

DOI: 10.19666/j.rlfed.202501029

基于多保真度数据和迁移学习的 凝汽器系统特性建模方法

张逸佳, 任少君, 朱保宇, 翁琪航, 卫子涵, 司风琪
(东南大学能源热转换及过程测控教育部重点实验室, 江苏 南京 210096)

[摘要] 数据驱动模型有效性取决于训练样本是否完备, 对于样本覆盖范围外的工况, 模型泛化能力较差。为构建适应机组宽负荷变化的凝汽器系统特性模型, 训练样本需包括较大变化范围的发电负荷和环境温度。然而, 新建机组因投运时间短, 无法提供完备数据集。因此, 针对不完备数据集提出了一种基于多保真度数据和迁移学习的凝汽器系统特性建模方法。该方法首先采用同类型系统的完备数据集构建预训练模型, 在预训练模型上, 新增线性和非线性校准网络, 通过新建机组的不完备数据对校准网络进行更新, 使预训练模型迁移适配不完备数据集的特征空间。最后通过某 1 000 MW 超临界机组凝汽器系统验证该方法有效性, 验证结果表明, 在训练样本不充分的情况下, 该方法能准确预测凝汽器压力和循环水出口温度等参数, 决定系数 R^2 平均值为 0.95, 明显优于传统单一数据集数据驱动模型的 R^2 平均值 0.81。

[关键词] 迁移学习; 多保真度数据; 深度学习; 凝汽器; 发电机组

[引用本文格式] 张逸佳, 任少君, 朱保宇, 等. 基于多保真度数据和迁移学习的凝汽器系统特性建模方法[J]. 热力发电, 2025, 54(11): 107-116. ZHANG Yijia, REN Shaojun, ZHU Baoyu, et al. Modeling method for characterizing condenser system based on multi-fidelity data and transfer learning[J]. Thermal Power Generation, 2025, 54(11): 107-116.

Modeling method for characterizing condenser system based on multi-fidelity data and transfer learning

ZHANG Yijia, REN Shaojun, ZHU Baoyu, WENG Qihang, WEI Zihan, SI Fengqi
(Laboratory of Energy Thermal Conversion and Control of Ministry of Education, Southeast University, Nanjing 210096, China)

Abstract: The effectiveness of a data-driven model relies on the completeness of its training samples. For operating conditions beyond the scope of the training samples, the model's generalization ability is compromised. Therefore, to develop a condenser model that can adapt to the wide load variation of the unit, it is essential for the training samples to involve a diverse range of power generation loads and ambient temperatures. However, achieving this complete dataset is difficult for newly-commissioned units because of their short operation time. To address these challenges, a method for characterizing condensing units using multi-fidelity data and transfer learning is proposed, even with incomplete data. In this method, a pre-trained model is firstly built based on the comprehensive operational dataset collected from a similar unit. On the basis of the pre-trained model, additional linear and nonlinear calibration networks are introduced. The calibration networks are updated through the incomplete data of newly constructed units, enabling the transfer of the pre-training model to the feature space that is adapted to the incomplete dataset. The effectiveness of this method is validated through the condenser of a 1 000 MW supercritical unit. The results indicate that, even with limited training samples, the method accurately predicts parameters such as condenser pressure and circulating water outlet temperature, with an average R^2 of 0.95, significantly outperforming the conventional data-driven model based on a single data set, of which the average R^2 is only 0.81.

收稿日期: 2025-01-27 网络首发日期: 2025-09-12

基金项目: 国家自然科学基金项目(52306230); 国家重点研发计划项目(2022YFB4100700)

Supported by: National Natural Science Foundation of China (52306230); National Key Research & Development Program (2022YFB4100700)

第一作者简介: 张逸佳(2001), 男, 硕士研究生, 主要研究方向为凝汽器系统特性建模, 220234970@seu.edu.cn.

通信作者简介: 司风琪(1973), 男, 教授, 博士生导师, 主要研究方向为大型火电机组运行特性、性能优化及故障诊断, fqs@seu.edu.cn.

Key words: transfer learning; multi-fidelity data; deep neural network; condenser; power plant

凝汽器是燃煤电厂的关键设备,主要通过为机组提供稳定的低温环境,从而凝结低压缸排汽并维持汽轮机排汽口真空。为了保障凝汽器高效稳定运行,对其运行参数进行监测和优化至关重要^[1-4]。由于凝汽器的运行环境复杂且受冷却水温度、热电负荷及外界气象条件等多种因素的影响,仅通过人工调整难以满足复杂的工况变化需求^[5-7]。为此,研究者常常通过建立凝汽器的系统特性模型来预测其真空度、循环水出口温度等关键参数。一方面,模型预测结果可以与实际值进行对比,通过预测偏差来判断凝汽器的运行状况,从而及时发现潜在问题并采取相应措施^[8]。另一方面,高保真的凝汽器系统特性模型能够表征运行参数在不同工况下的变化特性,为汽轮机组冷端优化提供理论依据^[9]。

目前,针对凝汽器系统特性建模的方法主要分为机理建模和数据驱动建模两大类。机理建模通过能量守恒和质量守恒等理化规律进行模型构建,也采用计算流体动力学(computational fluid dynamics, CFD)软件 Fluent 或系统级仿真平台 Apros 和 Eplison 等软件进行流动、换热等复杂过程的精细模拟^[10-12]。随着人工智能和大数据技术的快速发展,数据驱动建模方法已广泛应用于燃煤发电机组凝汽器系统建模,因其计算效率高和拟合精度良好成为研究热点^[13-15]。然而,该类模型的有效性依赖于训练数据的准确性和完整性,对于训练样本未覆盖的运行工况往往预测性能不佳。由于凝汽器换热量受多因素影响,数据驱动模型需要训练样本覆盖较广的发电负荷和环境温度变化范围,当面向新建机组或系统内设备维护(清洁、修理、更换)等情况时,训练样本覆盖的运行工况则不够完备^[16-17]。

面向不完备数据集的建模方法已成为数据驱动建模领域一个公认的难点^[18]。迁移学习通过将源任务的知识迁移到目标任务中,能够在目标任务数据不足时提高模型的泛化能力,特别适用于数据不完备的情况^[19-20]。Torzoni 等人^[21]通过简化模型生成大量低保真仿真数据,再采用迁移学习将低保真仿真数据与高精度有限元模型获得的高保真数据相结合,成功构建了结构健康监测的代理模型,结果表明该策略能够提供比单一保真度方法更准确的预测结果。任少君等^[22]则通过模型迁移学习将 Aspen Plus 仿真数据与实验数据融合,建立了一种

高精度的生物质气化产物预测模型。此外, Geng 等人^[23]将 BEMT 模型生成的低保真数据和 CFD 模拟得到的高保真数据相融合,进一步建立了螺旋桨叶片空气动力学和气动声学性能优化代理模型。

在凝汽器建模场景中,除目标凝汽器运行数据外,也存在着多种不同保真度的数据来源。如通过机理模型可以生成大量仿真数据,目标凝汽器在检修前存储了长时周期的运行数据,或不同机组同类型凝汽器也可提供海量运行数据。虽然这些数据不能直接用于目标凝汽器的特性建模,但与目标凝汽器运行数据存在着一定的共性关系。为此,本文通过迁移学习的思想来有效利用低保真数据的广度与高保真数据的精度,弥补样本量不足的问题,进而在凝汽器建模中构建更稳定和准确的特性模型。

以某新建百万机组为例,由于机组运行时间短,因此已存储的运行数据不足以构建准确的凝汽器特性模型。为此,本文充分考虑了同类型机组的长时段运行数据与目标机组少量运行数据的相似性和差异性,提出了一种基于多保真度数据和迁移学习(multi-fidelity data and transfer learning, MF-TL)的凝汽器系统特性建模方法,从而解决不完备数据集场景下的凝汽器系统特性建模问题。对于目标新建机组而言,同类型机组的长时段运行数据为低保真数据,目标机组本身的少量运行数据为高保真数据。该方法首先利用同类型机组大量低保真运行数据对凝汽器系统模型进行训练,得到预训练模型。然后,利用新建机组少量高保真运行数据对预训练模型进行更新,实现模型迁移。最后,通过工程实例验证所提出的 MF-TL 方法的有效性。

1 建模方法

1.1 基于深度神经网络的预训练模型

神经网络(deep neural network, DNN)通过引入多层结构,能够捕捉复杂数据特征并处理非线性、高维问题。本文基于给定源域数据集 $D_S = \{x_s, y_s\}$, 采用神经网络建立凝汽器系统特性模型。该 DNN 模型包含 n 个输入层节点、 m 个输出层节点以及 L 个隐含层。模型输入记为 $x = [x_1, x_2, \dots, x_n]^T$, 第 l 层隐含层的输出为:

$$A_l = g(W_l A_{l-1} + b_l), l = 1, 2, \dots, L \quad (1)$$

式中: W_l 为连接第 $l-1$ 层与第 l 层的权重矩阵; b_l

为偏置项; $g(\tau)=\max(0, \tau)$ 为 RELU 激活函数。

因此, DNN 模型的输出可表示为:

$$\hat{y} = f(x) = g(W_l A_l + b_l) \quad (2)$$

式中: \hat{y} 为模型输出。

为了评估模型的性能, 将模型输出值与真实测试值进行对比, 并通过计算损失函数来量化误差。这里采用均方误差 (mean square error, δ_{MSE}) 作为损失函数, 其计算公式为:

$$\delta_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_L - y_L)^2 \quad (3)$$

式中: N 为训练样本数量; y 为训练样本真实值。

本文采用反向传播 (back propagation, BP) 算法来进行 DNN 网络的参数优化, BP 算法通过最小化损失函数来更新权重与偏置, 该优化过程为:

$$dW_l = \frac{\partial \delta_{\text{MSE}}}{\partial W_l}, db_l = \frac{\partial \delta_{\text{MSE}}}{\partial b_l} \quad (4)$$

$$W_l = W_l - l_r dW_l, b_l = b_l - l_r db_l \quad (5)$$

式中: dW_l 和 db_l 分别为损失函数对第 l 层隐含层权重和偏置的偏导数; l_r 为学习率。

在训练过程中, 选取合适的超参数, 主要包括隐含层层数、每层神经元个数、学习率 l_r 和训练次数 N_e 。考虑到源域数据量较大, 在预训练过程中以较大的学习率 l_r 和训练次数 N_e 来迭代更新网络权重。基于源域数据集预训练出的 DNN 模型只是一个近似模型, 称为低保真模型。

1.2 模型迁移

本文在预训练模型的基础上, 通过模型迁移的方式将预训练模型调整至与目标域数据集 $D_T=\{x_T, y_T\}$ 相匹配的特征空间^[24]。模型迁移的关键点是发现和利用预训练模型和目标域数据集之间的关联^[25], 实现对目标任务的有效适配。其关联式可表示为:

$$y_H = F(x, y_L) \quad (6)$$

式中: x 为模型输入; y_H 和 y_L 分别为目标域数据集和对应预训练模型的输出值。

$F(\cdot)$ 可以分解为线性和非线性两部分, 用于自适应地挖掘目标域数据与源域数据之间线性和非线性关联, 即为:

$$F = F_1 + F_{nl} = \alpha F_1(x, y_L) + (1 - \alpha) F_{nl}(x, y_L) \quad (7)$$

式中: F_1 和 F_{nl} 分别为 $F(\cdot)$ 中线性项和非线性项; α 为 $F(\cdot)$ 中线性项的权重因子。

综上, 模型迁移的具体流程如图 1 所示。本文所提出的多保真模型由 1 个预训练的神经网络 (NN_L) 和 2 个校准网络 (NN_{H1} 和 NN_{H2}) 共 3 个

神经网络组成。 NN_L 是源域数据集建立的神经网络预训练模型, NN_{H1} 和 NN_{H2} 分别表征式(7)中的线性项 F_1 和非线性项 F_{nl} 。

多保真模型采用 BP 算法进行模型训练, 包括预训练和模型迁移 2 个步骤。首先使用源域数据集预训练 NN_L 模型, 其损失函数为:

$$\delta_{\text{MSE,L}} = \frac{1}{N_L} \sum_{i=1}^{N_L} (\hat{y}_L - y_L)^2 \quad (8)$$

式中: \hat{y}_L 为预训练网络的预测输出值。

之后进行模型迁移, 冻结预训练模型 NN_L 的网络参数, 通过训练 NN_{H1} 和 NN_{H2} 校准网络, 对预训练模型 NN_L 进行调整, 从而最小化多保真模型在目标域数据集样本上的预测误差。其损失函数为:

$$\delta_{\text{MSE,H}} = \frac{1}{N_H} \sum_{i=1}^{N_H} (\hat{y}_H - y_H)^2 \quad (9)$$

式中: \hat{y}_H 为多保真模型的预测输出值。

在迁移过程中目标域数据量有限的情况下, 模型性能对超参数设置尤为敏感。学习率直接影响收敛性和泛化能力, 网络结构决定特征提取与过拟合的平衡, 而训练次数则影响模型收敛程度和计算效率。因此, 本文通过网格搜索、隐含层结构设计以及训练次数控制的方式进行超参数优化。为实现模型在有限数据条件下的稳定训练, 采用较低的学习率 l_{r2} 和训练次数 N_{e2} 进行训练, 在保证训练速度的同时减小波动。构造多保真模型算法流程的详细步骤如下。

阶段 1: 预训练模型 NN_L 阶段

1) 输入: 源域数据集, 目标域数据集;

2) 随机初始化网络参数;

3) 使用源域数据集训练模型 NN_L , 根据式(8)最小化损失函数;

4) BP 算法参数更新, 直到损失函数收敛结束迭代, 训练完成。

阶段 2: 基于多保真度数据的模型迁移阶段

1) 冻结预训练 NN_L 模型的网络参数;

2) 随机初始化网络参数 NN_{H1} 和 NN_{H2} 校准网络参数;

3) 使用目标域数据集训练 NN_{H1} 和 NN_{H2} 2 个校准网络, 根据式(9)最小化损失函数;

4) BP 算法参数更新, 直到损失函数收敛结束迭代, 训练完成;

5) 输出: 模型预测值。

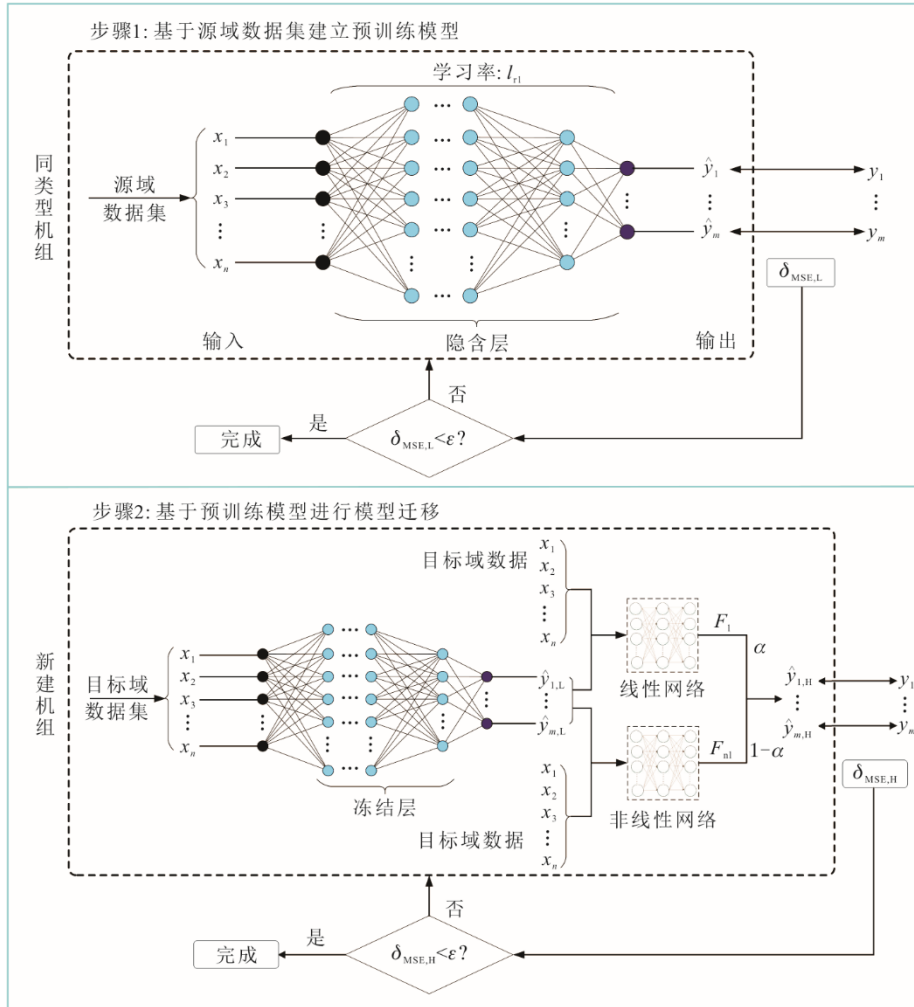


图 1 基于多保真度数据和迁移学习的建模方法
Fig.1 The modeling method based on multi-fidelity data and transfer learning

2 模型建立

2.1 对象分析

模型相关的输入和输出参数信息见表 1。

表 1 凝汽器建模输入变量、输出变量
Tab.1 Input and output variables for modeling a condenser

输入变量	输出变量
机组负荷, MW	凝汽器 A 真空压力, kPa
循环水进水温度, °C	凝汽器 B 真空压力, kPa
循环水流量, kg/s	凝汽器 A 温度, °C
循环水进水压力, MPa	凝汽器 B 温度, °C
循环水出水压力, MPa	循环水连接管温度, °C
LP 汽缸 A 排气压力, kPa	循环水出口温度, °C
LP 汽缸 B 排气压力, kPa	热井出口温度, °C
冷凝水流量, kg/s	
热井水位, mm	

本文研究对象为 1000 MW 新建机组, 以该同类机组为源域机组。先从源域机组的监控信息系统

(supervisory information system, SIS) 中以 1 min 采样频率采集 84 960 个连续样本 D_L 。从目标域机组的 SIS 中以同样参数和采样频率, 采集 43 200 个连续样本 D_H 。作为预处理步骤, 对所有的输入变量进行了高斯标准化处理, 确保所有变量的数据分布一致。

2.2 多保真模型建立

为分析不同模型的预测效果, 建立 3 种模型:

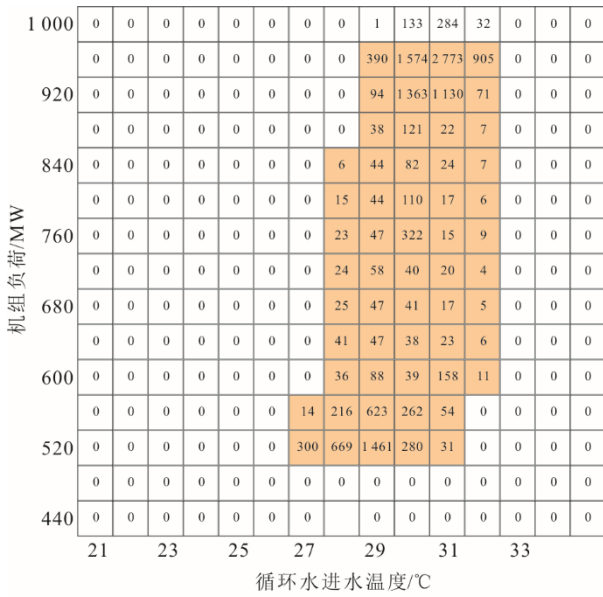
1) 模型 1, 基于有限高保真数据建立的模型将数据集 D_H 前 14 400 条样本记为训练集 T_{cH} , 将数据集 D_H 中剩余的 28 800 条样本记为测试集 T_{eH} 。基于训练集 T_{cH} 构建 DNN 模型进行训练, 对测试集 T_{eH} 进行模型测试, 观察模型 1 的预测精度。

2) 模型 2, 基于充分低保真数据建立的模型以数据集 D_L 为训练集建立 DNN 模型, 以数据集 D_H 为测试集进行模型测试, 观察模型 2 预测结果。

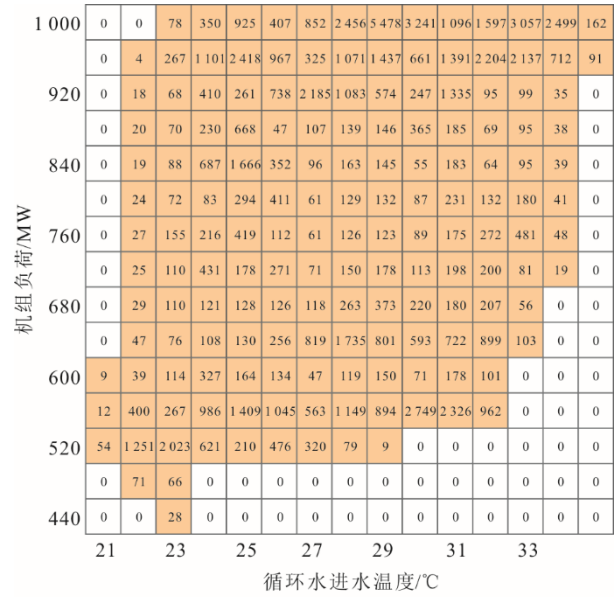
3) 模型 3, 结合有限高保真数据和充分低保真数据建立的多保真模型 该模型采用模型 1 作为预

训练模型。预训练完成后冻结模型 1 的网络结构参数并在此基础上新增线性 and 非线性校准网络。基于训练集 T_{H} 的数据对校准网络进行更新，得到模型 3，以测试集 T_{eH} 对模型进行测试，将模型 3 的性能与模型 1 和模型 2 的性能进行对比。

图 2 给出了目标域机组不完备数据集 T_{H} 和源域机组完备数据集 D_{L} 的数据分布。图 2 中框内数字表示对应工况所含数据样本的数量大小，颜色为所取数据集覆盖的工况范围。由图 2 可见， D_{L} 中机组负荷和循环水进水温度的覆盖区间分别为 [440, 1 000] MW 和 [21, 35] °C，而 T_{H} 中机组负荷和循环水进水温度的覆盖区间分别为 [520, 1 000] MW 和 [27, 32] °C。由于源域机组运行时间较长， D_{L} 覆盖的机组负荷与循环水进水温度范围较大。相对而言，目标机组投运时间较短， T_{H} 工况覆盖率较低。



a) 目标域机组不完备数据集



b) 源域机组完备数据集

图 2 数据集样本分布
Fig.2 Distributions of the dataset samples


为了比较不同模型的精度，3 个模型的深度神经网络部分具有相同的网络结构和参数配置，均采用 5 层神经网络结构，第一层输入层，中间三层为隐含层，神经元个数均为 10 个，最后一层为输出层。模型 1、模型 2 和模型 3 的学习率 l_1 和循环次数 N_{e1} 均设定为 10^{-3} 和 10 000。本文算法在 Python 3.8 以及

PyTorch-2.0.1 版本的开发环境下通过 Visual Studio Code 1.89.1 编辑器编程实现。


3 结果分析

3.1 模型精度

图 3 给出了基于有限高保真数据的模型 1 的预测结果。



a) 低压凝汽器压力



b) 高压凝汽器压力

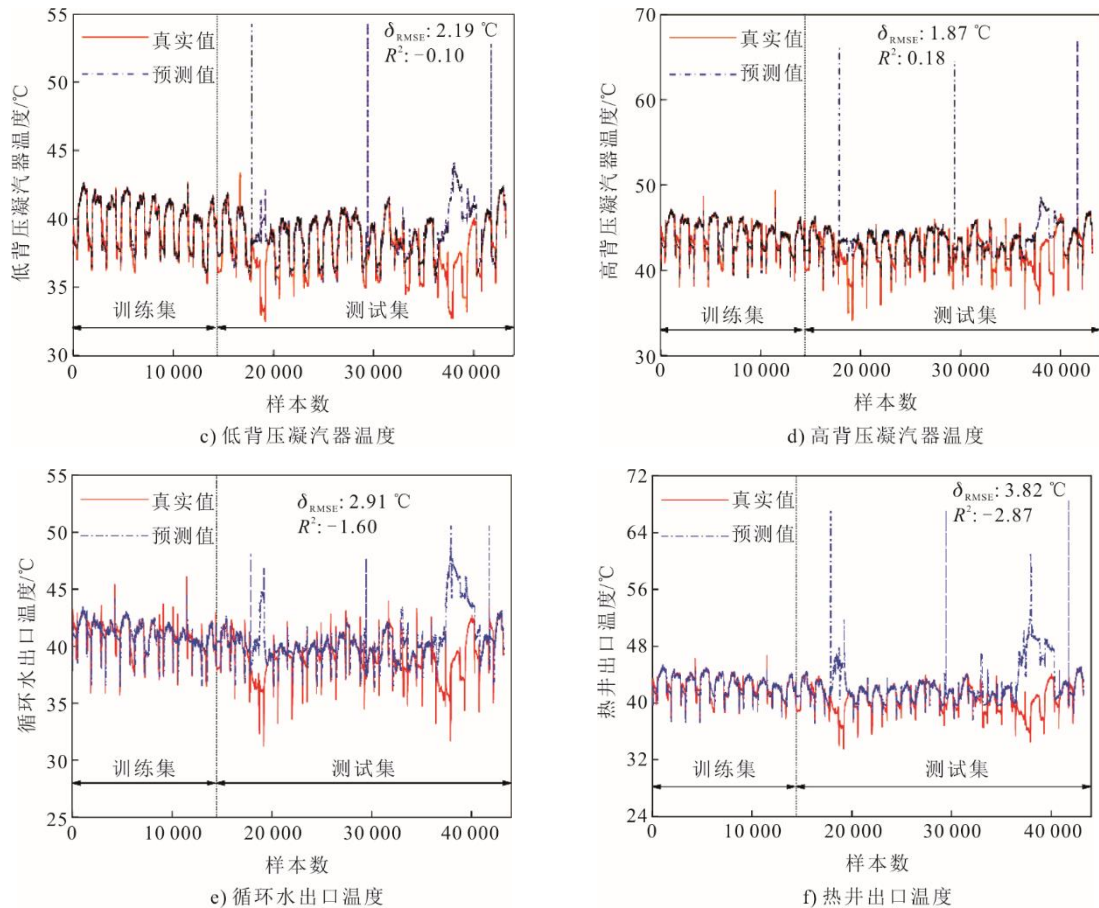




图3 基于有限高保真数据的模型预测效果
Fig.3 The model prediction performance based on limited high-fidelity data

从图3可以看出,模型预测值与真实值较为吻合,但在样本数18 000~20 000以及36 000~40 000这2段预测的结果都较差,即该模型在测试数据集的部分工况(如循环水进水温度23~25℃)表现不佳。具体来说,图3a)中低背压凝汽器压力的预测值与实际测量值在绿色圈内有较大的偏差,均方根误差为1.62 kPa,决定系数 R^2 低至-3.88。这是由于训练集 T_{H} 中样本的循环水进水温度所覆盖的区间为[27, 32]℃,而圈内包含的测试集样本循环水进水温度覆盖的区间为[23, 25]℃,即该部分样本处在训练样本覆盖范围以外的工况。因此模型表现出泛化能力不足的特性,无法准确预测出低背压凝汽器压力。


图4给出了基于充分低保真数据的模型2的预测结果。值得注意的是,该模型是以同类型机组充分低保真数据为训练样本,以目标新建机组的运行数据为测试样本。从图4可以看出,模型预测结果与测试数据的变化趋势保持一致,但存在明显偏移。这说明源域机组与目标域机组凝汽器系统具有

共性特征,但由于测点安装位置和凝汽器本身特性存在差异,所以在相似工况下其参数预测值存在一定的偏差。如图4a)所示,低背压凝汽器压力的2条曲线存在约1 kPa的偏离。这表明2台机组数据之间存在相关性,在近似运行条件下目标域机组低背压凝汽器压力比源域机组整体偏高。由此可见,直接用源域模型对目标域系统进行预测会带来较大的预测误差。







b) 高背压凝汽器压力




f) 热井出口温度




c) 低背压凝汽器温度




d) 高背压凝汽器温度



e) 循环水出口温度



a) 低背压凝汽器压力



b) 高背压凝汽器压力

图 4 基于充分低保真数据的模型预测效果
Fig.4 The model prediction performance based on sufficient low-fidelity data

图 5 给出了多保真模型的预测效果。由图 5 可以看出，与单一保真度模型相比，多保真模型的预测值更接近真实值，低背压和高背压凝汽器压力的均方根误差分别降低至 0.10 kPa 和 0.15 kPa，低背压凝汽器温度、高背压凝汽器温度、循环水出口温度和热井出口温度的均方根误差分别降低至 0.45、0.34、0.43、0.48 °C，R² 值也均提升至 0.9 以上。




图5 多保真模型预测效果

Fig.5 The prediction performance of multi-fidelity model

图6比较了3种模型的预测性能。由图6可见,就 R^2 值而言,基于多保真度数据的模型3明显优于基于有限高保真数据的模型1和基于充分低保真数据的模型2,模型3所有参数的 R^2 值均接近1,均值为0.95,远高于模型2($R^2=0.81$)和模型1($R^2=-1.53$)。这表明多保真模型能够准确预测在目标域机组中凝汽器系统的关键参数的趋势。通过根据测量值偏差设置适当的阈值,可以在模态变化后监测凝汽器的特性。




图6 不同模型预测性能比较

Fig.6 Performance comparison between different models

3.2 模型可解释性

3.2.1 合成样本验证

为了进一步评估3种模型的可解释性。本文以某一测试样本为基础,设定负荷为650 MW,循环水入口温度范围为 $20\sim 36\text{ }^{\circ}\text{C}$,步长为 $1\text{ }^{\circ}\text{C}$,其他输入参数保持不变,共得到16组合成样本。

图7比较了3种模型对合成样本的预测结果。由图7可以看出,由于训练样本有限,基于有限高保真数据的模型1未能捕捉到低温范围内的凝汽器压力特性,导致曲线趋势出现偏差。基于充分低保真数据的模型2的预测曲线几乎是一条直线,有效地反映了随着循环水进水温度升高,凝汽器整体换热量减少,进而导致凝汽器压力增加的线性关系。然而,在循环水入口温度较高的范围内,曲线垂直偏离基于有限高保真数据的模型1。这一偏差主要源于源域与目标域机组数据的差异,进而导致基于低保真数据的模型出现预测偏差,影响预测精度。基于多保真度数据的模型3在保留基于充分低保真数据的模型参数关系的同时,增强了泛化能力,对目标域机组凝汽器的预测更加准确。




图 7 合成样本预测值对比
Fig.7 Prediction values of different synthetic samples

3.2.2 误差分布验证

采用平方预测误差 (squared prediction error, δ_{SPE}) 指标来评估模型的可解释性。该指标是用来衡量模型预测值与真实值之间偏差的平方和, 数值越小, 表示模型的性能越好。 δ_{SPE} 计算公式为:

$$\delta_{SPE} = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (10)$$

式中: N 为样本数量; y_i 和 \hat{y}_i 分别为第 i 个样本真实值及其模型预测值。

分别计算基于有限高保真数据的模型 1 与基于多保真度数据的模型 3 针对目标域机组数据集 D_H 的 δ_{SPE} 指标, 将 δ_{SPE} 根据样本的机组负荷与循环水进水温度分为不同工况后求和取平均, 绘制 δ_{SPE} 根据样本工况的分布对比图 (图 8)。由图 8 可以看出, 基于有限高保真数据的模型 1 在训练集的表现很好, 当样本的循环水进水温度偏低时, δ_{SPE} 值明显增加。温度偏离训练集覆盖范围越远, δ_{SPE} 越高。而基于多保真度数据的模型 3 通过学习完备数据集中的规律, 能够在未被训练集覆盖的较低循环水进水温度区间也表现出很高的精度。可见, 多保真模型能够在包括无样本区域在内的较大工况范围内, 保持机理规律的一致性, 得到的预测结果比单一模态数据更具有可解释性。

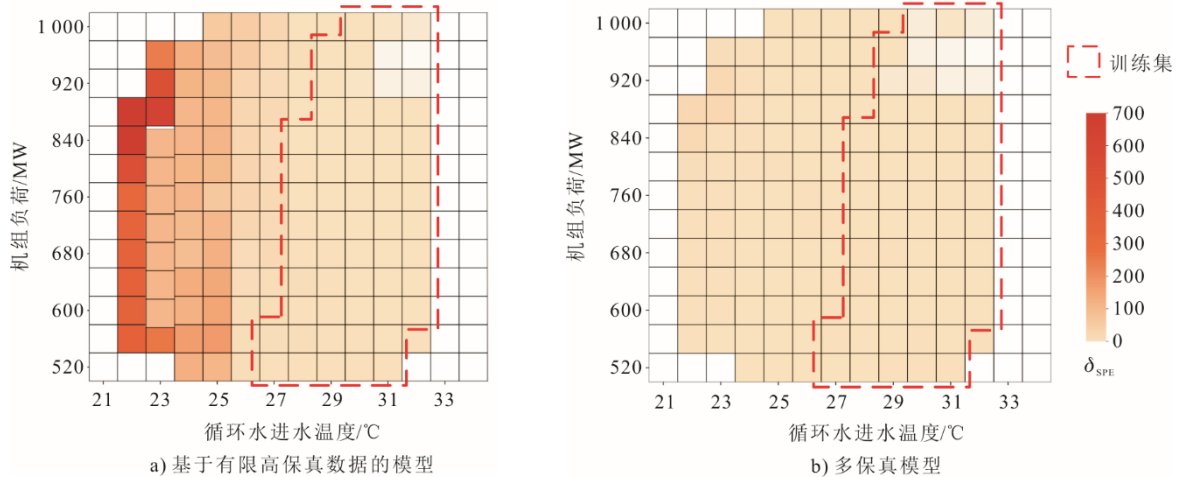


图 8 误差分布对比
Fig.8 Comparison of error distributions

4 结 论

1) 本文提出了面向不完备数据集的 MF-TL 凝汽器系统特性建模方法, 该方法通过采集同类型机组凝汽器系统运行数据构建预训练模型, 并利用新建机组有限的高保真数据对预训练模型进行迁移优化。

2) 本文 MF-TL 模型在预测精度和泛化能力方面均优于传统的单一保真度模型, 低背压凝汽器压力和高背压凝汽器压力的均方根误差分别降低至 0.10 kPa 和 0.15 kPa, 低背压凝汽器温度、高背压凝汽器温度、循环水出口温度和热井出口温度的均方

根误差分别降低至 0.45、0.34、0.43、0.48 °C, R^2 均值为 0.95, 满足高精度预测需求。

3) 本文方法在运行数据不完备的情况下, 也能够 在宽工况范围内给出符合机理规律的预测结果, 具有较高的物理可解释性。

[参考文献]

[1] 杜小泽, 金衍胜, 姜剑波, 等. 火电厂直接空冷凝汽器传热性能实验研究[J]. 工程热物理学报, 2009, 30(1): 99-101.
DU Xiaoze, JIN Yansheng, JIANG Jianbo, et al. Experimental study on heat transfer performance of direct air-cooled condenser in power plant[J]. Journal of Engineering Thermophysics, 2009, 30(1): 99-101.

- [2] JIANG J. Fault diagnosis of condenser based on wavelet neural network[J]. *Industrial Engineering Journal*, 2010, 13(4): 104-107.
- [3] ZHONG D, ZENG H, MENG J, et al. Numerical simulation of power plant condenser performance and roles for tube arrangement[J]. *Journal of Engineering Thermophysics*, 2014, 35(1): 123-127.
- [4] 薛倩. 凝汽器强化传热研究[J]. *当代化工*, 2020, 49(9): 2037-2040.
XUE Qian. Study on enhanced heat transfer of condenser in power plant[J]. *Contemporary Chemical Industry*, 2020, 49(9): 2037-2040.
- [5] WANG J, WANG H, BI W. Research of energy consumption of evaporative condenser in ammonia refrigeration system[J]. *Cryogenics & Superconductivity*, 2011, 31(10): 74-77.
- [6] WANG Q, LIU B, DONG X, et al. Performance characteristics of microchannel condenser under different heat loads[J]. *Cryogenics*, 2014(5): 58-62.
- [7] HAJIDAVALLOO E, EGHTEADARI H. Performance improvement of air-cooled refrigeration system by using evaporatively cooled air condenser[J]. *International Journal of Refrigeration*, 2010, 33(5): 982-988.
- [8] 张远绪. 基于 PSO-DDSAEN 的凝汽器故障诊断研究[D]. 青岛: 青岛科技大学, 2019: 1.
ZHANG Yuanxu. Research on condenser fault diagnosis based on PSO-DDSAEN[D]. Qingdao: Qingdao University of Science and Technology, 2019: 1.
- [9] 冯金金, 章颖, 李健平, 等. 1 000 MW 燃煤机组双压凝汽器冷端系统运行优化[J]. *科技和产业*, 2024, 24(21): 198-204.
FENG Jinjin, ZHANG Hao, LI Jianping, et al. Operation optimization of the cold end system with dual-pressure condenser of 1 000 MW coal-fired unit[J]. *Science Technology and Industry*, 2024, 24(21): 198-204.
- [10] HAFJEJE R A, LAUBSCHER R. Development of a thermofluid network modeling methodology for double-row air-cooled condensers[J]. *Thermal Science and Engineering Progress*, 2020, 19: 100646.
- [11] 朱自强. 不同凝汽器冷却方式的燃气蒸汽联合循环系统热经济性研究[D]. 北京: 华北电力大学, 2022: 1.
ZHU Ziqiang. Study on thermoeconomic performance of gas-steam combined cycle system with different condenser cooling modes[D]. Beijing: North China Electric Power University, 2022: 1.
- [12] 代雨辰. 基于机器学习的凝汽器设备故障分类方法研究[D]. 南京: 东南大学, 2022: 1.
DAI Yuchen. Research on fault classification method of condenser based on machine learning[D]. Nanjing: Southeast University, 2022: 1.
- [13] WU D, ZHOU D, ZHANG J, et al. Multimode process monitoring based on fault dependent variable selection and moving window-negative log likelihood probability[J]. *Computers & Chemical Engineering*, 2020, 136: 106787.
- [14] WU H, ZHAO J. Self-adaptive deep learning for multimode process monitoring[J]. *Computers & Chemical Engineering*, 2020, 141(20): 107024.
- [15] ZAMZAM A S, FU X, SIDIROPOULOS N D. Data-driven learning-based optimization for distribution system state estimation[J]. *IEEE Transactions on Power Systems*, 2019, 34(6): 4796-4805.
- [16] 高建强, 王艳. 基于 BP 神经网络的直接空冷凝汽器换热性能预测[J]. *动力工程学报*, 2013, 33(6): 443-447.
GAO Jianqiang, WANG Yan. BP neural network prediction on heat-transfer performance of direct air-cooled condensers[J]. *Journal of Chinese Society of Power Engineering*, 2013, 33(6): 443-447.
- [17] LI X, WANG N, WANG L, et al. A data-driven model for the air-cooling condenser of thermal power plants based on data reconciliation and support vector regression[J]. *Applied Thermal Engineering Design Processes Equipment Economics*, 2018, 129: 1496-1507.
- [18] LAI C, BARALDI P, ZIO E. Physics-informed deep autoencoder for fault detection in new-design systems[J]. *Mechanical Systems & Signal Processing*, 2024, 215: 111420.
- [19] 王力光, 贡勇博, 朱保宇, 等. 基于迁移学习的湿法烟气脱硫系统出口 SO₂ 浓度预测研究[J]. *发电设备*, 2021, 35(6): 420-425.
WANG Liguang, YUN Yongbo, ZHU Baoyu, et al. Research on the prediction of SO₂ concentration at the outlet of wet flue gas desulfurization system based on transfer learning[J]. *Power Equipment*, 2021, 35(6): 420-425.
- [20] BENJAMIN P, KAREN W, MAX G. Survey of multifidelity methods in uncertainty propagation, inference, and optimization[J]. *SIAM Review*, 2018, 60(3): 550-591.
- [21] TORZONI G, MANZONI R, MARIANI S. A multi-fidelity surrogate model for structural health monitoring exploiting model order reduction and artificial neural networks[J]. *Mechanical Systems and Signal Processing*, 2023, 197: 110376.
- [22] 任少君, 朱保宇, 翁琪航, 等. 基于数据增强和模型迁移的生物质气化产物分布预测方法[J]. *中国电机工程学报*, 2024, 44(18): 7309-7321.
REN Shaojun, ZHU Baoyu, WENG Qihang, et al. Prediction method of biomass gasification product distribution based on data augmentation and model migration[J]. *Proceedings of the CSEE*, 2024, 44(18): 7309-7321.
- [23] GENG X, LIU P, HU T, et al. Multi-fidelity optimization of a quiet propeller based on deep deterministic policy gradient and transfer learning[J]. *Aerospace Science and Technology*, 2023, 137: 108288.
- [24] YE X, NI Y Q, SAJJADI M, et al. Physics-guided, data-refined modeling of granular material-filled particle dampers by deep transfer learning[J]. *Mechanical Systems & Signal Processing*, 2022, 180: 109437.
- [25] GISELLE M, PARK C, KIM N H, et al. Review of multi-fidelity models[J]. *Advances in Computational Science and Engineering*, 2017, 1(4): 351-400.

(责任编辑 杜亚勤)