



DOI:10.12404/j.issn.1671-1815.2507459

引用格式:李昀泰,张忠民.基于小波变换与特征卷积的燃气轮机氮氧化物两阶段预测模型[J].科学技术与工程,2026,26(27):11822-11829.

Li Yuntai, Zhang Zhongmin. Two-stage prediction model for nitrogen oxides in gas turbines based on wavelet transform and feature convolution [J]. Science Technology and Engineering, 2026, 26(27): 11822-11829.

基于小波变换与特征卷积的燃气轮机氮氧化物 两阶段预测模型

李昀泰, 张忠民*

(哈尔滨工程大学信息与通信工程学院, 哈尔滨 150001)

摘要 为解决燃气轮机在恶劣环境下性能参数测量存在传感器部署困难、易损坏的问题,本文采用深度神经网络搭建预测模型,对反映燃气轮机运行效果与运行模式的氮氧化物浓度进行预测,所设计的预测模型结合了两个阶段的处理:第一阶段通过多尺度融合完成整体趋势预测,第二阶段采用小波变换与特征卷积提取完成细节信息预测。实验结果表明:该两阶段模型预测结果的平均绝对误差(mean absolute error, MAE)为 0.681,均方根误差(root mean square error, RMSE)为 0.995,证明该方法可以有效识别燃气轮机的运行模式以及恶劣环境下的数据波动,能够实现氮氧化物排放浓度的准确预测。

关键词 燃气轮机; 氮氧化物预测; 小波变换; 特征提取

中图分类号 TP391; **文献标志码** A

Two-stage Prediction Model for Nitrogen Oxides in Gas Turbines Based on Wavelet Transform and Feature Convolution

LI Yun-tai, ZHANG Zhong-min*

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

[Abstract] In order to address the challenges of sensor deployment and vulnerability in harsh gas turbine environments, a predictive model based on deep neural networks was developed. The model forecasts nitrogen oxide concentrations, which reflect operational performance and modes. A first-stage multi-scale fusion approach was integrated for overall trend prediction. A second-stage design using wavelet transforms and feature convolution was employed for detailed information prediction. The results show that the two-stage model achieves a mean absolute error of 0.681 and a root mean square error of 0.995. This demonstrates the model's ability to identify operational patterns of gas turbines. It also captures data fluctuations under adverse conditions. Therefore, the model accurately predicts nitrogen oxide emission concentrations.

[Keywords] gas turbine; nitrogen oxide prediction; wavelet transform; feature convolution

燃气轮机作为一种典型的常规燃料动力装置,具备功率密度大、使用寿命长、启动速度快等优势,凭借优异性能被广泛应用于航空航天、电力、船舶、天然气输送等工业核心领域^[1]。燃气轮机往往长期工作在高温、温度骤变的恶劣环境中,这会导致其内部传感器逐步退化,甚至完全失效;同时燃气轮机通常需要持续长时间运行,传感器故障会对设备整体运行策略造成严重影响。氮氧化物(NO_x)是燃气轮机排放的主要污染气体,其生成量与燃气轮机的运行状态和工作效率直接相关,同时它会引发

光化学烟雾、酸雨、对流层臭氧污染、臭氧层破坏,甚至加剧全球变暖等环境问题,高浓度的氮氧化物还会危害人体健康^[2]。目前各国已出台严格的燃气轮机污染物排放法规,通过预测排放数据的方式,可以为降低环境污染、制定干预调控策略提供数据支撑;同时,无需依赖恶劣工况下的传感器,不仅能节省传感器更换带来的人力物力成本,减少发电厂等长周期运行设施的紧急运维频次,还能有效降低此类场景引发的数据异常问题。

近年来,燃气轮机排放预测相关方法的研究不

收稿日期: 2025-10-27 修订日期: 2026-01-05

基金项目: 中央高校基本科研业务费“新方向培育专项计划”(3072024XX0807)

第一作者: 李昀泰(2001—),男,汉族,吉林长春人,硕士研究生。研究方向:深度学习。E-mail: lyt200101071@163.com。

* 通信作者: 张忠民(1972—),男,回族,黑龙江哈尔滨人,博士,副教授。研究方向:图像处理、深度学习。E-mail: zhangzhongmin@hrbeu.edu.cn。

投稿网址: www.stae.com.cn

断丰富。神经网络、遗传算法、模糊逻辑等软计算方法能够适配燃气轮机的非线性与动态特性,为排放预测任务提供了有效工具^[3]。传统建模方法依赖物理模型与统计方法适配特定场景,已有研究采用线性回归、非线性回归、单参数双指数平滑、卡尔曼滤波以及贝叶斯预测方法对涡轮排气温度进行预测^[4-5]。Vipul 等^[6]采用自回归分数积分移动平均和广义自回归条件异方差模型拟合残差过程,以多阶段向量自回归的形式应对温度突变趋势,显著提升了预测效果。但受模型复杂度与数据规模限制,这类方法无法广泛推广适配其他类型设备。机器学习模型可处理复杂非线性关系与高维数据,为提升排放气体预测的准确性与稳定性,Chen 等^[7]使用灰狼优化算法(grey wolf optimizer, GWO)优化了极端梯度提升(extreme gradient boosting, XGBoost)模型。向彬彬^[8]使用遗传算法(genetic algorithm, GA)优化支持向量机(support vector machines, SVM)的超参数,将二者结合构建了集成预测模型。Rezazadeh^[9]使用 K 近邻算法(K nearest neighbors, KNN)结合主成分分析(principal components analysis, PCA)完成预测任务。Kaya 等^[10]以极限学习机(extreme learning machine, ELM)作为基础学习器,通过实验对比平均法、随机森林(random forest, RF)和 ELM 作为元学习器的预测效果,实现了预测性能的提升。

深度学习在处理非平稳性、季节性、多变量、异构时间序列数据时能够实现较高预测精度,且可以充分挖掘历史数据中的特征信息,具备良好的泛化能力。李耀华等^[11]通过双向时间卷积网络和多头注意力机制增强特征交互能力,实现特征权重的自适应分配,提升了预测任务的精度。Guo 等^[12]先使用奇异谱分析(singular spectral analysis, SSA)去除数据噪声,再使用轻量级梯度提升机算法(light gradient boosting machine, LightGBM)完成特征选择,最终采用双注意力长短期记忆模型(dual-stage attention-based long short term memory, DA-LSTM)进行预测。Li 等^[13]对 Transformer 网络的编码器骨干结构进行改进,引入因果卷积模块优化编码器性能,实现了更精准的时间序列模式识别,提升了预测准确度。Su 等^[14]基于 Transformer 改进得到 Informer 模型,结合基于密度的噪声应用空间聚类(density-based spatial clustering of applications with noise, DBSCAN)、Savitzky-Golay 滤波器和多层残差网络(multi-layer residual networks, M-ResNet)进行时间序列分析预测。Feng 等^[15]将小波变换用作编码器和解码器,对数据的近似系数和细节系数进行分

解,该方法在多个开源数据集上取得了优秀的预测效果,证明了时间序列分解在数据分析中的重要作用。钟松浩等^[16]将门控循环单元嵌入混合图卷积网络处理时间序列矩阵,在多个开源数据集上也取得了较好的预测效果。

燃气轮机参数预测需要考虑诸多因素,实验数据通常来自机组实际运行过程,会受到传感器精度、环境及噪声等因素的干扰。在长期高强度运行条件下,人为操作与环境波动还会进一步引发数据波动,产生噪声与异常值,提高了数据的复杂程度,导致传统预测模型的输出结果精度下降。燃气轮机的运行状态随运行模式变化呈现出非平稳性与不规则性,但仍然具备明确的长期趋势与周期特征。只有采用能够合理提取并利用这些特征,且可以学习时间序列复杂时间依赖关系的模型,才能解决燃气轮机排放预测中,数据数值剧烈波动导致预测准确性较差的问题。因此提出一个两阶段模型,实现对 NO_x 的时间序列预测,该模型的主要特点如下。

(1) 基于分离趋势信息与细节信息的思路设计两阶段模型,两个阶段的模型参数分别训练,避免模型向单一阶段的特征偏倚。第一阶段模型通过分析利用多变量数据集的多尺度趋势信息与季节信息,并引入注意力机制,使融合后的预测结果更贴合数据的整体趋势,逼近真实预测结果。

(2) 针对第一阶段的输出结果,使用 Haar 小波变换分析数据集的细节特征,再采用简化的 Inception 结构提取细节特征,放大局部信息对预测结果的影响,同时模型可以基于历史趋势对当前时间步的影响学习数据波动规律,以此适配剧烈的数据变化,实现精准预测。

1 一阶段多尺度融合预测模型

两阶段模型的构建思路源于指数平滑的处理形式,将时间序列细节波动变化与其运行模式和环境影响所形成的整体趋势加权相加,具体实现为一阶段以预测整体模式为主,设计了加入注意力机制的多尺度时间序列融合模型。

该部分使用 TimeMixer 模型^[17]为主体,分为过去分解融合和未来预测融合。

分析时间序列通常将其分解为趋势项和季节项,对于输入时间序列,采用下采样的方式划分为一组多尺度的时间序列,每个尺度的时间序列被分解为趋势项和季节项,采用 Autoformer^[18]中的移动平均思想。通过平滑季节项来突出趋势项,通过去除序列中的趋势部分来得到季节项。过程可表示为

$$X_t = \text{AvgPool}[\text{Padding}(X)] \quad (1)$$

$$X_s = X - X_t \quad (2)$$

式中: X_t 、 X_s 和 X 分别为时间序列分解出的趋势项、季节项和原始数据。

季节项中较大的周期可以看作是较小周期的聚合。因此,在如图 1(a)所示的季节项中,可以使用自下而上的方法,将时间序列的季节项信息向上整合,从而为高尺度的季节项补充信息。与季节项部分相反,在捕捉宏观趋势时,细节变化更加重要。较高尺度的时间序列相比较低尺度,能提供更有用的趋势信息。因此,在如图 1(b)所示的趋势项中采




图1 季节项混合和趋势项混合

Fig. 1 Bottom-up-mixing of seasonal and top-down-mixing of trend

用了自上而下的混合方法。上述两种互补方法的结构均为线性层-高斯误差线性单元激活函数(gaussian error linear unit, GeLU)-线性层。

燃气轮机的运行模式与排放浓度之间存在强烈的因果关系。在运行过程中,环境因素也会影响运行性能。季节性变化会影响温度、湿度等参数,从而影响结果,其中季节项成分是这些波动的总体表现。利用这一特性,选用注意力机制对趋势成分应用季节项标签进行加权,从而提升模型的输出效果。该部分采用的是缩放点积注意力机制,具体表达式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (3)$$

式(3)中: $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 分别为查询矩阵、键矩阵和值矩阵; d 为键向量维度。引入 d 是为了在计算时避免因键向量长度较大而导致的梯度消失或爆炸问题,从而保证训练的稳定性。

不同尺度上的信息表现出不同的预测能力。因此,对每个尺度分别进行预测。采用线性层将多尺度信息投影回原始序列长度。然后通过叠加对预测结果进行信息验证。一阶段模型整体如图 2 所示。

2 二阶段细节特征预测模型

本节介绍以小波变换和特征卷积为核心的模型,该模型主要捕捉输入多变量时间序列中的局部特征,以优化 TimeMixer 模型的输出。

Haar 小波变换是一种经典的小波分析方法,由匈牙利数学家阿尔弗雷德·哈尔(Alfred Haar)于 1909 年提出。该方法通过多分辨率分析将信号分解为不同尺度的近似分量和细节分量,并广泛应用于信号处理、图像压缩等领域。对于时间 t 而言,Haar 小波变换的母小波函数为

$$\psi(t) = \begin{cases} 1, & 0 \leq t < 0.5 \\ -1, & 0.5 \leq t < 1 \\ 0, & \text{其他} \end{cases} \quad (4)$$

尺度函数为

$$\varphi(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{其他} \end{cases} \quad (5)$$

将其应用于处理时间序列的离散 Haar 小波变换,将一维信号分解为近似系数 a_k 和细节系数 d_k 。表达式为

$$a_k = \frac{x_{2k-1} + x_{2k}}{\sqrt{2}}, \quad k \geq 1 \quad (6)$$

$$d_k = \frac{x_{2k-1} - x_{2k}}{\sqrt{2}}, \quad k \geq 1 \quad (7)$$




图2 添加注意力机制的TimeMixer模型

Fig. 2 TimeMixer model with attention mechanism

式中: x 为输入数据; k 为时间步。

二阶段模型注重一阶段采样和池化过程中消耗掉的细节信息,而 Haar 小波变换通过计算相邻数据间的差值,有效提高了模型对数据间累积效果的识别,为后续的特征提取提供更清晰的信息,实现形式是通过使用卷积核尺寸为 2 的卷积层来设置内部权重,根据通道将其划分为高通 ($1/\sqrt{2}, -1/\sqrt{2}$) 和低通 ($1/\sqrt{2}, 1/\sqrt{2}$) 卷积核。

Inception^[19]是由谷歌团队提出的,旨在通过高效的模块化结构提高模型的性能并降低计算成本。其核心是通过多尺度并行卷积操作提取特征,并通过降维技术优化计算效率。Inception 模块主要将不同的卷积层并行组合,以高效地扩展网络的深度和宽度,从而提高深度学习网络的效果并防止过拟合的发生。对于本文所设计的模型,通过小波变换所扩展的特征信息需要使用合理的提取方法,因为细节信息是多种参数变化所形成的最终结果,所以用多种卷积层去提取特征能够很好地识别不同特征,而这种特征信息如果利用残差连接的方式处理,很有可能会被原始信息削弱,所以对现有的模型进行优化,去掉了卷积核为 1 的冗余连接,同时,在连接层中添加了一个线性层。这部分如图 3 所示。

经过小波变换后的特征被输入到简化的 Inception 中进行特征提取,并结合第一阶段的结果进行线性预测。这一部分由两层线性层组成,并加入了线性整流函数(rectified linear unit, ReLU)和 Drop-out 以提高模型的泛化能力。该阶段模型的主要目的是通过对数据集的二次利用,捕捉并放大数据集中包含的特征信息。通过这种方式,第一阶段的预测结果得到修正,从而获得更准确的预测。融合注意力机制的 TimeMixer 模型作为第一阶段模型,其与第二阶段模型共享部分参数,包括数据集划分、批量大小和输入序列长度。第二阶段模型独立于第




图3 简化 Inception 模块

Fig. 3 Simplified Inception module

一阶段模型进行训练,两者之间仅保持数据传递关系。在两阶段训练过程中,第二阶段仅使用第一阶段训练中对应当前时间步及历史时间步的输出作为输入,从而严格防止数据泄露。最终模型如图 4 所示。

3 数据集和实验结果

在本文中,使用了来自 UCI 数据库的位于土耳其西北部的联合循环电厂燃气轮机的数据作为实验数据集。数据收集涵盖了部分负荷(75%)到满负荷(100%)的运行范围。数据集包含 36 733 个实例,每个实例包括从 2011—2015 年平均或汇总的 11 个传感器测量值,除了环境变量如温度、湿度和压力。数据集还包括 9 个输入变量,如涡轮发电功率、压缩机排气压力等。如表 1 所示为每个变量及相关的统计信息。该数据集是燃气轮机的实际运行数据,机器的维护情况未知,存在由特定事件或机器异常运行引起的异常数据值。并且随着机器的运行,由于内部设备的损耗,机器的运行效果可能会发生变化,使预测更加困难。数据集中不包含缺失值,因此使用了奇异谱分析的方法对数据集进行清洗,选取了占比最大的 7 个分析结果,将数值约




图4 细节特征提取模型

Fig. 4 Detail feature extraction model

表1 数据集参数和统计

Table 1 Dataset parameters and statistics

变量	最小值	最大值	平均值
环境温度(AT)/℃	-6.23	37.10	17.71
环境压力(AP)/mbar	985.85	1 036.56	1 013.07
环境湿度(AH)/%	24.08	100.20	77.87
空气过滤器压差(AFD)/mbar	2.09	7.61	3.93
燃气轮机排气压力(GTEP)/mbar	17.70	40.72	25.56
涡轮机入口温度(TIT)/℃	1 000.85	1 100.89	1 081.43
涡轮机后温度(TAT)/℃	511.04	550.61	546.16
压缩机排气压力(CDP)/mbar	9.85	15.16	12.06
涡轮机发电量(TEY)/MWh	100.02	179.50	133.51
一氧化碳(CO)/(mg·m ⁻³)	0.00	44.10	2.37
氮氧化物(NO _x)/(mg·m ⁻³)	25.90	119.91	65.29

注:1 mbar = 100 Pa。

为原有数据 95% 的处理结果作为输入数据,以降低异常数据对预测任务的影响。

本实验主要针对 NO_x 预测,因此作为废气成分的 CO 特征已被剔除。数据集按 3:1:1 的比例划分为训练集、验证集和测试集,输入时间序列批次大小设置为 32,输入长度为 24 个时间步长,Adam 优化器的损失函数采用平均绝对误差(mean absolute error, MAE)进行参数训练。学习率设为 0.001,并设置提前停止机制以防止模型过拟合。第二阶段的 dropout 为 0.1。两阶段模型可以看作两个独立的模型,它们之间仅进行数据传递,结果不会相互影响。第一阶段训练后进行滚动预测,以获得中间过程的初步结果。与原始数据集合并后,输入第二阶段模型,从而完成对第一阶段预测结果的优化。

在时间序列预测任务中,MAE 和 RMSE 是衡量模型性能的核心指标,MAE 使用绝对误差的平均值来对所有误差给予相同的权重,并且具有线性特性,使其对异常值更具鲁棒性,适用于数据集分布

不稳定或存在噪声干扰的任务。均方误差(mean square error, MSE)可以通过计算预测值与实际值之间差异的平方平均,有效反映模型对重大偏差的敏感性,对较大的误差给予更高的权重,适用于需要关注捕捉极端误差的场景。RMSE 是 MSE 的平方根。它继承了 MSE 对误差规模敏感的特性,其量纲与原始数据一致,便于直观理解误差的实际影响。

3.1 消融实验

在消融实验中,研究了一阶段结果下 Inception 模块和小波变换对预测结果的影响。实验结果如表 2 所示。模型主要由数据预处理和特征提取模块组成。简化的 Inception 模块有效利用了时间序列片段的整体特征,极大提高了模型的预测结果。作为一种出色的信号分析方法,小波变换增加了输入数据的信息量,通过对各特征波动情况的分析,为特征提取提供了细节信息和对预测参数的影响模式。

3.2 对比实验

本文中的两阶段模型是在第一阶段基础上的进一步研究。前期研究发现,尽管第一阶段模型的预测结果总体上能够符合实际数据,但对历史趋势累积效应无法加以区分,因此难以正确预测设备模式转换阶段的剧烈变化。为了解决这个问题,尝试通过提取细节特征来解决该问题,模型的建立考虑了历史结果对当前情况可能产生的影响,因此这部分是预测效果的对比实验,实验对比结果如表 3 所示。通过加入两阶段误差校正,MAE 和 RMSE 分别降低了 43.01% 和 47.55%。如图 5 所示预测效果表明,经过误差校正后,结果的预测更加准确,对于数据剧烈变化的数据点的预测效果有显著提高,但部分结果仍无法被准确校正,仍有优化空间。

表 2 消融实验

Table 2 Ablation experiment			
方法	MAE	MSE	RMSE
OT	24.167	—	30.056
OT + Haar	14.640	—	17.538
OT + DC	0.748	1.248	1.117
OT + Haar + Inception	0.911	1.410	1.190
OT + Haar + DC	0.681	0.991	0.995

注:OT 代表使用一阶段结果进行线性训练;Haar 代表加入 Haar 小波变换;DC 代表使用简化的 Inception 模块;—代表预测结果非常差。

表 3 阶段对比

Table 3 Comparison of stage			
方法	MAE	MSE	RMSE
一阶段预测	1.195	3.598	1.897
二阶段预测	0.681	0.991	0.995




图 5 阶段对比实验(部分)
Fig. 5 Comparison of the stage(part)

实验同样选取了近几年相关研究的模型,具体参数如下。

(1) PCA-KNN 模型使用 PCA 压缩信息,然后使用 KNN 算法进行任务预测。在比较实验中,数据集被划分为 3:1:1,而不是原文中的 7:1:1。

(2) Transformer^[20] 作为一种优秀的深度学习模型,在各种任务中表现良好,但在燃气轮机污染物排放任务中使用较少,因此使用其经典模型进行任务预测。

(3) 在 GWO-XGBoost 模型中,使用 GWO 作为优化算法来优化 XGBoost 中的参数,学习率为 0.065 8,树的最大深度为 9,学习器数量为 263。

(4) DA-LSTM 模型使用两种注意力机制的叠加,并结合 LSTM 进行时间序列预测。时间窗口根据原文设置为 24。特征注意力机制和时间注意力机制均包含一个输入为 32 的 LSTM 隐藏层。

(5) ELM-RF 模型选择 50 个具有 512 个隐藏

神经元的正则化 ELM 模型作为基础学习器,并进行平均计算,ELM 和 RF 作为第二层的元学习器。其中,RF 是最佳元学习器,也用于本实验中的比较。

(6) GA-SVM 使用 GA 优化 SVM 中的惩罚因子 C,并根据结果将惩罚因子设置为 1.66 进行训练。

根据图 6 和表 4 中展示的结果可以看出,所提出的模型在对比实验中取得了最佳的预测性能,这表明两个阶段都对预测任务的性能提升起到了有效作用。第一阶段模型为后续的误差修正提供了更小的与真实值之间的校正距离。第二阶段模型通过小波变换扩展了有用信息,并采用特征卷积层有效提取局部数据细节特征,将其应用于对结果的修正从而放大了特征的影响。两个阶段提取的特征信息可以归纳为第一阶段的整体数据趋势预测和第二阶段的局部特征放大。两个阶段协同工作,能够有效识别复杂的运行模式和非线性特征,同时准确预测高波动数据。为了展示预测结果的整体效果,将真实值与预测结果的整体比较绘制在图 7 中。横轴为测试集中的 7 341 个序列索引,纵轴为 NO_x,表示预测值和实际值的测量单位。对于 NO_x 的浓度预测任务,所使用模型的预测结果非常接近实际值,数据集的真实值整体波动较大,波动较小部分的预测结果几乎接近真实值,而波动较大部分的误差相对较大,但整体预测结果仍然良好,这表明




图 6 其他模型对比实验(部分)
Fig. 6 Comparison of the other models(part)

表 4 对比实验

Table 4 Compare of other models		
方法	MAE	RMSE
本文	0.681	0.995
PCA-KNN	1.402	3.203
Transformer	2.413	3.694
GWO-XGBoost	2.745	5.028
DA-LSTM	3.542	5.690
ELM-RF	4.035	5.532
GA-SVM	5.969	8.430




图7 测试集预测结果

Fig. 7 Testset prediction result

模型构建合理。特征提取方法符合数据集的特性,能够适应数据预测中的剧烈变化。

这个结果证明了分阶段预测全局和局部特征的设计方法的有效性,同时也反映了引入小波变换和 Inception 模块对特征提取及中间预测结果优化具有显著作用,这为该模型在复杂多变量时间序列预测任务中的应用提供了坚实的理论基础。

4 结论

在此任务中通过二阶段模型以进一步提高预测效果进行试验,尝试解决数据剧烈波动导致的预测效果不佳的问题,得到以下结论。

(1)将数据变化趋势和细节信息分两阶段进行时间序列预测任务,在所用的具有数值剧烈变化特征的数据集上取得了准确的预测效果。

(2)实验结果证明了通过小波变换扩展信息量,再通过特征提取的手段获取细节特征的方式能够有效提高模型对数据波动的变化识别。

未来的研究可以分为几个方向:首先,在模型方面,所使用的小波变换仍有优化空间,特征分析的深度不足,可以尝试结合更有效的小波变换。其次,由于数据集采集间隔问题,仅进行单步预测任务,可通过其他数据集将二阶段模型的单步预测扩展到短期和长期预测,并在保持和优化预测的准确性和鲁棒性的前提下扩大应用范围。最后,可以将预测结果与效率、使用寿命等机器参数结合,为理论应用于实践提供支持。

参 考 文 献

[1] 马玉辉, 杨永波, 张楠, 等. 基于可测数据特征和回归分析的燃气轮机燃油系统故障诊断方法[J]. 燃气轮机技术, 2025, 38(3): 43-49.
Ma Yuhui, Yang Yongbo, Zhang Nan, et al. Fault diagnosis

method for gas turbine fuel system based on measurable data features and regression analysis[J]. Gas Turbine Technology, 2025, 38(3): 43-49.

[2] Skalska K, Jacek S M, Stanislaw L. Trends in NO_x abatement: a review[J]. Science of the Total Environment, 2010, 408(19): 3976-3989.

[3] Surase R S, Konijeti R, Chopade R P. Thermal performance analysis of gas turbine power plant using soft computing techniques: a review [J]. Engineering Applications of Computational Fluid Mechanics, 2024, 18(1): 1-24.

[4] Rajat S, Hany B, John W. A comparison of two trending strategies for gas turbine performance prediction[J]. Journal of Engineering for Gas Turbines and Power, 2008, 130(4): 041601.

[5] Andrea C, Mauro V. Application of forecasting methodologies to predict gas turbine behavior over time[J]. Journal of Engineering for Gas Turbines and Power, 2012, 134(1): 012401.

[6] Vipul G, Xu M Y, Jayanta K, et al. Prediction enhancement of machine learning using time series modeling in gas turbines[J]. Journal of Engineering for Gas Turbines and Power, 2023, 145(12): 121005.

[7] Chen Z M, Pu Y X. Prediction of emissions from gas turbine power generation on GWO-XGBoost-Sobol[J]. Journal of Mechanical Science and Technology, 2024, 38: 1547-1556.

[8] 向彬彬. 基于 GA-SVM 的燃气轮机 NO_x 排放预测研究[J]. 机械管理开发, 2023, 38(2): 47-49, 52.
Xiang Binbin. GA-SVM based prediction of NO_x emissions in gas turbines[J]. Mechanical Management and Development, 2023, 38(2): 47-49, 52.

[9] Rezazadeh A. Environmental pollution prediction of NO_x by predictive modelling and process analysis in natural gas turbine power plants[J]. Pollution, 2021, 7(2): 481-494.

[10] Kaya H, Pinar T, Erdinç U. Predicting CO and NO_x emissions from gas turbines: novel data and a benchmark PEMS [J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2019, 27(6): 4783-4796.

[11] 李耀华, 王洁. 基于改进时间卷积网络的航空发动机寿命预测模型[J]. 科学技术与工程, 2025, 25(31): 13643-13650.
Li Yaohua, Wang Jie. Aero-engine life prediction model based on improved temporal convolutional network[J]. Science Technology and Engineering, 2025, 25(31): 13643-13650.

[12] Guo L J, Zhang S J, Huang Q L. NO_x prediction of gas turbine based on dual attention and LSTM[C]//2022 34th Chinese Control and Decision Conference (CCDC). Hefei: Institute of Electrical and Electronics Engineers Inc, 2022: 4036-4041.

[13] Li J J, Han J, Niu D P, et al. Fast and accurate gas turbine emission prediction based on a light and enhanced Transformer model [J]. Fuel, 2024, 376: 132750.

[14] Su X, Zhang Y M, Zhang Y Y, et al. An enhanced multilayer Res-Informer with Savitzky-Golay filter for predicting mixed CO and NO_x emissions in gas turbines[J]. Chemometrics and Intelligent Laboratory Systems, 2025, 261: 105379.

[15] Feng N H, Lai S N, Yang J Y, et al. TimeSieve: extracting tem-

- poral dynamics through information bottlenecks[J]. arXiv Preprint, arXiv: 2406. 05036, 2024.
- [16] 钟松浩, 卢毅, 李理, 等. 基于跨周期稀疏技术的长时交通流预测模型[J]. 科学技术与工程, 2025, 25(24): 10468-10477.
Zhong Songhao, Lu Yi, Li Li, et al. Long term traffic flow forecasting model based on cross period sparse technique[J]. Science Technology and Engineering, 2025, 25(24): 10468-10477.
- [17] Wang S Y, Wu H X, Shi X M, et al. TimeMixer: decomposable multiscale mixing for time series forecasting[J]. arXiv Preprint, arXiv: 2405. 14616, 2024.
- [18] Wu H X, Xu J H, Wang J M, et al. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting [J]. Advances in Neural Information Processing Systems, 2021, 34: 22419-22430.
- [19] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: Institute of Electrical and Electronics Engineers Inc, 2016: 2818-2826.
- [20] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems. Long Beach: MIT Press, 2017: 1-30.