

中文引用格式:姚俊名,梁伟,郑志明,等. 基于 VCW-Informer 的天然气压压缩机组监测数据预警方法[J]. 中国安全科学学报, 2025, 35(7): 167-175.

英文引用格式:YAO Junming, LIANG Wei, ZHENG Zhiming, et al. Monitoring data early warning method of natural gas compressor unit based on VCW-Informer[J]. China Safety Science Journal, 2025, 35(7): 167-175.

基于 VCW-Informer 的天然气压压缩机组 监测数据预警方法*

姚俊名^{1,2}, 梁伟^{**1,2}教授, 郑志明³, 黄天长^{1,2}, 付千郡^{1,2}, 廖春燕^{1,2}

(1 中国石油大学(北京)安全与海洋工程学院, 北京 102249; 2 应急管理部油气生产安全与应急技术重点实验室, 北京 102249; 3 中油国际管道有限公司, 北京 102249)

中图分类号: X937

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.07.0604

资助项目: 中国石油天然气集团有限公司合作项目(ZYQ-2023-HT-JS-17)。

【摘要】 为进一步提升天然气压压缩机组的早期异常预警能力, 基于变分模态分解(VMD)算法、Informer 算法、 3σ 准则判据与 Correlation-Weight 优化提出一个新的预警方法。基于 Informer 架构搭建预测模型, 利用 VMD 算法将监测数据分解为不同频率的多维尺度特征作为模型输入。在训练过程中, 计算各分量特征与原始信号的权重系数来优化调整模型内部参数。并利用预测重构结果与统计分析的 3σ 判据进一步提升预警性能。采集现场压缩机组 2 段正常与异常的压差监测数据进行实例验证, 试验结果表明: 相比于其他预测方法, 所提出的预警方法具有最小的预测误差, 正常箱体压差的预测结果同比降低 66.67%~71.43% (均方误差(MSE)), 36.67%~45.45% (平均绝对误差(MAE)), 40.17%~45.42% (均方根误差(RMSE)), 36.57%~45.72% (平均绝对百分比误差(MAPE)); 异常进气压差的预测结果同比降低 64.43%~71.12% (MSE), 44.02%~52.27% (MAE), 40.36%~45.53% (RMSE), 37.24%~47.79% (MAPE)。该方法在细节特征与趋势特征上具有更好的预测精度, 在测试集中能提前 60 min 时间为异常监测信号提供预警, 从而提升机组安全稳定运行的可靠性。

【关键词】 变分相关性权重优化 Informer (VCW-Informer); 天然气压压缩机; 监测数据; 异常预警; 深度学习; 信号分解

Monitoring data early warning method of natural gas compressor unit based on VCW-Informer

YAO Junming^{1,2}, LIANG Wei^{1,2}, ZHENG Zhiming³, HUANG Tianchang^{1,2},
FU Qianjun^{1,2}, LIAO Chunyan^{1,2}

(1 College of Safety and Ocean Engineering, China University of Petroleum (Beijing), Beijing 102249, China;
2 Key Laboratory of Oil and Gas Safety and Emergency Technology, Ministry of Emergency Management,
Beijing 102249, China; 3 Sino-Pipeline International Company Limited (SPI), Beijing 102249, China)

Abstract: In order to further enhance the early abnormal warning capability of natural gas compressor

* 文章编号: 1003-3033(2025)07-0167-09; 收稿日期: 2025-03-14; 修稿日期: 2025-05-18

** 通信作者: 梁伟(1978—), 男, 陕西绥德人, 博士, 教授, 博士生导师, 主要从事油气生产安全监测与设备智能诊断、运维等方面的研究。
E-mail: tongxun_1978@126.com。

units, a novel method was proposed based on the VMD (Variational Mode Decomposition) algorithm, Informer algorithm, 3σ criterion, and Correlation-Weight optimization. A predictive model was constructed using the Informer architecture, in which the monitoring data were decomposed by VMD algorithm into multi-scale features of different frequencies to serve as model inputs. During the training process, the weight coefficients between each decomposed component and the original signal were calculated to optimize and adjust the internal model parameters. Furthermore, the prediction reconstruction results were combined with the 3σ statistical criterion to further improve the warning performance. Two segments of normal and abnormal pressure differential monitoring data from field compressor units were collected for experimental validation. The results show that, compared with other prediction methods, the proposed warning method achieves the lowest prediction errors. For the prediction of normal box pressure differentials, the errors are reduced by 66.67%–71.43% (Mean Squared Error, MSE), 36.67%–45.45% (Mean Absolute Error, MAE), 40.17%–45.42% (Root Mean Squared Error, RMSE), and 36.57%–45.72% (Mean Absolute Percentage Error, MAPE). For the abnormal inlet pressure differentials, the errors are reduced by 64.43%–71.12% (MSE), 44.02%–52.27% (MAE), 40.36%–45.53% (RMSE), and 37.24%–47.79% (MAPE). The proposed method exhibits superior prediction accuracy in both detailed and trend features. In the test set, it provides anomaly warning 60 minutes in advance, thereby improving the reliability of safe and stable operation of the compressor units.

Keywords: variational correlation-weight Informer (VCW-Informer); natural gas compressor; monitoring data; abnormal early warning; deep learning; signal decomposition

0 引言

随着我国能源结构的调整,天然气、氢能等重要清洁能源占比不断增加,长输管线作为主要的运输方式之一,其规模也在不断扩大^[1]。天然气压缩机组作为长输管线提高介质输送压力的关键设备,保证了整个管网的运输效率,但是机组一旦发生故障停机就容易造成巨大的生产安全事故^[2]。目前,机组内安装有温度、压力等状态监测传感器,其监测数值一旦高于设定阈值就会触发机组紧急停机。然而,当触发紧急停机机制时,机组可能已经造成了不可逆转的设备损坏,进而影响整个管网运输系统。因此,对于天然气压缩机组关键监测数据的早期异常预警至关重要。

机组监测数据的早期预警任务本质上是时间序列预测问题,其方法主要分为统计学方法和机器学习方法2大类。基于统计学的预测方法是依赖于时间序列数据的统计特性和模式来进行预测,主要包括自回归模型^[3]、移动平均模型与自回归积分滑动平均模型等^[4-5]。这类方法需要数据具有平稳性,对于数据的异常值比较敏感,适用于短期预测。基于机器学习的预测方法是将预测问题视为具有时变参数的标准回归问题,通过损失函数反向调整模型参数,最终得到时序预测模型。传统的机器学习模

型包括支持向量回归模型^[6]、全连接神经网络^[7]等。虽然这类模型具有较好的非线性拟合预测性能,但只考虑了当前时间的特征集合,无法获取时间序列数据中时间的依赖性,因此,对于时间序列的预测精度难以保证。

随着人工智能的快速发展,深度学习算法在多个领域展现出优秀的性能^[8-10],在时间序列预测任务中取得了重要突破。基于深度学习的预测方法通过构建深层网络结构,利用大量模型参数进行特征学习提升预测性能。常见模型包括循环神经网络 (Recurrent Neural Network, RNN)、长短时记忆神经网络 (Long Short-Term Memory, LSTM)、卷积神经网络 (Convolutional Neural Network, CNN)、Transformer 和 Informer 等,许多学者也开展了相关研究。如周锐等^[11]利用 CNN-LSTM 预测分析了燃气轮机燃烧室的监测数据来降低停机风险。袁镇华等^[12]利用注意力机制和蝴蝶算法优化了双向 LSTM,开展了离心式压缩机的故障预警研究。杨婷婷等^[13]基于 Transformer 架构开展了磨煤机早期故障的预警研究。张友等^[14]使用 Informer 模型预测设备健康指标的未来走势,实现了离心鼓风机的故障趋势预测。王振浩等^[15]利用集合经验模态分解优化预测模型的特征输入,进一步提高了深度学习模型的预测精度。这些研究分析表明:在复杂设备监测数据预测

中,虽然深度学习模型的预测性能要优于传统方法,但也存在 RNN 与 LSTM 这类结构计算复杂度大,训练与预测的时间成本高等局限性。而基于多头注意力机制的 Transformer 与 Informer 架构虽然减少了 RNN 结构的计算量,拥有更大的并行度,但对于非线性时间序列的细节特征预测仍然不足。同时,受机组设备的阈值报警停机限制,传统预测方法无法进一步提升早期异常预警的安全余量。

鉴于此,笔者拟提出一个新的天然气压缩机组早期异常预警方法 (Variational Correlation-Weight Informer, VCW-Informer)。利用变分模态分解 (Variational Mode Decomposition, VMD) 算法分解出不同尺度的模态分量作为模型多维特征输入,提出 Correlation-Weight 优化来改善传统预测模型在细节特征与趋势特征的预测性能,同时,引入 3σ 准则判据提升传统被动阈值报警的预警余量,以期进一步保障压缩机组安全稳定运行的可靠性。

1 监测数据预警基本算法

1.1 VMD

VMD 是由 DRAGOMIRETSKIY^[16] 于 2013 年提出的一种自适应、完全非递归的信号分解方法,如今已经被广泛用于信号分析、信号处理等领域^[17-19]。VMD 引入了惩罚因子和拉格朗日乘数,将约束变分问题转化为非约束变分问题,极大改善了传统经验模态分解 (Empirical Mode Decomposition, EMD) 存在的模态混叠现象^[20]。VMD 可把原始时序序列分解成多个本征模态函数 (Intrinsic Mode Functions, IMF),在压缩机组关键参数趋势预测中,多维 IMF 特征能够更加精确地预测重构出原始序列不同频率段的细节变化。

1.2 Informer

Informer 模型是由 ZHOU Haoyi 等^[21] 于 2021 年提出的,在不同领域的时间序列预测任务中有较好的表现。Informer 针对 Transformer 架构自注意力机制复杂度、堆叠层内存瓶颈与预测输出速度慢等局限性作出了针对性改进。如下式,Informer 提出一种稀疏概率自注意力机制,通过选取少数得分较高的点积对,将其他得分较低点积对忽略的思想,来降低传统 Transformer 架构中的时间复杂度和内存使用量。

$$M(\mathbf{q}_i, \mathbf{K}) = \ln \sum_{j=1}^{L_K} \exp\left(\frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{\mu}}\right) - \frac{1}{L_K} \sum_{j=1}^{L_K} \frac{\mathbf{q}_i \mathbf{k}_j^T}{\sqrt{\mu}} \quad (1)$$

式中: $\mathbf{q}_i$ 为查询向量 $\mathbf{Q}$ 的值; $\mathbf{k}_j$ 为键向量 $\mathbf{K}$ 的值; L_K 为 $\mathbf{K}$ 的数据长度; $\sqrt{\mu}$ 为尺度因子; $M(\mathbf{q}_i, \mathbf{K})$ 为 $\mathbf{q}_i$ 最高得分的稀疏量度。

$$A(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\bar{\mathbf{Q}}\mathbf{K}^T}{\sqrt{\mu}}\right) \mathbf{V} \quad (2)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询向量、键向量和值向量组成的矩阵; $\bar{\mathbf{Q}}$ 为一个与 $\mathbf{Q}$ 大小相同的稀疏矩阵; $\text{Softmax}()$ 为激活函数;

Informer 还引入自注意力蒸馏操作,特权化具有支配能力的优势特征,通过正则卷积和池化操作减少维度和网络参数量,如下式:

$$\mathbf{X}_{j+1}^T = \text{maxpool}(\text{ELU}(\text{conv1D}([\mathbf{X}_j^T]_{\text{AB}}))) \quad (3)$$

式中: $[\mathbf{X}_j^T]_{\text{AB}}$ 为注意力模块; $\text{Conv1D}()$ 为一维卷积运算; $\text{ELU}()$ 为激活函数; $\text{maxpool}()$ 为最大池化运算。

在 Decoder 中 Informer 构建生成式解码器,同样是由多头注意力层组成,通过一个向前过程来产生预测输出,只需一步便可生成全部预测序列,避免逐步预测造成的误差累计,缩短了预测时间,如下式:

$$\mathbf{X}_{\text{de}}^T = \text{Concat}(\mathbf{X}_{\text{te}}^T, \mathbf{X}_0^T) \in R^{(L_{\text{te}}+L_y) \cdot d_{\text{md}}} \quad (4)$$

式中: L_{te} 为起始序列长度; L_y 为目标序列的长度; d_{md} 为嵌入维度; $\mathbf{X}_{\text{te}}^T \in R^{(L_{\text{te}}+L_y) \cdot d_{\text{md}}}$ 为起始段; $\mathbf{X}_0^T \in R^{(L_{\text{te}}+L_y) \cdot d_{\text{md}}}$ 为目标序列的占位符。

2 基于 VCW-Informer 的机组监测数据预警方法

2.1 VMD 与数据处理

基于 VMD、Informer、 3σ 准则判据以及 Correlation-Weight 损失优化提出 VCW-Informer 预警方法,如图 1 所示。VCW-Informer 方法主要由数据处理、预测模型、训练优化和异常预警 4 个模块构成。数据处理模块是对原始采集的机组监测数据进行 VMD、预处理和数据集划分。首先,利用 VMD 算法分解原始监测数据,得到不同频率区间的 IMFs 与残差。VMD 过程中模态数 z 的选取会影响分解性能,数值过大容易造成过拟合、引入额外噪声降低重构信号质量;相反,数值过小会导致模态欠分解与信号信息丢失。在 VCW-Informer 预警方法中,基于压缩机组监测数据的分布特性、重构误差以及专家经验,选取 5 个模态数量,能够有效表示信号的主要频率成分。然后,将原始的一维机组监测数据分解为 5 个不同频段的模态分量与 1 个残差分量,来提高




图1 VCW-Informer 预警方法

Fig. 1 Framework of VCW-Informer early warning method

模型的特征输入质量。考虑到不同频段之间模态分量的数据尺度不同,归一化处理各个特征分量,消除不同分量之间尺度差异对训练过程的影响。最后,数据预处理后,将数据分割为训练集与测试集,训练集用于模型训练,测试集用于模型泛化能力验证。

2.2 Informer 预测模型

VCW-Informer 基于 Informer 架构搭建了预测模型。模型的编码器由 2 个多头离散自注意力机制与数据蒸馏模块构成,通过概率稀疏与特征蒸馏来提高模型的学习能力。模型的解码器由掩码多头离散自注意力机制、多头自注意力机制与全连接层构成。在预测过程中,通过掩码机制能够提升预测结果的因果性与关联性,确保每个预测步长仅依赖于历史信息,从而避免传统自回归模型常见的预测偏差。式(4)中,构建的生成式解码器通过起始段数据 $\mathbf{X}_{te}^T$ 的引导能够一次生成整个预测序列,从而提升模型的并行预测能力,减小逐步累积的预测误差与预测时长。模型的参数设置设定为:编码器输入长度为 96,解码器的 $\mathbf{X}_{te}^T$ 数据长度为 4,模型的预测长度为 16。

2.3 Correlation-Weight 优化

在模型训练过程中,针对不同模态函数对重构

信号局部精度的影响,提出 Correlation-Weight 优化项来约束模型损失函数。利用相关系数法将 VMD 得到不同本征模态函数与原始信号进行相关性分析,如下式:

$$r_z = \frac{\sum_{i=1}^n (\text{IMF}_i - \overline{\text{IMF}}) (X_i - \bar{X})}{\sqrt{\sum_{i=1}^n (\text{IMF}_i - \overline{\text{IMF}})^2} \sqrt{\sum_{i=1}^n (X_i - \bar{X})^2}} \quad (5)$$

式中: IMF_i , $\overline{\text{IMF}}$ 为各模态函数与其均值; X_i , $\bar{X}$ 为原始信号与其均值; n 为信号长度; z 为模态函数与残差的数量。

根据得到的各模态函数与残差相关系数计算出每个分量所占的相关性权重,优化整个预测模型的损失函数,如下式:

$$w_z = \frac{r_i}{\sum_{i=1}^z r_i} \times 100\% \quad (6)$$

式中 r_i 为各模态函数与残差对应的相关系数值。

原始 Informer 预测模型的损失函数是由预测分量与真实分量计算的均方误差 (Mean Square Error, MSE) 构成,无法在模型训练过程中考虑到不同分量之间对于重构信号的贡献。因此,Correlation-Weight

优化项基于每个模态分量的相关性权重来自适应分配 MSE 损失函数占比,从而提高细节特征预测精度。同时,引入趋势相关性损失函数优化预测信号的趋势特征,如下式:

$$\text{Loss_MSE}_z = \frac{1}{n} \sum_{i=1}^n (\text{IMF}_i^p - \text{IMF}_i^o)^2 \quad (7)$$

$$\text{Loss_r}_z = \frac{\sum_{i=1}^n (\text{IMF}_i^p - \overline{\text{IMF}_i^p}) (\text{IMF}_i^o - \overline{\text{IMF}_i^o})}{\sqrt{\sum_{i=1}^n (\text{IMF}_i^p - \overline{\text{IMF}_i^p})^2} \sqrt{\sum_{i=1}^n (\text{IMF}_i^o - \overline{\text{IMF}_i^o})^2}} \quad (8)$$

式中: IMF_i^p 为预测的模态分量; IMF_i^o 为真实的模态分量; Loss_MSE 为均方误差损失函数; Loss_r 为趋势相关性损失函数。

Correlation-Weight 优化项的总损失函数如下式,通过趋势损失函数与相关性权重分配提高预测模型在细节特征与趋势特征的学习能力。

$$\text{Loss} = \sum_{i=1}^z (w_i \times \text{Loss_MSE}_i + \rho \times \text{Loss_r}_i) \quad (9)$$

式中: w_i 为计算出来的相关性权重; ρ 为尺度优化因子,常数值文中设定为 0.2。

2.4 3 σ 异常预警

考虑到传统机组监测信号超阈值报警的被动迟滞性,引入 3 σ 准则判据重新构建预警策略。3 σ 准则判据是基于正态分布的数理统计分析,通过数据的均值、标准差,找出偏离正常数据 99.7% 的数据点。在异常预警模块,基于机组历年来正常的历史运行数据统计分析出 3 σ 界限值,划分出 3 σ 准则判据。利用预训练模型预测出各个监测信号模态分量与方差,重构还原出真实尺度下的预测结果。再利用 3 σ 准则判据进行预警判定,从而实现早期机组异常状态的报警。

3 机组预警实例验证分析

3.1 数据采集与划分

在实例验证环节中,采集某天然气长输管线中在役压缩机组的运行数据进行验证分析。压差信号作为天然气压缩机组运行过程中的一个重要监测参数,能够反映压缩机内部的压力、流速与流量的变化,进而反应机组的运行效率与故障状态。采集箱体压差与进气压差 2 个关键的压力监测指标进行验证分析。其中,进气压差传感器的监测数据由于机

组发生故障导致出现超阈值报警停机,而箱体压差传感器为正常段数据,进行对比试验。在数据采集过程中,按照每分钟一个点的采样频率采集 2 组监测数据。在机组停机前后共采集 2 389 个点,其中,将最后的 389 个点划分为测试集,前 2 000 个点划分为训练集。

3.2 信号分解与权重计算

利用 VMD 算法分解原始信号,2 组压差监测数据的分解结果如图 2 和图 3 所示。从图 2 中可以看出,正常箱体压差信号分解的变分模态分量 IMF1—IMF4 频率较高,能够分解出监测信号的细节特征。而 IMF5 的频率与波动性较低,但是振幅相对较大,能够分解出信号的整体趋势特征。残差表示原始信号与 IMFs 重构信号之间的差异。正常箱体压差信号分解出的残差值小,表明 VMD 算法与所选取的模态数量具有较好的特征分解性能。从图 3 可以看出,异常进气压差的高频模态分量只集中在 IMF1 与 IMF2,而 IMF3—IMF5 的频率低、幅值变化大,并且在原始信号振荡区域的残差值也明显高于平稳段。这是由于压缩机组进气段异常,监测数据幅值变化明显,具有较大的信号趋势。因此,在 VMD 信号分解过程中,异常信号的低频趋势分量相较于平稳正常信号占比更大,也侧面验证了 VMD 算法在不同类别信号中都具备优秀的特征分解性能。




图 2 箱体压差 VMD 结果

Fig. 2 VMD decomposition of box pressure difference

为改善不同频段 IMFs 与 Residual 对信号细节特征与趋势特征的重构影响,利用所提出的 Correlation-Weight 优化项约束 VCW-Informer 的训练过程。如式(5)、式(6),利用 VMD 结果计算出各个模态分量与原始信号的权重优化系数。权重优化系数分布如图 4 所示。正常信号的相关性权重分布较为均衡,而对于异常信号,IMF3—IMF5 趋势模态分量的权重远远大于其他几个分量。通过权重优化系




图3 进气压差 VMD 结果

Fig. 3 VMD decomposition of inlet filter difference

数的对比分析表明:在模型训练过程中,不同模态分量的权重分配对于预测信号的趋势特征与细节特征十分重要。




图4 权重优化系数分布

Fig. 4 Weight optimization coefficient distribution

3.3 模型训练与测试

归一化处理监测信号分解出的模态分量,作为预测模型的标准多维特征输入。利用训练集训练预测模型,训练环境与训练参数为:Python 3.9;Pytorch 2.0;Adam 优化器;Batchsize 为 32;训练次数为 25。在训练过程中,利用计算得到的权重优化系数与趋势相关性损失构建 Correlation-Weight 优化。如式(9)所示,计算出优化过后的对抗损失函数 Loss 反向梯度传播,更新预测模型的全局参数。模型训练完成后,利用测试集验证分析预测模型,2 组压差监测数据的测试结果如图 5 和图 6 所示。

选取 MSE、平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Squared Error, RMSE)、平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 这 4 个定量指标评价测试结果。其中,箱体压差这组正常监测信号的定量评价结果为 MSE: 0.000 2, MAE: 0.011 4, RMSE: 0.014 3, MAPE: 1.398 2。从图 5 可以看出,箱体压




图5 箱体压差预测结果

Fig. 5 Box pressure difference prediction results




图6 进气压差预测结果

Fig. 6 Inlet filter difference prediction results

差的预测结果精确,能够准确预测出较高的振荡频率,同时,有效还原了监测信号的细节特征。进气压差这组异常信号的定量评价结果为 MSE:0.651 7, MAE:0.607 6, RMSE:0.807 3, MAPE:7.308 2。从图 6 可以看出,所提出的优化模型在异常信号的预测中也有较好的表现,能够准确预测出整体的异常趋势。测试集的验证结果表明:所提出的 VCW-Informer 预警方法在高频率与高振幅的 2 种压缩机组监测数据中都有优秀的预测性能。

3.4 异常预警分析

基于 VCW-Informer 的预测结果,开展压缩机组异常预警分析。基于大量压缩机组历史运行数据统计分析出 2 组压差监测数据的均值、标准差,计算出 3σ 判据的上下判别界限。将计算得到的 3σ 判据反演到预测结果中,如图 5 与图 6 的 3σ 判据虚线所示。从图 5 可以看出,正常的箱体压差在预测结果中也始终收敛于 3σ 判据界限中。从图 6 可以看出, 3σ 判据能够从机组历史运行大数据的角度提供一个主动反应区域。相比于传统的被动超阈值停机, 3σ 判据的主动反映区域能够提前 44 min 为机组异常状态提供预警,给现场的工程师提供充足的主动停机检查时间。另外,所提出预警方法的 16 min 预测时长,能够进一步给异常监测信号提供一个预测缓冲区

域。因此,所提出来的 VCW-Informer 预警方法能够将预警时间提前到 60 min,能够为天然气压缩机组监测信号的异常状态提供早期预警,避免机组随着运行时间的延长故障不断扩大。将被动的超阈值停机机制进一步改善为基于实时预测结果的主动停机预防模式,提升了机组的安全稳定运行的可靠性。

4 机组预警方法对比分析

横向对比 Informer、LSTM 与双向 LSTM (Bidirectional LSTM, Bi-LSTM) 模型。在相同条件

下,利用 2 组压差数据分别训练与验证每个对比模型,对比结果见表 1。首先,对比分析箱体压差正常段监测数据,各模型的预测结果如图 7 所示。从图 7 中可以看出,VCW-Informer 方法基于 Correlation-Weight 优化能够准确预测出振荡信号的细节特征,表现出最好的预测性能。定量的对比结果表明:VCW-Informer 具有最小的预测误差,相比于传统的预测模型,MSE 下降 66.67%~71.43%,MAE 下降 36.67%~45.45%,RMSE 下降 40.17%~45.42%,MAPE 下降 36.57%~45.72%。

表 1 不同方法的预测评价结果

Table 1 Prediction evaluation results of different models

监测数据	对比方法	MSE	MAE	RMSE	MAPE
箱体压差	VCW-Informer	0.000 2	0.011 4	0.014 3	1.398 2
	Informer	0.000 6	0.018 0	0.023 9	2.204 3
	LSTM	0.000 7	0.020 9	0.026 2	2.575 7
	Bi-LSTM	0.000 6	0.018 6	0.024 9	2.266 1
进气压差	VCW-Informer	0.651 7	0.607 6	0.807 3	7.308 2
	Informer	1.832 4	1.273 1	1.353 7	16.438
	LSTM	2.256 5	1.085 3	1.502 2	11.645
	Bi-LSTM	2.196 6	1.087 9	1.482 1	13.998




图 7 箱体压差预测对比

Fig. 7 Box pressure difference prediction comparison

对比分析异常进气压差信号的预测表现,如图 8 所示。VCW-Informer 方法在 Correlation-Weight 优化项约束下,在兼顾细节特征的同时能够有效捕获长时间序列的趋势特征,具有最好的预测精度。定量评价结果表明:VCW-Informer 在异常信号预测中仍然具有最小的预测误差。相比于传统的预测方法,VCW-Informer 方法的 MSE 同比下降 64.43%~71.12%,MAE 下降 44.02%~52.27%,RMSE 下降 40.36%~45.53%,MAPE 下降 37.24%~47.79%。进一步验证了 VCW-Informer 方法在天然气压缩机

组关键指标预测中具有更好的性能,相比于传统方法在高频振荡幅值重构、细节特征还原与异常趋势预测上都有更好的表现。




图 8 进气压差预测对比

Fig. 8 Inlet filter pressure difference prediction comparison

5 结 论

1) 针对天然气压缩机组提出一个新的 VCW-Informer 异常预警方法,通过 2 组压差信号的验证结果表明:VCW-Informer 方法能够准确预测出信号的异常状态。可提前 60 min 预警,将传统的被动超

阈值停机机制改善为基于实时预测结果的主动停机预防模式,为现场工程师的响应处理提供充足时间,从而提升机组安全稳定运行的可靠性。

2) Correlation-Weight 优化改善了多维尺度特征对于预测重构信号的影响,提高了细节特征与趋势特征的预测精度。同时,结合基于历史运行大数据统计分析出来的 3σ 判据,能够有效延长主动反应时间,提升预警的性能。

3) 在实例验证中,相比于传统预测方法,VCW-Informer 方法具有最小的预测误差。正常箱体压差的预测结果同比降低 66.67% ~ 71.43% (MSE), 36.67% ~ 45.45% (MAE), 40.17% ~ 45.42% (RMSE), 36.57% ~ 45.72% (MAPE)。异常进气压差的预测结果同比降低 64.43% ~ 71.12% (MSE), 44.02% ~ 52.27% (MAE), 40.36% ~ 45.53% (RMSE), 37.24% ~ 47.79% (MAPE)

参考文献

[1] 高振宇, 张慧宇, 高鹏. 2022 年中国油气管道建设新进展[J]. 国际石油经济, 2023, 31(3): 16-23.
GAO Zhenyu, ZHANG Huiyu, GAO Peng. New progress in China's oil and gas pipeline construction in 2022[J]. International Petroleum Economics, 2023, 31(3): 16-23.

[2] ZHOU Dengji, HUANG Dawen, HAO Jiarui, et al. Vibration-based fault diagnosis of the natural gas compressor using adaptive stochastic resonance realized by generative adversarial networks[J]. Engineering Failure Analysis, 2020, 116: DOI: 10.1016/j.engfailanal.2020.104759.

[3] 李鑫, 卢灿铭, 左洪福, 等. 自回归和 EWMA 在齿轮箱早期异常检测中的应用[J]. 机械设计与制造, 2024(8): 63-66.
LI Xin, LU Canming, ZUO Hongfu, et al. Early fault diagnosis of gearbox based on autoregression and EWMA[J]. Machinery Design & Manufacture, 2024(8): 63-66.

[4] JIN Yongchao, WANG Renfang, ZHUANG Xiaodie, et al. Prediction of COVID-19 data using an ARIMA-LSTM hybrid forecast model[J]. Mathematics, 2022, 10(21): DOI: 10.3390/math10214001.

[5] SINGH S, MOHAPATRA A. Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting[J]. Renewable Energy, 2019, 136: 758-768.

[6] 古莹奎, 汪源金, 石昌武. 基于 EWM 和 SVR 的滚动轴承剩余使用寿命预测方法[J]. 中国安全科学学报, 2023, 33(9): 49-55.
GU Yingkui, WANG Yuanjin, SHI Changwu. Remaining useful life prediction method of rolling bearing based on EWM and SVR[J]. China Safety Science Journal, 2023, 33(9): 49-55.

[7] 吴小忠, 肖立华, 童超, 等. 基于传递熵与 JS-BP 神经网络的锂离子电池容量预测模型[J]. 中国电力, 2025, 58(2): 186-192.
WU Xiaozhong, XIAO Lihua, TONG Chao, et al. Capacity prediction model of lithium-ion batteries based on transfer entropy and JS-BP neural network[J]. Electric Power, 2025, 58(2): 186-192.

[8] YAO Junming, LIANG Wei, XIONG Jingyi. Novel intelligent diagnosis method of oil and gas pipeline defects with transfer deep learning and feature fusion[J]. International Journal of Pressure Vessels and Piping, 2022, 200: DOI: 10.1016/j.ijpvp.2022.104781.

[9] 林青, 姚俊名, 梁伟, 等. 基于深度学习的燃气发电机组剩余寿命预测[J]. 中国安全科学学报, 2023, 33(9): 113-121.
LIN Qing, YAO Junming, LIANG Wei, et al. Residual life prediction of gas generator set based on deep learning[J]. China Safety Science Journal, 2023, 33(9): 113-121.

[10] 黄迅迪, 庞雄文. 基于深度学习的智能设备故障诊断研究综述[J]. 计算机科学, 2023, 50(5): 93-102.
HUANG Xundi, PANG Xiongwen. Review of intelligent device fault diagnosis based on deep learning[J]. Computer Science, 2023, 50(5): 93-102.

[11] 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 Yingwei. Fault warning of gas turbine combustor based on CNN-LSTM[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39(1): 191-197.

- [12] 袁镇华, 茅大钧, 李玉珍. 基于注意力机制与 XBOA-Bi-LSTM 的离心式压缩机故障预警方法[J]. 机电工程, 2024, 41(3): 400-408.
- YUAN Zhenhua, MAO Dajun, LI Yuzhen. Centrifugal compressor fault warning method based on attention mechanism and XBOA-Bi-LSTM[J]. Journal of Mechanical & Electrical Engineering, 2024, 41(3): 400-408.
- [13] 杨婷婷, 李浩干, 陈晓峰, 等. 基于 WPT-Transformer 的磨煤机故障预警研究[J]. 热力发电, 2023, 52(12): 180-189.
- YANG Tingting, LI Haoqian, CHEN Xiaofeng, et al. Research on fault early warning of coal mill based on WPT and Transformer[J]. Thermal Power Generation, 2023, 52(12): 180-189.
- [14] 张友, 李聪波, 林利红, 等. 数据不完备下基于 Informer 的离心鼓风机故障趋势预测方法[J]. 计算机集成制造系统, 2023, 29(1): 133-145.
- ZHANG You, LI Congbo, LIN Lihong, et al. Centrifugal blower fault trend prediction method based on Informer with incomplete data[J]. Computer Integrated Manufacturing Systems, 2023, 29(1): 133-145.
- [15] 王振浩, 王翀, 成龙, 等. 基于集合经验模态分解和深度学习的光伏功率组合预测[J]. 高电压技术, 2022, 48(10): 4133-4142.
- WANG Zhenhao, WANG Chong, CHENG Long, et al. Photovoltaic power combined prediction based on ensemble empirical mode decomposition and deep learning[J]. High Voltage Engineering, 2022, 48(10): 4133-4142.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [17] 代巍, 付华, 冀常鹏, 等. 回采工作面瓦斯涌出量 VMD-DE-RVM 区间预测方法[J]. 中国安全科学学报, 2018, 28(9): 109-115.
- DAI Wei, FU Hua, JI Changpeng, et al. Interval prediction method for gas emission from coal mining face based on VMD-DE-RVM[J]. China Safety Science Journal, 2018, 28(9): 109-115.
- [18] ZHANG Pengfei, GAO Dong, LU Yong, et al. Online chatter detection in milling process based on fast iterative VMD and energy ratio difference[J]. Measurement, 2022, 194: DOI: 10.1016/j.measurement.2022.111060.
- [19] 江星星, 宋秋昱, 杜贵府, 等. 变分模式分解方法研究与应用综述[J]. 仪器仪表学报, 2023, 44(1): 55-73.
- JIANG Xingxing, SONG Qiuyu, DU Guifu, et al. Review on research and application of variational mode decomposition[J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 55-73.
- [20] 刘丽桑, 郭凯琪, 徐哲壮, 等. 基于数据挖掘的双模式组合光伏功率日前预测[J]. 武汉大学学报:工学版, 2024, 57(10): 1459-1468.
- LIU Lisang, GUO Kaiqi, XU Zhezhuang, et al. Day-ahead prediction of dual-mode combined photovoltaic power based on data mining[J]. Engineering Journal of Wuhan University, 2024, 57(10): 1459-1468.
- [21] ZHOU Haoyi, ZHANG Shanghang, PENG Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 11106-11115.

作者简介: 姚俊名 (2000—),男,重庆人,博士研究生,主要研究方向为油气设备安全检测与智能诊断、人工智能算法。E-mail: 2022310517@student.cup.edu.cn。