

基于 KPCA-IPOA-BiGRU 的联合循环余热锅炉 主蒸汽参数预测*

刘学¹ 向荣² 向文国¹

(1. 东南大学能源热转换及过程测控教育部重点实验室 南京 211102; 2. 华能南京金陵发电有限公司 南京 210046)

摘要: 余热锅炉主蒸汽参数对于联合循环机组的健康运行判断至关重要。针对余热锅炉运行参数非线性和时延性导致主蒸汽参数预测精度低的问题,提出了一种联合循环余热锅炉主蒸汽参数预测模型。首先,采集燃机电厂的 SIS 运行数据,通过灰色相关性分析法确定输入变量;其次,通过核主成分分析(kernel principal component analysis, KPCA)提取输入参数的特征信息,并根据主成分贡献率选取输入维度;最后,利用改进的鹈鹕优化算法(improved pelican optimization algorithm, IPOA)优化双向门控循环神经网络(bi-directional gated recirculation neural network, BiGRU),并构建 KPCA-IPOA-BiGRU 进行三压余热锅炉主蒸汽参数的预测测验。结果表明,现场采集的 10 000 组数据点,其中 8 000 组用作训练集,2 000 组用作测试集,提出的模型将 28 维输入参数降低至 8 维,可准确预测 3 个压力级的蒸汽参数,且 R^2 均大于 98%,为预测时延性的联合循环余热锅炉主蒸汽参数提供了技术支持。

关键词: 主蒸汽参数预测;双向门控循环神经网络;鹈鹕优化算法;核主成分分析

中图分类号: TK39; TP181 **文献标识码:** A **国家标准学科分类代码:** 520.2010

Prediction of main steam parameters of combined cycle recovery steam generator based on KPCA-IPOA-BiGRU

Liu Xue¹ Xiang Rong² Xiang Wenguo¹

(1. Key Laboratory of Energy Thermal Conversion and Control of Education, Southeast University, Nanjing 211102, China; 2. Huaneng Nanjing Jinling Power Generation Co., Ltd., Nanjing 210046, China)

Abstract: Main steam parameters of heat recovery steam generator (HRSG) are crucial for the healthy operation of the combined cycle unit. Aiming at the problem of low prediction accuracy of main steam parameters due to non-linearity and time-delay of operating parameters of HRSG, a model for predicting main steam parameters of the combined cycle HRSG is proposed. Firstly, operation data of a gas turbine combined cycle were collected to determine the input variables by grey correlation analysis. Secondly, the feature information of the input parameters was extracted by KPCA and the input dimensions were selected according to the principal component contribution ratio. Finally, BiGRU was optimised by IPOA and KPCA-IPOA-BiGRU was constructed to conduct the prediction test of the three-pressure-HRSG main steam parameters. The results show that the proposed model reduces the 28-dimensional input parameters to 8 dimensions and can predict the three-pressure steam parameters using 8 000 data points as the training set, and 2 000 data points as the test set. The R^2 is greater than 98% for all of the tests, which provides technical support for monitoring time-delayed main steam parameters.

Keywords: main steam parameter prediction; bidirectional gated recurrent neural network; pelican optimisation algorithm; kernel principal component analysis

收稿日期:2024-01-29

* 基金项目:国家科技重大专项(2017-I-0002-0002)资助

0 引言

以天然气为燃料的燃气-蒸汽联合循环机组具有低污染、低排放等优点,成为新能源发电转型快速发展的重要支撑^[1-2]。因此,燃气-蒸汽联合循环机组得到了广泛的应用^[3]。余热锅炉是连接燃气轮机和汽轮机的重要设备,其运行状态会对整个联合机组产生巨大影响^[4]。余热锅炉3个压力级主蒸汽温度、压力参数作为余热锅炉机组运行的主要监测参数,可以准确反映出机组当前的运行状态^[5]。但是,由于燃机机组变负荷、减温水阀门开度等运行指令发出与蒸汽参数变化处于稳态之间存在时延^[6],实时监测蒸汽参数比较困难,并且传感器测量无法提前预警^[7]。因此,为了准确监测余热锅炉运行状态,对余热锅炉三压力级蒸汽参数进行预测是很有必要的。

近年来,基于数据驱动的故障诊断方法成为研究热点,该方法可以拟合任意函数并训练大数据信息,在厂矿设备的运行参数预测方面得到了广泛应用^[8]。郭敏等基于改进的双向长短期记忆神经网络提出一种融合多个退化模型的电池寿命预测方法^[9]。周建新等^[10]基于混合变异策略改进鲸鱼优化算法提出了卷取温度预测模型,精度达到了97.5%。王印松等^[11]基于(distributed control system, DCS)数据结合互信息算法筛选输入数据后,利用长短期记忆(LSTM)实现了垃圾焚烧炉主蒸汽温度预测。魏炜等^[12]利用卷积神经网络(CNN)对样本数据进行软分类,提出了一种加入注意力机制的LSTM的风机状态预测模型。以往的研究都是针对数据量较小的具体厂矿设备的温度,无法证明该模型在大型厂矿设备全工况的监测效果。本文应用实例的F级燃机电厂存在数据量大,运行机理模糊不清的情况,也导致了预测模型训练难、精度低的问题。因此,基于SIS数据驱动的余热锅炉主蒸汽参数预测模型研究还不够完善。

基于上述研究,本文提出了一种新型的三压余热锅炉主蒸汽参数预测模型。首先,采取灰色相关性分析进行输入参数选择;其次,使用核主成分分析(kernel principal component analysis, KPCA)充分提取非线性数据特征并实现降维;最后,采用Sine混沌映射算法和鲸鱼优化算法(whale optimization algorithm, WOA)螺旋更新机制改进的正余弦策略改进的鹈鹕优化算法(improved pelican optimization algorithm, IPOA)优化双向门控循环神经网络(bi-directional gated recirculation neural network, BiGRU),实现了燃气-蒸汽联合循环机组的余热锅炉三压力级蒸汽温度和压力的全工况提前监测。

1 KPCA-IPOA-BiGRU 算法理论

1.1 BiGRU 网络

BiGRU是具备门控结构的循环神经网络,且具有两个双向的循环记忆单元。门控结构内部的记忆单元可以有效地处理时间序列数据,避免梯度爆炸。相比LSTM,

GRU精简了神经网络的门控结构,仅采用重置门、更新门两个门控机制控制信息的输入、输出,从而实现对时间序列数据的处理^[13]。而双向门控循环神经网络则,门控关系的变量计算公式如下:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (1)$$

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (h_{t-1} \odot r_t) + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (4)$$

前一时刻的隐藏状态为 h_{t-1} ,将当前时刻的输入为 x_t ,两个状态作为输入通过重置门和更新门并计算出 z_t 和 r_t ,根据影响情况选择性遗忘历史信息。接着,根据 z_t 和 r_t 计算出临时隐藏状态 \tilde{h}_t ,最后根据 z_t 、 r_t 和 \tilde{h}_t 输出当前的隐藏状态 h_t 。其中, σ 为sigmoid激活函数, W 、 U 为重置门和更新门结构中的权重矩阵, b 为其对应的偏置向量。

1.2 KPCA 法

KPCA^[14]的特点是基于一非线性核函数 Φ 对原始运行数据的样本集 x_k 进行非线性变换,将 x_k 映射至高维线性特征空间 F ,再对新的样本集计算其协方差矩阵,即:

$$C = \frac{1}{m} \sum_{j=1}^m \phi(x_j) \phi(x_j)^T \quad (5)$$

再求出上述矩阵的特征值 λ 和特征向量 v ,满足以下条件:

$$\lambda v - Cv = 0 \quad (6)$$

两边引入非线性函数 $\phi(x_i)$,特征向量 v 由 $\phi(x_i)$ 线性表示,即:

$$v = \sum_{i=1}^m \alpha_i \phi(x_i) \quad (7)$$

定义核函数矩阵 $K_{ij} = \langle \phi(x_i), \phi(x_j) \rangle$,转化为:

$$m\lambda \alpha - K\alpha = 0 \quad (8)$$

式中: α 为特征向量,下标 i 表示输入数据集中某一元素。对于任意样本,在特征空间 F 中主元 $\phi(x)$ 上的投影为:

$$v\phi(x) = \sum_{i=1}^m \alpha_i \phi(x_i) \phi(x_j) = \sum_{i=1}^m \alpha_i K(x_i, x) \quad (9)$$

1.3 IPOA 算法

1) 鹈鹕优化算法(POA)

POA是2022年由Pavel等^[15]提出的一种自然启发式算法。该算法模拟了鹈鹕狩猎时展现出的行为和策略,主要包含如下几种行为。

(1) 勘探行为,在解空间内随机生成猎物的位置,鹈鹕进行勘探并向猎物位置进行移动,可表述为:

$$C_{ij}^{p1} = \begin{cases} C_{ij} + \text{rand}(p_j - I \cdot C_{ij}), & F_p < F_i \\ C_{ij} + \text{rand}(C_{ij} - p_j), & F_p \geq F_i \end{cases} \quad (10)$$

式中: C_{ij} 为第 i 组鹈鹕在第 j 维的初始位置; C_{ij}^{p1} 为第 i 组鹈鹕在第 j 维的新位置; I 为1或2的随机数; p_j 为猎物在第 j 维的位置; F_p 为目标函数值。

若勘探阶段获取的目标函数值更优,鹈鹕进行位置更新:

$$X_i = \begin{cases} X_i^{P_1}, & F_i^{P_1} < F_i \\ X_i, & \text{其他} \end{cases} \quad (11)$$

式中： $X_i^{P_1}$ 为第 i 只鹈鹕的新位置； F_i 为初始目标函数值； $F_i^{P_1}$ 为勘探获取的目标函数值。

(2) 觅食行为，勘探完毕后，鹈鹕进行觅食行为，向最优猎物位置收敛，可表述为：

$$C_{ij}^{P_2} = C_{ij} + R \left(1 - \frac{t}{T}\right) \times (2rand - 1) \times x_{ij} \quad (12)$$

式中： $C_{ij}^{P_2}$ 为觅食阶段第 i 组鹈鹕在第 j 维的新位置； R 为常数，取值 0.2； $R \left(1 - \frac{t}{T}\right)$ 为邻域半径，其中 t 为迭代次数， T 为设置的最大迭代次数， $rand$ 为 $[0,1]$ 的随机数。

2) 基于 Sine 混沌映射与正余弦策略 IPOA 算法

(1) Sine 混沌映射

混沌映射可以均匀分布搜索空间中的变量，提高 POA 算法的寻优效率和精度^[16]。在算法应用研究中，Sine 映射出的优秀种群可以提高了算法的收敛速度和精度。为了丰富 POA 算法初始化多样性，对于每个鹈鹕个体进行 Sine 映射初始化：

$$x_{n+1} = \frac{\alpha}{4} \sin(\pi \cdot x_n) \quad (13)$$

式中： x_n 为初始化个体位置； x_{n+1} 为映射后的个体新位置。

(2) 基于 WOA 螺旋机制改进的正余弦策略

正余弦策略是利用正余弦周期性波动函数构造迭代方程，从而实现全局搜索和局部寻优的功能。本文融入 WOA 算法的螺旋机制以提高全局搜索能力，得到一种改进的正余弦策略：

$$X_i^j(t+1) = \begin{cases} X_i^j(t) + r_1 \cdot \sin(r_2) \cdot |r_3 P_{best}(t) - X_i^j(t)|, & p > 0.5 \\ X_i^j(t) + r_1 \cdot \cos(r_2) \cdot |r_3 P_{best}(t) - X_i^j(t)|, & p < 0.5 \end{cases} \quad (14)$$

式中： t 为迭代次数； $X_i^j(t)$ 为第 t 次迭代中第 i 个个体的第 j 维变量； r_1 和 r_3 为 $[0,1]$ 的随机数， r_2 为 $[0,2\pi]$ 的随机数； $P_{best}(t)$ 为本次迭代最优解。

(3) 算法流程

本文基于 Sine 混沌映射与 WOA 螺旋机制改进的正余弦策略对 POA 进行改进，提出了 IPOA。首先利用 Sine 混沌映射初始化鹈鹕种群以及个体；接着每个鹈鹕个体进行勘探行为、觅食行为完成最优位置的更新；最后重复循环迭代到满足所设置的要求，输出最优解。具体 IPOA 算法流程如图 1 所示。

1.4 灰色相关性分析

灰色相关性分析能够根据不同变量曲线的相似性来确定变量之间的相关性，实现了灰关系的相关性定量分析。假设自变量为 X ，因变量为 Y ，则自变量与因变量的

相关系数为：

$$\xi_i(j) = \frac{\min_i \min_j |y(j) - x_i(j)| + \rho \cdot \max_i \max_j |y(j) - x_i(j)|}{|y(j) - x_i(j)| + \rho \cdot \max_i \max_j |y(j) - x_i(j)|} \quad (15)$$

由此可得变量 x_i 与因变量序列 $y(j)$ 之间的关联度

r_i ：

$$r_i = \frac{1}{n} \sum_{j=1}^n \xi_i(j) \quad (16)$$

式中： n 为样本数量； $\xi_i(j)$ 的表示第 i 个自变量 x_i 对 $y(j)$ 的关联系数； ρ 为灰色相关性系数，本文取值 0.5。

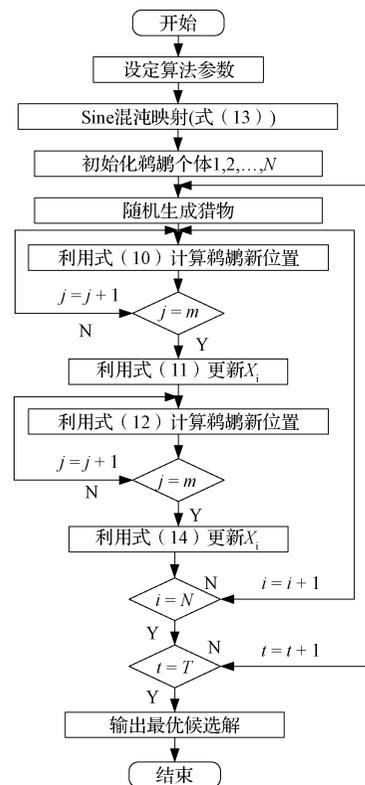


图 1 IPOA 算法流程

Fig. 1 Flowchart of IPOA algorithm

2 余热锅炉主蒸汽参数预测模型

2.1 余热锅炉简介

本文余热锅炉主蒸汽参数预测模型适用于 S109FA 联合循环机组，该机组的余热锅炉为 Q2386/605-286 (42.7)-10(0.4)/566.5(296.5) 型号的三压再热、自然循环型锅炉。

如图 2 所示，某电厂采用三压、再热、无补燃余热锅炉，热源来自燃气轮机的高温排气。高压段蒸汽由二级过热器进行过热，然后由二级过热器加热成过热蒸汽送入高压汽轮机做功；中压段蒸汽送入过热器加热成过热蒸汽，再与高压汽轮机排汽混合后，送入二级再热器进行再热，

产生再热蒸汽并送入中压汽轮机做功;低压段蒸汽由过热器进行过热后与中压排汽混合送入低压汽轮机做功。由此,本文把3个压力级最终出口产生的蒸汽温度与蒸汽压力(高压过热蒸汽温度、高压过热蒸汽压力、中压再热蒸汽温度、中压再热蒸汽压力、低压过热蒸汽温度、低压过热蒸汽压力)作为余热锅炉主蒸汽参数进行预测,可以精确地监测送入汽轮机做功的蒸汽健康状态。

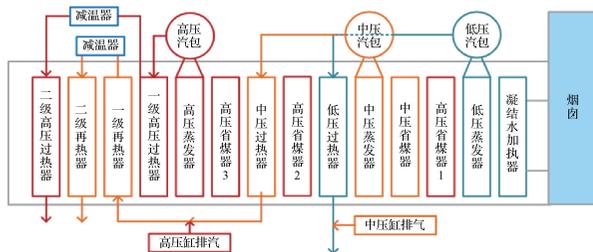


图2 S109FA机组余热锅炉受热面构成
Fig.2 Recovery steam generator heating surface composition for unit M701F4

2.2 预测模型

本文构建了一种基于KPCA-IPOA-BiGRU算法。具体来说,首先采用KPCA提取数据特征并进行降维,筛选出包含绝大部分数据信息的主成分并丢弃其余冗余数据。其次,利用IPOA算法优化BiGRU内部的最佳学习率、L2正则化系数和隐藏层的超参数。最后,将KPCA降维后保留的主成分特征作为输入参数训练模型。基于KPCA-IPOA-BiGRU的预测模型流程如图3所示。

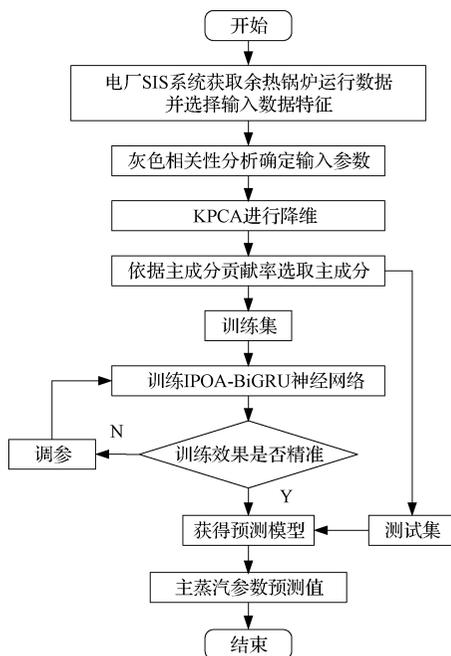


图3 预测模型流程
Fig.3 Flowchart of prediction model

2.3 模型预测性能评价指标

为进一步验证基于混合策略神经网络的余热锅炉监测模型的预测性能,选取决定系数 R^2 、均方根误差(RMSE)、平均绝对误差(MAE)作为评价指标。 R^2 是度量拟合程度的统计量, RMSE可以反映出误差大小, MAE能够反映出模型的预测稳定程度, 3个指标的计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (17)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (18)$$

$$MAE = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{m} \quad (19)$$

式中: m 为测试集的样本数; y_i 为第*i*个样本的真实值; \hat{y}_i 为对应的预测值; \bar{y} 为样本的平均值。

3 实例分析

3.1 数据分析

以中国某大型燃机电厂的S109FA型燃气-蒸汽联合循环发电机组2022年12月1日~2023年3月31日实际运行数据作为模型的训练数据,时间间隔为1min,共计217400个数据点。部分原始实验数据分布如图4所示,锅炉启、停或工况改变时,由于蒸汽参数延迟、有惯性、有自平衡的动态特性,低压过热蒸汽参数变化具有延迟现象。表1为该机组余热锅炉的设计参数。

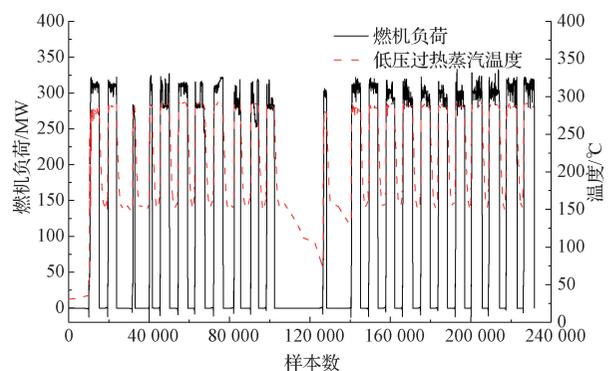


图4 部分原始实验数据分布
Fig.4 Distribution of part of the original experimental data

表1 余热锅炉设计参数

参数	高压部分	中压部分	低压部分	再热部分
最大连续蒸发量/($t \cdot h^{-1}$)	284.7	75.8	47.7	351.8
额定蒸汽出口压力/bar	127.9	35.2	6.67	33.5
额定蒸汽出口温度/°C	540	319.2	245.4	568.0

3.2 数据预处理

由于需要训练的数据为联合循环机组在稳态运行状态下的健康状态,因此需要剔除机组非稳态运行状态的数据点。本文使用滑动窗口法筛选稳态运行数据,并选用检修后的10 000个数据点作为数据集,其中前8 000个数据点作为训练集,后2 000个数据点作为测试集,再使用最小-最大归一化消除数据间的量纲差异,将数据线性地转换到[0, 1]范围内后送入模型训练。最小-最大归一化的计算公式如下:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (20)$$

式中: X 为原始数据; X_{\min} 为每列数据中最小值; X_{\max} 为每列数据中最大值; X' 是归一化后的数据。

3.3 灰色相关性分析

余热锅炉运行时蒸汽侧、给水侧参数间前后影响,运行机制存在物理模型不清晰的灰关系,难以定量对于最终出口蒸汽参数的影响程度。采用灰色相关性分析法探究燃机负荷、燃气温度、减温水流量、给水温度、给水流量、排汽温度等28个输入参数与3个压力级的出口参数的关联度关系。分析结果如图5所示,选取的输入参数与6个输出参数的关联度均大于0.95,具有强相关性,可作为输入特征送入模型训练。

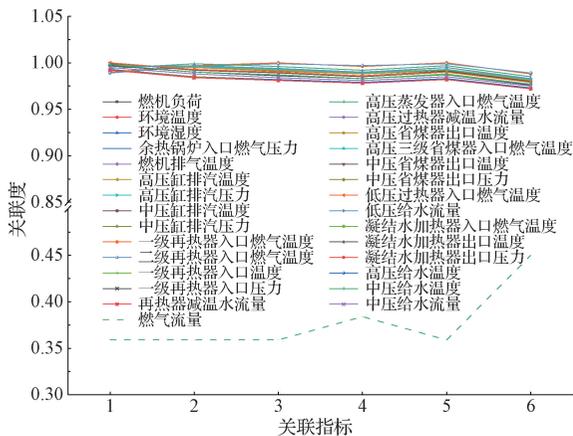


图5 灰色相关性分析结果

Fig. 5 The results of grey correlation analysis

3.4 KPCA降维结果

为了去除输入参数的冗余信息,将28个输入参数进行KPCA降维,核函数采用高斯核函数。选取累积贡献率达到96%的主成分作为输入主成分,最终选取的主成分如表2所示。碎石图以及累积方差贡献率如图6所示,主成分1的贡献率达到52.74%以上,前8个主成分的累计贡献率已经达到96%以上,已经可以反应出余热锅炉输入参数的绝大部分信息,因此设定阈值为0.96,将数据从28维降到8维。

3.5 模型验证

对于主蒸汽参数,机组的启、停阶段的时延约为

表2 KPCA主成分相关信息

Table 2 Principal component information table

主成分	特征值/($\times 10^4$)	方差率/%	累积贡献率/%
1	14.768	52.744	52.744
2	5.660	20.213	72.957
3	2.311	8.253	81.210
4	1.066	3.807	85.017
5	1.007	3.597	88.613
6	0.960	3.428	92.042
7	0.752	2.687	94.729
8	0.543	1.941	96.670

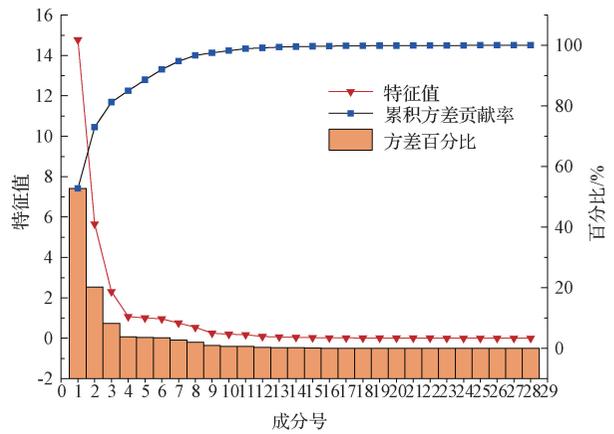


图6 碎石图以及累积贡献率

Fig. 6 Scree plot and cumulative contribution rate

5 min,即5个数据点,减温水调节阶段的时延约为1 min,即1个数据点。针对负荷、减温水调节等运行工况改变到蒸汽参数变化存在时延的问题,本文模型选用时间步长为5个步长,对2 000个数据点的主蒸汽参数进行预测测试。

为了直观体现KPCA-IPOA-BiGRU模型的预测性能,本文对该模型对于6个主蒸汽参数进行了消融实验。并为了进一步对比本模型的预测效果,设置了反向传播神经网络(back propagation neural network, BP)、LSTM网络和基于改进鲸鱼优化算法(IWOA)的GRU 3个模型作为对照组。经过多轮测试训练后,将3个压力级的主蒸汽数据输入训练好的模型,消融实验对比如图7所示,不同算法预测模型的预测对比如图8所示。由于主蒸汽时延性,BP预测曲线与实际值存在极大偏差,反映出BP神经网络处理时延性数据的局限性。由于余热锅炉机组负荷频繁变化,主蒸汽参数波动性较大,LSTM、PCA-IWOA-GRU在波峰处出现了欠拟合问题,而KPCA-IPOA-BiGRU模型的预测曲线与实际值曲线高度吻合,能够精确有效地反映余热锅炉温度、压力未来的变化趋势,具有更强的泛化能力。

热蒸汽温度,各项评价指标信息如表3所示。对于

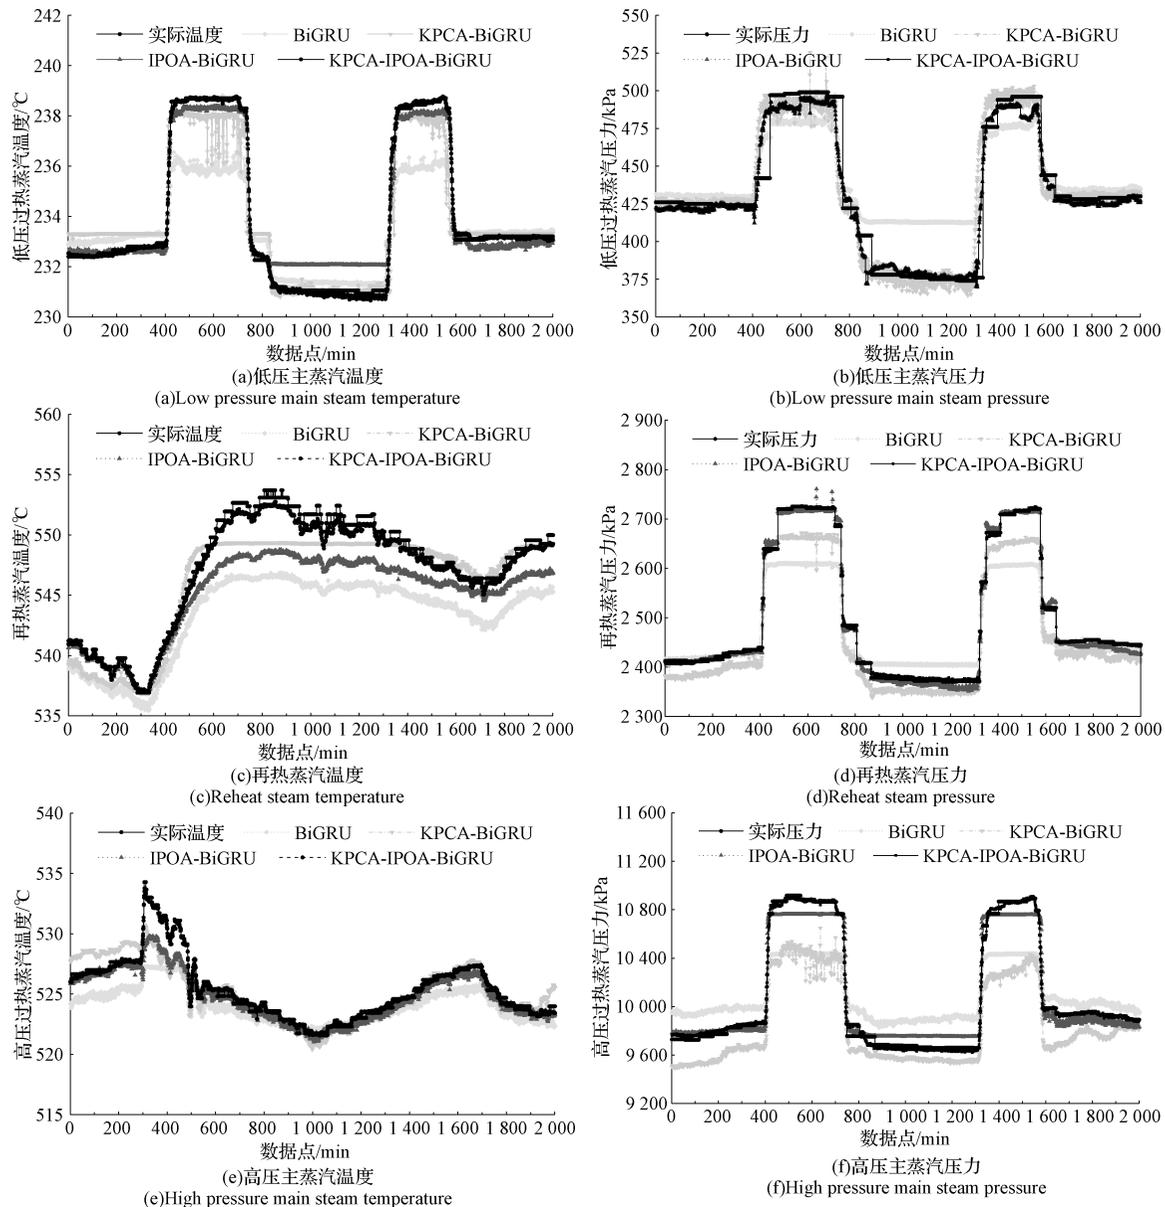


图7 3个压力级主蒸汽参数的消融实验对比

Fig. 7 Comparison of ablation experiments of main vapour parameters at three pressure levels

3个压力级的主蒸汽参数进行了预测,本文提出的KPCA-IPOA-BiGRU模型的预测性能指标与对照组相比均有所提高。KPCA-IPOA-BiGRU的 R^2 达到了99.3%,体现出模型对于6个主蒸汽参数均有良好的拟合效果。由于机组处于调峰阶段,负荷有较大波动,各个模型的预测精度会受到影响,KPCA-IPOA-BiGRU响应负荷波动较快且曲线更为平滑,相较于其余模型展现出更好的抗扰动能力。在消融实验中,提出的模型在3个压力级主蒸汽参数下相较于BiGRU, RMSE平均降低了87.80%, MSE平均降低了77.47%,表明了IPOA算法具有较强寻优性能。在对比实验中,本文模型对于6个主蒸汽参数预测的RMSE相较于PCA-

IWOA-GRU平均降低了53.99%、都具有更高的预测精度。对于3个压力级的出口主蒸汽温度预测的MAE值均低于0.136℃,出口主蒸汽压力预测的MAE值均低于0.009 MPa。结果表明,本文模型对余热锅炉蒸汽参数提前预测的效果最好,可以提前预测出2000个数据点的主蒸汽参数,满足提前监测时延性主蒸汽运行状态的应用需求。

综上所述,相比其余6组对照模型,KPCA-IPOA-BiGRU模型对于三压力级蒸汽参数具有更好的预测性能,在余热锅炉变工况运行下,仍然能够精准预测出2000 min的主蒸汽参数,具有较强的泛化能力和鲁棒性,达到了提前监测余热锅炉主蒸汽参数的目的。

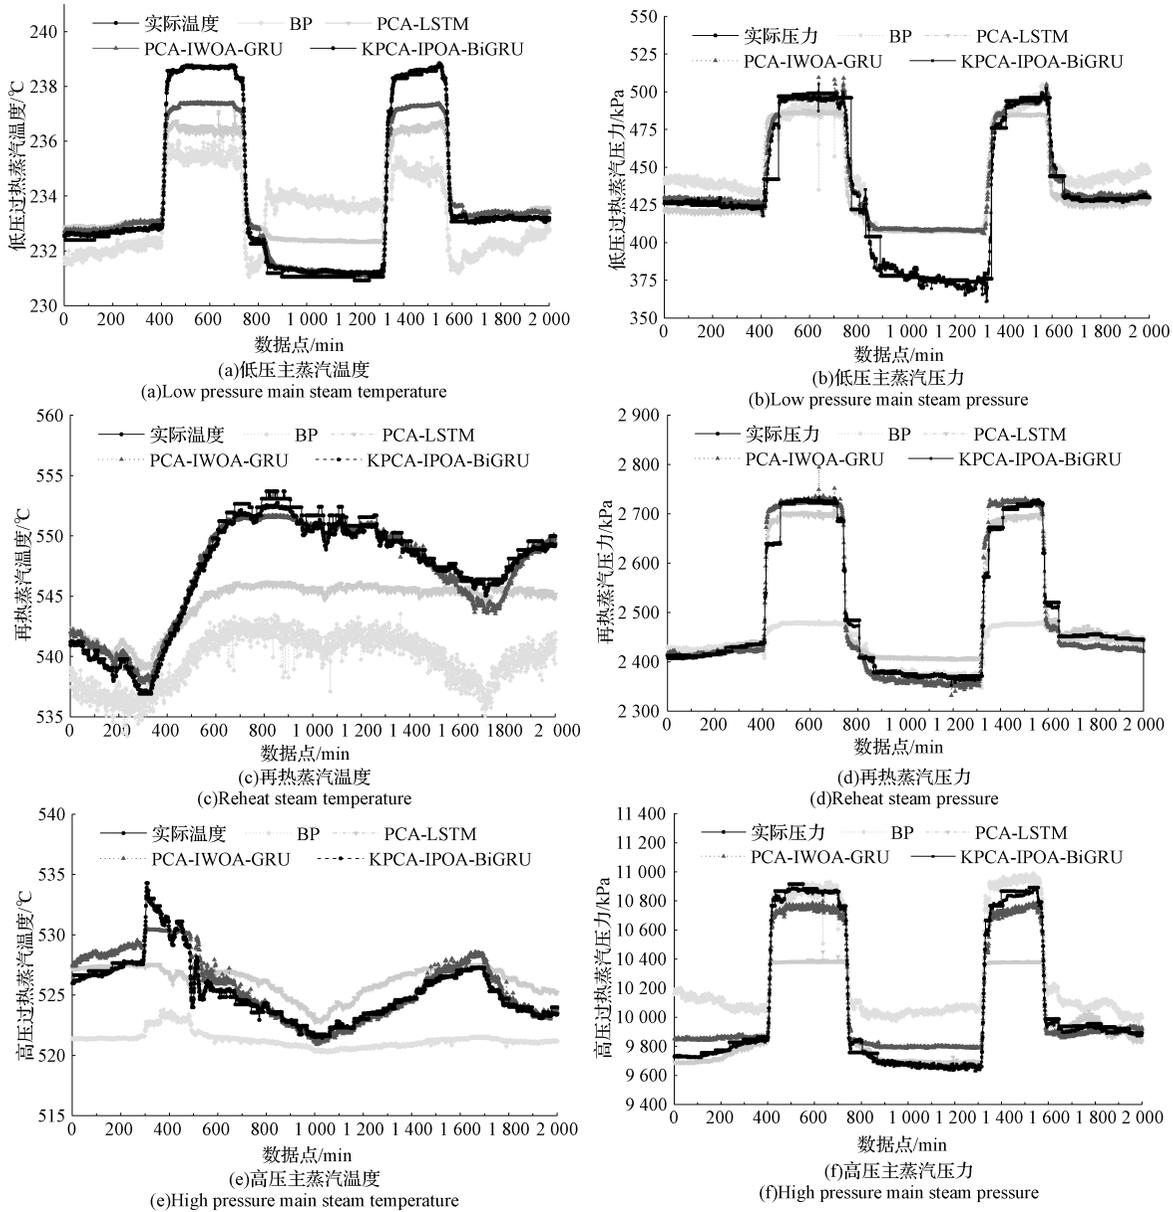


图 8 3 个压力级主蒸汽参数的不同模型对比

Fig. 8 Comparison of different models with different main steam parameters for three pressure levels

表 3 7 种模型预测效果的评价指标

Table 3 The evaluation indicators of the predictive effects of the seven models

对比模型	R^2	RMSE	MAE
BP	0.668	2.706	2.142
BiGRU	0.750	2.343	1.650
PCA-LSTM	0.795	2.125	1.762
KPCA-BiGRU	0.877	1.646	1.305
IPOA-BiGRU	0.945	1.107	0.749
PCA-IWOA-GRU	0.982	0.429	0.313
KPCA-IPOA-BiGRU	0.993	0.203	0.114

4 结论

本文针对燃机电厂采集的实际运行数据时存在非线性、维度高、数据量庞大等问题。模型训练前,使用 KPCA 方法除去冗余信息将 28 维输入参数降低至 8 维。利用改进后的 IPOA 算法对 BiGRU 神经网络进行超参数寻优后,利用获取的超参数建立三压力级蒸汽参数的预测模型,并进行了消融实验和对比试验,证明了 KPCA-IPOA-BiGRU 模型的优越性,可以提前预测出时延性的联合循环余热锅炉主蒸汽参数,为准确监测主蒸汽参数提供了技术支持。

参考文献

- [1] ZHANG P, ZHOU L, XU W. Compressibility factor calculation from gross calorific value and relative density for natural gas energy measurement [J]. International journal of energy research, 2022(7): 46(7): 9948-9959.
- [2] 闫明月, 刘德俊, 商丽艳, 等. 燃气-蒸汽联合循环余热回收系统性能研究[J]. 工程热物理学报, 2021, 42(4): 854-864.
YAN M Y, LIU D J, SHANG L Y, et al. Research on performance of gas-steam combined cycle waste heat recovery system [J]. Journal of Engineering Thermophysics, 2021, 42(4): 854-864.
- [3] ZHEN W, DUAN L Q. Thermoeconomic optimization of steam pressure of heat recovery steam generator in combined cycle gas turbine under different operation strategies [J]. Energies, 2021, 14(16): 4991-4991.
- [4] 国洪立, 陈时熠, 唐寅, 等. 基于 PCA-SSA-LSTM 的余热锅炉状态监测模型[J]. 热力发电, 2023, 52(10): 86-94.
GUO H L, CHEN SH Y, TANG Y, et al. Condition monitoring model of HRSG based on PCA-SSA-LSTM [J]. Thermal Power Generation, 2023, 52(10): 86-94.
- [5] 王一丰, 翟春华, 黄庆, 等. 大功率燃气轮机联合循环机组三压再热余热锅炉建模及变负荷运行规律研究[J]. 热力发电, 2023, 52(12): 79-89.
WANG Y F, ZHAI CH H, HUANG Q, et al. Off-design modeling of heat recovery steam generator in heavy-duty gas turbine combined cycle unit and variable load operation research[J]. Thermal Power Generation, 2023, 52(12): 79-89.
- [6] 桂宁, 华菁云. 数据驱动下火电机组时延鉴别及主汽温度预测[J]. 计算机应用, 2020, 40(11): 3400-3406.
GUI N, HUA J Y. Data driven time delay identification and main steam temperature prediction in thermal power units [J]. Journal of Computer Applications, 2020, 40(11): 3400-3406.
- [7] 冯旭刚, 张泽辰, 刘圣晶, 等. 基于 IGPC 的火力发电机组主汽温预测控制策略[J]. 中国电机工程学报, 2022, 42(9): 3307-3317.
FENG X G, ZHANG Z CH, LIU SH J, et al. Predictive control strategy for main steam temperature of thermal power unit[J]. Proceedings of the CSEE, 2022, 42(9): 3307-3317.
- [8] YU J, ZHAO Y, PAN R, et al. Prediction of the critical temperature of superconductors based on two-layer feature selection and the optuna-stacking ensemble learning model [J]. ACS Omega, 2023, 8(3): 3078-3090.
- [9] 郭敏, 张浩. 基于改进 Bi-LSTM 网络下的多时变状态锂电池剩余寿命预测方法[J]. 国外电子测量技术, 2023, 42(10): 59-68.
GUO M, ZHANG H. Remaining useful life prediction method of lithium-ion battery in multiple time-varying states based on an improved Bi-LSTM network [J]. Foreign Electronic Measurement Technology, 2023, 42(10): 59-68.
- [10] 周建新, 霍彤明. 基于 NMWOA-LSTM 的卷取温度预测模型[J]. 电子测量技术, 2023, 46(18): 60-66.
ZHOU J X, HUO T M. Prediction model of coiling temperature based on NMWOA-LSTM [J]. Electronic Measurement Technology, 2023, 46(18): 60-66.
- [11] 王印松, 雷玉. 基于 DCS 数据和燃烧图像的垃圾焚烧炉主蒸汽温度预测[J]. 中国电机工程学报, 2023, 43(22): 8790-8801.
WANG Y S, LEI Y. Prediction of main steam temperature of waste incinerator based on DCS data and combustion image[J]. Proceedings of the CSEE, 2023, 43(22): 8790-8801.
- [12] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法[J]. 仪器仪表学报, 2023, 44(4): 19-27.
WEI W, LV Y, QI X Y, et al. State prediction method for power plant fans based on the CNN-LSTM-AM dynamic integrated model [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [13] 周静雷, 贺家琛, 崔琳. CNN-GRU 和 SSA-VMD 在扬声器异常声分类中的应用[J]. 电子测量与仪器学报, 2023, 37(3): 161-168.
ZHOU J L, HE J CH, CUI L. Application of CNN-GRU and SSA-VMD in loudspeaker abnormal sound classification [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 161-168.
- [14] HUANG G. An insight into extreme learning machines: Random neurons, random features and kernels [J]. Cognitive computation, 2014, 6(3): 376-390.
- [15] PAVEL T, MOHAMMAD D. Pelican optimization algorithm: A novel nature-inspired algorithm for

engineering applications[J]. Sensors, 2022, 22(3): 855-855.

- [16] 刘磊, 姜博文, 周恒扬, 等. 融合改进 Sine 混沌映射的新型粒子群优化算法[J]. 西安交通大学学报, 2023, 57(8): 182-193.

LIU L, JIANG B W, ZHOU H Y, et al. Predictive control strategy for main steam temperature of thermal power unit[J]. Journal of Xi'an Jiaotong University, 2023, 57(8): 182-193.

作者简介

刘学, 硕士研究生, 主要研究方向为大数据处理以及联合循环机组的故障预警。

E-mail: seu_xliu0277@163.com

向荣, 工程师, 主要研究方向为电厂锅炉运行监测。

向文国, 教授, 主要研究方向为煤/生物质气化与制氢、热力系统运行优化与故障诊断。

E-mail: wgxiang@seu.edu.cn