831@qq.com)。

(上接第7页)

- CAO Yupeng, LUO Lin, WANG Qiao, et al. Fault diagnosis of high-voltage vacuum circuit breaker with a convolutional deep network [J]. Power System Protection and Control, 2021, 49(3): 39-47.
- [22] 李静, 易晨曦, 彭世东, 等. 高海拔环境下大容量直流空气断路器灭弧性能研究[J]. 电工技术学报, 2024, 39(3): 863-874.
- LI Jing, YI Chenxi, PENG Shidong, et al. Study on interrupting characteristics of large capacity DC air circuit breaker at high altitude[J]. Transactions of China Electrotechnical Society, 2024, 39(3): 863-874.
- [23] 黄华, 姚嘉靖, 王永和, 等. 基于多通道一维卷积神经网络的刀具磨损动态预测模型[J]. 振动与冲击, 2023, 42(2): 60-67.
- HUANG Hua, YAO Jiajing, WANG Yonghe, et al. Dynamic prediction model for tool wear based on a multi-channel one-dimensional convolutional neural network[J]. Journal of Vibration and Shock, 2023, 42(2): 60-67.
- [24] 范兴明, 李涛, 张鑫. 基于电容自然充电换相的混合式直流断路器设计与仿真[J]. 电工技术学报, 2024, 39(11): 3510-3521.
- FAN Xingming, LI Tao, ZHANG Xin. Design and simulation of hybrid DC circuit breaker based on capacitor natural charging commutation[J]. Transactions of China Electrotechnical Society, 2024, 39(11): 3510-3521.
- 莫楚安(1998—), 男, 硕士研究生, 研究方向为断路器故障诊断与寿命评估(通信作者)(E-mail: 425926274@qq.com)。
- 童昕(1964—), 男, 教授, 博士, 博士生导师, 主要从事机电系统动态分析与控制、数字化分析与设计的研究(E-mail: xtong@fjut.edu.cn)。