

基于 TCAN 混合模型的火电过热蒸汽温度预测研究

姚 振

(国能神华九江发电有限责任公司, 江西 九江 332504)

摘 要:火电机组的大范围变负荷运行对过热蒸汽温度(SST)的稳定性提出了更高要求,准确有效地预测 SST 对控制过热系统至关重要。文中提出一种基于多元时序集成方法的 SST 预测模型,在时间卷积神经网络(TCN)的基础上引入注意力机制(Attention TCN, TCAN),提升对 SST 多元时序数据特征的提取能力,并将能量守恒约束作为等式约束引入 TCAN 架构的数据驱动模型损失函数中,以增强模型泛化能力。将 SST 与喷水流量之间的物理关系作为不等式约束条件引入上述损失函数,使混合模型可表征正确的物理特征。为验证所提方法的优越性,基于火电厂采集的大范围负荷变化的运行数据进行了仿真测试。结果表明:在不同测试集下,相比物理模型和数据驱动模型,基于物理损失函数混合模型的均方根误差 RMSE 平均降低 22.4% 和 43.8%,平均绝对误差 MAE 平均降低 24.6% 和 58.9%,决定系数 R^2 平均提升 7.3% 和 12.1%;混合模型的预测效果不仅具有通用性,而且与阶跃响应的动态特性保持科学一致。

关 键 词:火电厂;注意力机制;时间卷积神经网络;主蒸汽温度;混合建模;预测

中图分类号:TP183 文献标识码:A DOI:10.16146/j.cnki.rndlgc.2025.04.013

[引用本文格式]姚 振. 基于 TCAN 混合模型的火电过热蒸汽温度预测研究[J]. 热能动力工程, 2025, 40(4): 115-124. YAO Zhen. Prediction of superheated steam temperature in thermal power plant based on TCAN hybrid model[J]. Journal of Engineering for Thermal Energy and Power, 2025, 40(4): 115-124.

Prediction of Superheated Steam Temperature in Thermal Power Plant based on TCAN Hybrid Model

YAO Zhen

(Guoneng Shenhua Jiujiang Power Generation Co., Ltd., Jiujiang, China, Post Code: 332504)

Abstract: The large-scale variable load operation of thermal power units poses a severe challenge to the stability of superheated steam temperature (SST). Accurate and effective prediction of SST plays an important role in the control of superheated system. In this paper, a SST prediction model based on multivariate time series integration method was proposed. Attention TCN (TCAN) was introduced on the basis of time convolution neural network (TCN) to improve the feature extraction ability of SST multivariate time series data. Then, energy conservation constraints were introduced into the data-driven model loss function of TCAN architecture as equality constraints to enhance the generalization ability of the model. The physical relationship between SST and water jet flow was introduced into the above loss function as an inequality constraints, so that the hybrid model can characterize the correct physical characteristics. In order to verify the superiority of the proposed method, the simulation verification was carried out based on the operation data of large-scale load changes collected by thermal power plants. The comparison results show that in different test datasets, compared with the physical model and the data-driven model, the root mean square errors (RMSE) of the hybrid model based on the physical loss function are reduced by

22.4% and 43.8% on average, mean absolute errors (MAE) are reduced by 24.6% and 58.9% on average and determination coefficients R^2 are increased by 7.3% and 12.1% on average. The prediction effect of the hybrid model is not only universal, but also scientifically consistent with the dynamic characteristics of step response.

Key words: thermal power plant, attention mechanism, time convolution neural network, main steam temperature, hybrid modeling, prediction

引 言

电力系统中间歇性可再生能源的快速增长对电网的稳定性和安全性带来了严峻挑战^[1-2]。燃煤电厂的灵活运行在快速响应电力需求方面发挥着至关重要的作用^[3]。然而,火电机组的大范围变负荷调节过程中,过热蒸汽温度(SST)的稳定性面临严峻挑战^[4-6]。传统的 SST 串级 PI 控制策略难以有效保证 SST 的控制性能^[7-8],而开发先进控制策略的前提是准确建立被控对象模型,以精确模拟实际运行情况,尤其是变工况下的运行^[8-9]。因此,构建精确的 SST 动态预测模型对机组的安全、经济运行至关重要。

目前,多种基于物理的建模技术被用于揭示 SST 的动态特性。文献[10]采用流体动力学(CFD)建模方法评估不同负荷下屏式和末级过热器的热性能,但由于 CFD 模型自身的计算特点,在满足实时预测方面存在一定局限性^[11]。应用线性传递函数^[12]和集总非线性动态建模方法^[13]可有效降低仿真过程的复杂性,但线性传递函数模型是基于运行点附近的拉普拉斯转换建立的,因此难以准确模拟非稳态运行的动态过程。

数据驱动模型作为一种无需详细机理知识的人工智能方法,在电力工程领域备受关注。基于 T-S (Takagi-Sugeno, T-S) 模糊方法建立的数据驱动模型可近似计算 SST 的动态特性^[14]。但由于所辨识模型的状态变量缺乏明确的物理意义,因此很难对模型进行解释。近年来,多层感知器神经网络(MLP)、卷积神经网络(CNN)、长短期记忆网络(LSTM)等深度学习模型受到广泛关注,并被广泛应用于物理系统建模任务中。但单一的高方差、低偏差深度学习模型很难在复杂多变的任务过程中保持较高的预测精度和鲁棒性^[15-16]。

考虑到物理模型和数据驱动模型的局限性,许

多学者对上述两种模型的结合进行了研究。一些研究提出了集成数据驱动模型,通过结合动态线性慢特征分析来捕捉潜在变量,从而提高模型的泛化性能^[17]。在学习目标中使用基于物理约束的损失函数,以确保数据驱动模型的预测与已知物理特征一致^[18]。混合建模已广泛应用于其他领域^[19-21]。同时,发电领域也在逐渐应用集成数据驱动模型解决过程建模、机组优化等问题,文献[22]针对火电机组设备多模态变工况运行特性,提出一种融合物理约束的多模态混合建模方法,文献[23]则基于热力学理论和模糊粗糙集方法构建了混合建模方法,以处理大容量的运行数据并优化火电机组的能耗。然而,在过热系统的 SST 预测方面,对混合建模的研究仍较少。

本文提出了一种基于多元时序预测混合建模方法,并构建了新型 SST 预测框架。通过在损失函数中加入能量守恒约束,使混合模型具有较高的预测能力和泛化能力。此外,通过引入输入与输出间的物理关系作为不等式约束条件,混合模型可表征正确的物理特征。将所提出的方法应用于燃煤电厂 SST 预测的建模过程,对预测结果进行了比较和讨论,所得结果为火电厂各系统的动态响应建模提供了有力的借鉴思路。

1 火电厂 SST 系统分析

1.1 SST 系统描述

本文研究对象为内蒙古某 660 MW 火力发电机组。火电机组结构原理如图 1 所示。汽包中的微过热蒸汽从给水中分离后,依次经常初级过热器、分隔过热器、屏式过热器和末级过热器吸收热量,逐渐被加热并转化为合格的过热蒸汽,最终送入高压汽轮机。

SST 主要受锅炉燃烧状态、煤质特性以及大范围负荷调节的影响。其中锅炉燃烧受到机组负荷、煤粉量、风量等多种运行参数的影响,最终导致 SST

稳定性降低。本文所选 SST 预测的变量如表 1 所示,其中序号 $x_1 \sim x_{33}$ 为模型输入变量,序号 y 为模型输出变量。




图 1 锅炉机组流程
Fig. 1 Process diagram of boiler unit

表 1 SST 混合预测模型的变量

Tab. 1 Variables of SST hybrid prediction model

序号	参数	名称
x_1	$N_{\text{unit}}/\text{MW}$	机组负荷
x_2	$Q_c/t \cdot h^{-1}$	燃煤总流量
x_3	$Q_{\text{air}}/t \cdot h^{-1}$	空气总流量
x_4	$t_{\text{gas}}/^{\circ}\text{C}$	锅炉出口烟气温度
x_5	$Q_{\text{so}}/t \cdot h^{-1}$	蒸汽流量
x_6	$t_{\text{in}}/^{\circ}\text{C}$	过热器入口蒸汽温度
x_7	$Q_{\text{sw}}/t \cdot h^{-1}$	喷水流量
x_8	$Q_{\text{si}}/t \cdot h^{-1}$	喷水减温器入口蒸汽流量
x_9	$V_{\text{sa}}/\%$	喷水减温器阀门开度
x_{10}	p_{si}/MPa	喷水减温器蒸汽压力
x_{11}	$t_{\text{si}}/^{\circ}\text{C}$	喷水减温器入口蒸汽温度
$x_{12} \sim x_{27}$	$t_{\text{tm}}^1 \sim t_{\text{tm}}^{16}/^{\circ}\text{C}$	屏式过热器管道温度
$x_{28} \sim x_{33}$	$I_1 \sim I_6/\text{A}$	磨煤机电流
y	$t_{\text{out}}/^{\circ}\text{C}$	过热器出口蒸汽温度

1.2 SST 系统运行过程的能量守恒

在过热蒸汽系统中,整个过热器管道的总吸收能量 E_{so} 由过热器进出口焓差 Δi 和蒸汽流量 Q_{so} 决定。其关系式为:

$E_{\text{so}} = \Delta i \cdot Q_{\text{so}}$ (1)

由于蒸汽焓可表示为压力和温度的函数,因此可改写为:

$E_{\text{so}} = [f(p_{\text{out}}, t_{\text{out}}) - f(p_{\text{in}}, t_{\text{in}})] \cdot Q_{\text{so}}$ (2)

式中: p_{in} —过热器入口压力,MPa; p_{out} —过热器出口压力,MPa。

沿蒸汽流动方向的压力分布由动量守恒定律决定。过热器的入口或出口压力可通过压差关系获得。具体表达式为^[24]:

$$\Delta p = \frac{\xi}{d_h} \rho_s \frac{w_s |w_s|}{2}$$
 (3)

式中: ξ —摩擦因子; d_h —过热器管径,m; w_s —蒸汽速度,m/s; ρ_s —蒸汽密度,kg/m³。

摩擦因子 ξ 由普兰特尔-冯卡尔马公式计算得出:

$$\xi = \frac{1}{4 \left(\log 3.7 \frac{d_h}{R_a} \right)^2}$$
 (4)

式中: R_a —粗糙度参数,铁氧体管的平均粗糙度为 0.06 mm。

蒸汽温度沿流体流动方向单调递增,热流密度 q_w 为:

$$q_w = Ah_w(t_w - t_s)$$
 (5)

式中: A —传热表面积,m²; h_w —管道内表面与蒸汽的传热系数,W/(m²·°C); t_w 和 t_s —管壁平均温度和蒸汽温度,°C。

由于蒸汽流速相对较高,蒸汽与内表面之间的传热一般被视为强制对流传热。因此,对于圆管中完全发展的湍流,管道内表面与蒸汽的传热系数 h_w 的计算公式如下^[25]:

$$h_w = 0.013 \frac{\lambda_s}{d_h} Re_s^{0.867} Pr_s^{1/3}$$
 (6)

雷诺数 Re_s 和普朗特数 Pr_s 的计算公式为:

$$Re_s = \frac{\rho_s w_s d_h}{\mu_s}$$
 (7)

$$Pr_s = \frac{\mu_s C_s}{\lambda_s}$$
 (8)

式中: λ_s —蒸汽导热系数,W/(m·°C); μ_s —蒸汽动力粘度,Pa·s; C_s —蒸汽比热容,J/(kg·°C)。

蒸汽的热物理性质可利用 IAPWS-IF97 公式计算。

蒸汽吸热量 E_{so} 和热流密度 q_w 之间的动态关系可以通过过热器蒸汽蓄热量的变化 ΔU_l 来反映。当吸入的 $q_w > E_{\text{so}}$ 时,蒸汽蓄热量就会增加。能量守恒可表示为:

$$\Delta U_l = U_{l+1} - U_l = q_w - E_{\text{so}}$$
 (9)

式中: U_l 和 U_{l+1} — t 时刻和 $t+1$ 时刻的蒸汽蓄热量,J。

另一方面,过热蒸汽蓄热量的变化 ΔU_l 可用蒸汽出口焓变 di_{out}/dt 与过热器中蒸汽质量 Q_{so} 的乘积来表示。具体如下:

$$\Delta U_l = Q_{so} \cdot \frac{di_{out}}{dt} \tag{10}$$

1.3 SST 系统运行过程中参数之间的单调性

对于喷水减温器,其通过蒸汽和喷淋水混合,使质量和能量交换过程迅速发生。因此,质量和能量守恒可直接表示为:

$$Q_{so} = Q_{sw} + Q_{si} \tag{11}$$

$$Q_{so} h_{so} = Q_{sw} h_{sw} + Q_{si} h_{si} \tag{12}$$

式中: h_{so} —过热器出口蒸汽温度 t_{out} 下的计算焓值; h_{sw} —减温水温度 t_{sw} 下的计算焓值; h_{si} —喷水减温器入口蒸汽温度 t_{si} 下的焓值, J/mol。三者可利用 IAP-WS-IF97 公式计算。

过热蒸汽温度的动态特性随喷水流量的阶跃变化是单调的^[26],因此这一关系可作为输出的约束条件。具体来说,在任意相对平衡的初始状态下,当喷水流量从 Q_{sw}^1 突然变为 Q_{sw}^2 时,蒸汽温度的前后关系为:

$$\begin{aligned} t_{out}[Q_{sw}^1, t] - t_{out}[Q_{sw}^2, t + 1] &\geq 0 \\ \text{s. t. } Q_{sw}^1 &< Q_{sw}^2 \end{aligned} \tag{13}$$

2 注意力时间卷积神经网络

2.1 时间卷积神经网络

时间卷积神经网络(TCN)的架构如图2所示。




图2 TCN 架构
Fig. 2 TCN structure

该架构是一种分层架构,具体包括因果卷积、空洞卷积和残差连接三部分。图中 y 与表1中过热器出口蒸汽温度对应, x 表示由表1中 $x_1 \sim x_{33}$ 以及 y 的历史时序数据组成的输入向量。其中因果卷积是指 t 时刻的输出仅由 t 时刻或更早时刻的输入进行

卷积决定。

空洞卷积可实现更大的感受野,从而捕获长记忆,输入序列元素 x 在输出位置 o 上的空洞卷积操作 F 定义为:

$$F(x)_o = \sum_{k=0}^{K-1} f(k) \cdot x(o - d \cdot k) \tag{14}$$

式中: $f: \{0, \dots, k-1\} \rightarrow R$ —卷积滤波器; x —时序输入,本文中为过热器出口蒸汽温度时间序列和输入变量的融合级联; k —滤波器大小; d —空洞因子; $x(o - d \cdot k)$ —以空洞率 d 为间隔,从输入序列中稀疏采样的位置,即相对于当前位置 o 的特定偏移位置,本质是通过跳跃采样扩大模型对长程依赖的捕捉能力,同时保持计算效率。

空洞卷积操作中,所有层的卷积核均保持不变,但空洞因子随网络深度呈指数级增长: $d_l = 2^l$, 其中 l 是网络层数。由图2可知, d_t 在第1层为1,然后每层都增加,在最后一个隐藏层达到4。这种金字塔结构和聚合机制有效地增加了TCN的感受野,允许覆盖长输入序列。

TCN网络残差连接如图3所示。残差连接有助于克服多层网络中的梯度消失问题。残差连接有两个分支,一个分支是通过一系列堆叠层转换输入,包括两个空洞因果卷积层;另一分支是输入的直接连接。但原始输入和残差块的输出宽度不同,无法进行加法运算,通过在直连分支上使用 1×1 卷积层 Conv 纠正,以确保宽度相同。




图3 TCN 网络的残差连接
Fig. 3 Residual connection of TCN network

2.2 TCAN 模型架构

TCN 使用空洞卷积能够实现更大的感受野,但也需要更多时间卷积层来覆盖长输入序列,这使架构更复杂、训练速度更慢,并可能会导致过度拟合。本文结合注意力机制,对 TCN 进行改进,构建了 TCAN 模型。TCAN 模型可在不增加时间卷积层数量的情况下访问更长的输入时间步长,关注输入序列中对预测很重要的时间步,忽略不相关的时间步,从而提高预测准确性。TCAN 模型架构如图 4 所示。由图 4 可知,TCAN 模型由时间卷积层、注意力层和输出层三部分组成。TCAN 模型采用分层卷积架构对输入序列进行编码,并将时间模式提取为潜变量 h_i 。注意力机制使用潜变量 h_i 来学习最相关的特征(先前的时间步长)并生成最终预测结果。潜变量对来自整个输入窗口的信息进行编码,从而在不增加额外卷积层的情况下扩大感受野。




图4 TCAN 结构

Fig. 4 TCAN structure

3 基于 TCAN 模型的混合建模方法及其在 SST 预测中的应用

3.1 基于物理约束的损失函数

训练传统数据驱动模型的标准方法是最小化预测变量 $\hat{y}$ 和目标变量 y 的损失,具体如下:

$$\min \text{Loss}(\hat{y}, y) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (15)$$

式中: n —样本数。

但传统训练过程受数据质量影响较大,数据的不规则分布导致即使最小化 $\hat{y}$ 和 y ,也难以确保模型能产生符合物理定律的结果。因此,引入图 5 所示的基于物理约束的损失函数,以引导数据驱动模型学习到与物理理论一致的解决方案。




图5 基于物理的约束机制

Fig. 5 Physics-based constraint mechanism

加入基于能量守恒的约束条件后,过热蒸汽温度的预测变化将符合物理规律,可使蒸汽蓄热量的变化 ΔU_t^1 和 ΔU_t^2 一致。因此,损失函数项定义为:

$$\Gamma_{\text{EN}} = \frac{1}{T} \sum_{t \in R^T} \text{ReLU}(|\Delta U_t^1 - \Delta U_t^2| - \Gamma_{\text{EN}}) \quad (16)$$

式中: Γ_{EN} —由未知因素或数据观测误差的影响而产生的阈值; ReLU —修正线性单元是一个激活函数; T —时间窗口长度。

对于混合模型其预测结果可能会在局部相关性方面违反其他类型的物理关系,如参数之间的单调性。模型可通过纳入这些额外的约束条件进行预测指导,使预测结果与实际物理情况保持一致。在过热系统中,以 SST 与喷淋水流量之间的单调性作为不等式约束。在任意一对连续的喷水流量值 Q_{sw}^i 和 Q_{sw}^{i+1} ($Q_{\text{sw}}^i < Q_{\text{sw}}^{i+1}$) 上,模型在时刻 t 上的蒸汽温度估计值的差值 $\Delta \hat{t}_{i,t}$ 计算如下:

$$\Delta \hat{t}_{i,t} = \hat{t}_{\text{out}}[Q_{\text{sw}}^i, t] - \hat{t}_{\text{out}}[Q_{\text{sw}}^{i+1}, t+1] \quad (17)$$

式中: $\hat{t}_{\text{out}}$ —过热蒸汽温度估计值。

若 $\Delta \hat{t}_{i,t}$ 为正值则表示过热蒸汽的预测违反物理规律,可作为 $\text{ReLU}(\Delta \hat{t}_{i,t})$ 的非零状态进行估计。因此,在连续的喷水流量变化速率值 N_w 和时间窗口 T 上,所有违反物理规律的平均值可视为基于物理的损失函数 Γ_{MC} :

$$\Gamma_{\text{MC}} = \frac{1}{T(N_w - 1)} \sum_{i=1}^{N_w-1} \sum_{t=1}^T \text{ReLU}(\Delta \hat{t}_{i,t}) \quad (18)$$

衡量模型预测是否符合这些基于物理的约束条件,可通过基于物理损失函数 Loss_{phy} 的值进行评估:

$$\text{Loss}_{\text{phy}}(\hat{y}, z) = \lambda_{\text{EN}} \Gamma_{\text{EN}} + \lambda_{\text{MC}} \Gamma_{\text{MC}} \quad (19)$$

式中: λ_{EN} 和 λ_{MC} —控制违反能量守恒约束和单调性约束影响的超参数。

结合传统损失函数 $\text{Loss}(\hat{y}, y)$ 和基于物理的损失函数 Loss_{phy} , 混合模型的完整学习目标可表示为:

$$\text{Loss}(\hat{y}, y) + \lambda_{\text{phy}} \cdot \text{Loss}_{\text{phy}}(\hat{y}, z) \quad (20)$$

式中: λ_{phy} —衡量物理不一致性影响的系数。

即使在训练数据不完全具有代表性的情况下,通过确保模型预测输出的物理一致性,仍可显著提升混合模型的泛化性能。

3.2 混合建模与预测实现流程

本文利用 TCAN 模型和基于物理的约束设计了一种动态预测的混合策略,整个框架由数据预处理阶段、混合建模阶段和预测阶段组成。具体算法步骤如下:

步骤 1: 从工况丰富的火电厂历史数据集中选取包含表 1 变量的时间序列数据 X , 并将其归一化到 $[0, 1]$ 之间。

步骤 2: 为实现 TCAN 模型架构, 将归一化数据 X 重塑为三维数组 $[n, m, q]$, 其中 n 为样本数, m 为时间步长, q 为输入或输出的特征。

步骤 3: 将三维格式的数据集 X 划分为训练集和测试集。

步骤 4: 以式 (19) 为损失函数, 利用训练集对提出的基于物理约束的混合模型进行训练, 保存混合模型的训练结构和网络参数;

步骤 5: 在测试集上利用训练好的模型进行测试。本文测试集分为两类, 其一为与训练集相类似的测试集 1, 另一类为训练集中未出现过的一种新工况数据, 用于进一步验证模型鲁棒性的泛化测试集 2。

3.3 性能指标

本文选取均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 R^2 作为预测性能的评价指标, 如下所示:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (21)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (22)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (23)$$

式中: y —过热器出口蒸汽温度测量值; $\hat{y}$ —过热器出口蒸汽温度预测值; $\bar{y}$ —过热器出口蒸汽温度测量数据的平均值。

4 仿真分析

4.1 数据说明和参数设置

为有效地训练所提出的模型, 从火电机组的监控信息系统 (SIS) 运行数据库中收集了间隔为 2 s 的一个月的运行数据。SIS 数据库的历史运行数据反映了机组动态特性, 在火电过程领域具有代表性。本文所选数据集的运行负荷范围为 $[300 \text{ MW}, 660 \text{ MW}]$, 对应机组实际运行的全范围。经过数据预处理后, 选取了共计 40 000 个样本作为 SST 混合预测模型的数据集, 其中训练集 70%, 测试集 30%, 并在训练集中选取 10% 作为验证集, 以评估模型训练的效果。

本文所有模型均在 Windows 11 环境下使用 RTX 3060Ti8GB GPU 和 PyTorch1.11 实现。深度学习模型基于 Adam 优化器的小批量梯度下降法进行优化, 最大迭代次数为 200。本文使用贝叶斯优化进行超参数搜索, 最大迭代次数为 20。

对于 TCAN, 模型学习率 $\lambda = 0.003$, 批量大小 $n_{\text{batch}} = 256$, dropout 的值 δ 从 $\{0, 0.15, 0.3\}$ 中选择; 卷积核大小 d_k 从 $\{3, 4, 5\}$ 中选择; 卷积层大小 d_{hid} 和卷积层数从 $\{32, 20, 16, 8, 6, 4\}$ 和 $\{2, 3\}$ 的排列中选择, 最终确定的模型参数 δ 为 0.15, d_{hid} 为 $[20, 16, 6]$, d_k 为 3, 能量守恒约束的阈值 Γ_{EN} 为 0.01, 能量守恒约束权重 λ_{EN} 为 0.2, 单调性约束权重 λ_{MC} 为 5。

4.2 混合模型的预测效果

测试集预测 SST 混合预测模型的 3 个评价指标分别如图 6 所示。由图 6 可知, 测试集的 RMSE 和 MAE 稳定在较低水平, 且有一定波动, R^2 处于较高水平。这说明混合模型的 SST 预测值准确度较高, 指标的小幅波动说明 SST 预测值具有良好的稳定性。因此, 所提混合模型在处理实际运行数据时具有良好的性能。




图 6 测试集预测 SST 结果的评价指标

Fig. 6 Evaluation indice of SST prediction results in test dataset

为说明数据驱动模型的共同局限性,使用 LSTM、TCN 和 TCAN 时间序列模型进行了预测,对比结果如表 2 所示。由表 2 可知,上述 3 种数据驱动模型在训练集上的表现较好,而在测试集上的预测效果在一定程度上有所下降,特别是在用于验证模型鲁棒性的泛化测试集 2 上,3 种数据驱动模型的预测性能均较差,说明数据质量对数据驱动模型的性能有较大影响。在实际运行中,历史数据库中

存在数据分布不均的情况,会对数据驱动模型的应用产生不利影响。

表 2 不同数据驱动模型的预测性能比较

Tab.2 Comparison of prediction performance of different data-driven models				
指标	数据集	LSTM	TCN	TCAN
RMSE/℃	训练集	1.733	1.385	1.196
	测试集 1	1.748	1.631	1.584
	测试集 2	4.325	3.501	2.792
MAE/℃	训练集	1.464	1.016	0.986
	测试集 1	1.514	1.368	1.202
	测试集 2	3.227	2.532	1.882
R^2	训练集	0.861	0.901	0.948
	测试集 1	0.831	0.879	0.902
	测试集 2	0.635	0.741	0.813

4.3 模型性能比较

针对上述问题,应用基于物理能量守恒约束的混合模型,并与基于物理的模型和数据驱动模型进行比较。在测试集 1 和 2 上不同模型的预测结果如图 7 和图 8 所示,不同模型预测性能比较如表 3 所示。




图 7 测试集 1 上的预测性能曲线

Fig. 7 Prediction performance curve in test dataset 1




图 8 测试集 2 上的预测性能曲线

Fig. 8 Prediction performance curve in test dataset 2

表 3 物理模型、数据驱动模型以及混合模型的预测性能比较

Tab.3 Comparison of prediction performance among physical models, data-driven models and hybrid models				
指标	数据集	物理模型	TCAN 模型	TCAN 混合模型
RMSE/℃	训练集	2.114	1.249	1.258
	测试集 1	1.842	1.593	1.338
	测试集 2	2.376	3.312	1.964
MAE/℃	训练集	1.833	0.997	1.026
	测试集 1	1.572	1.392	1.159
	测试集 2	1.652	2.516	1.272
R^2	训练集	0.862	0.944	0.941
	测试集 1	0.863	0.891	0.935
	测试集 2	0.857	0.742	0.921

由图 7 和图 8 及表 3 可知,在不同测试集下,相比物理和数据驱动模型,混合模型的 RMSE 平均降低 22.4% 和 43.8%、MAE 指标平均降低 24.6% 和 58.9%, R^2 指标平均提升 7.3% 和 12.1%。与数据驱动模型和所提混合模型相比,基于物理的模型对训练集的拟合效果最差,原因可能是物理模型的假设和简化容易忽略对模型输出有影响的因素。相比之下,数据驱动模型试图在训练过程中最小化预测值与测量值之间的总体误差。尽管数据驱动模型在训练数据上表现较好,但在测试数据上的表现却相对较差。但此问题在基于物理约束的模型中不会出现。

混合模型和数据驱动模型的时间成本对比如表 4 所示。图中 T_1 , T_2 和 T_3 分别为训练中单次迭代更新时间,总训练时间和预测时间。从结果对比来看,混合模型只需要较长的训练时间,预测过程的时间成本与数据驱动模型基本相同。这是因为物理约束只被集成到损失函数中。考虑到物理模型和数据驱动模型的优势互补,提出的混合模型通过在数据驱动模型的损失函数中引入物理约束来平衡这些优势。因此,所提出的混合模型在训练集和测试集上都显示出更好的预测性能。尤其是在与训练集存在较大差异的测试集 2 上表现最好。实验结果表明,在物理约束条件下,混合模型在训练后具有更好的泛化能力和优越的性能。

表 4 不同模型在训练和预测中的时间成本比较
Tab.4 Comparison of time costs of different models in the training and prediction

模型	T_1/s	T_2/s	T_3/s
TCAN 模型	3.582	386.943	2.214
TCAN 混合模型	4.379	479.362	2.337

4.4 不同物理约束权重下混合模型的性能

为分析所提混合模型在不同物理约束权重下的性能,从 $[0,100]$ 的范围内选择了 8 个有代表性的权重值。当物理约束权重设置为零时,混合模型的损失函数将忽略物理约束,从而使混合模型成为基于 TCAN 的数据驱动模型。

图 9 分别为测试集测试集 1 和泛化测试集 2 的 SST 预测结果评价指标。




图 9 不同物理约束权重下 SST 预测结果的评价指标
Fig.9 Evaluation indice of SST prediction results under different physical constraint weights

由图 9 可知,权重较小时,物理约束对模型结果的影响较小。当权重系数超过一定值时,物理约束过强,限制了模型的优化空间,导致约束效果明显下降,较优的物理约束权重在 $[0.05,0.5]$ 范围内。此外,物理约束权重的优化选择可在保证模型预测精度的同时提高模型的泛化能力,这一点从泛化测试集测试集 2 的评价指标趋势中可以看出。

4.5 阶跃信号下的动态响应

为进一步验证所提混合模型与物理规律的符合性,进行了喷水流量的阶跃实验。3 个模型的阶跃响应实验在满负荷运行条件下进行,所有模型的输入均选取相对稳定状态下的运行数据。由于各模型的预测精度不同,动态响应由模型输出变化曲线反映。3 种模型对喷水流量阶跃增大和减小的响应曲线如图 10 所示。根据喷水流量对蒸汽入口温度的影响原理,基于物理约束的模型可准确反映 SST 对喷水流量的动态响应特性。




图 10 喷水流量阶跃信号下的动态响应
Fig.10 Dynamic response under step signal of spray water flow

由图 10 可知,当喷水流量骤然增大时,过热器入口处的蒸汽流量会迅速增大,由于混入了更多的喷淋水,蒸汽入口温度会降低。同时,过热器管外烟气的入口参数保持不变,因此过热器出口处的 SST 会单调下降,并保持在一个新的稳定状态。当喷水流量减少时,SST 的动态响应与上述特征相反。相比之下,数据驱动模型(TCAN 模型)无法准确反映喷水流量变化的动态特性,数据驱动模型对喷水流量阶跃变化的输出曲线并不单调,部分响应曲线存在与实际物理意义相反的动态特性,主要由数据驱动模型的目标函数导致。为解决上述问题,通过在损失函数中引入单调性,从而构建一个带有不等式约束的混合模型(TCAN 混合模型),在经过运行数据的训练后发现,TCAN 混合模型能够很好地响应 SST 的正确动态特性。

综上,混合模型的预测性能和阶跃响应动态性能结果表明,物理等式约束和不等式约束的引入提升了模型的预测性能和泛化性能,同时也使模型可以更好地遵守物理规律。

5 结 论

准确预测 SST 对火电机组的安全经济运行具有重要作用。本文旨在研究基于多元时序混合建模方法的 SST 预测,因此构建了基于物理约束的损失函数,以引导基于 TCAN 的数据驱动模型学习到符合物理规律的解。通过对实际运行数据进行训练,比较模型预测结果可知,在不同测试集下,相比物理和数据驱动模型,混合模型的 RMSE 平均降低 22.4% 和 43.8%、MAE 平均降低 24.6% 和 58.9%, R^2 平均提升 7.3% 和 12.1%。基于能量守恒约束,通过平衡预测误差和损失,有效提升了混合模型的泛化能力。在 SST 与喷水流量物理关系的指导下,混合模型在阶跃实验中的响应与实际动态特性具有科学一致性。

参考文献:

[1] ZHAO Y,FAN P,WANG C,et al. Fatigue lifetime assessment on a high-pressure heater in supercritical coal-fired power plants during transient processes of operational flexibility regulation[J]. Applied Thermal Engineering,2019,156:196 – 208.

[2] MISRA S,PRAVIN P S,GUDI R D,et al. Integration of supply and demand sidemanagement using renewable power sources: Application on an air separation plant[J]. Industrial & Engineering Chemistry Research,2021,60(9):3670 – 3686.

[3] 王放放,杨鹏威,赵光金,等. 新型电力系统下火电机组灵活性运行技术发展及挑战[J]. 发电技术,2024,45(2):189 – 198.

WANG Fangfang,YANG Pengwei,ZHAO Guangjin,et al. Development and challenges of flexible operation technology of thermal power units under new power systems[J]. Power Generation Technology,2024,45(2):189 – 198.

[4] FAN H E,SU Z G,WANG P H,et al. A dynamic mathematical model for once-through boiler-turbine units with superheated steam temperature [J]. Applied Thermal Engineering, 2020, 170: 114912.

[5] FAN H,XU W,ZHANG J,et al. Steam temperature regulation characteristics in a flexible ultra-supercritical boiler with a double reheat cycle based on a cell model [J]. Energy, 2021, 229: 120701.

[6] SUN L,HUA Q,SHEN J,et al. Multi-objective optimization for advanced superheater steam temperature control in a 300 MW power plant[J]. Applied Energy,2017,208:592 – 606.

[7] ZHANG S,TAFT C W,BENTSMAN J,et al. Simultaneous gains tuning in boiler/turbine PID-based controller clusters using iterative feedback tuning methodology [J]. ISA Transactions, 2012, 51(5):609 – 621.

[8] WU Z,HE T,LI D,et al. Superheated steam temperature control based on modified active disturbance rejection control[J]. Control Engineering Practice,2019,83:83 – 97.

[9] FAN H E,SU Z G,WANG P H,et al. A dynamic nonlinear model for a wide-load range operation of ultra-supercritical once-through boiler-turbine units[J]. Energy,2021,226:120425.

[10] LAUBSCHER R,ROUSSEAU P. CFD study of pulverized coal-fired boiler evaporator and radiant superheaters at varying loads [J]. Applied Thermal Engineering,2019,160:114057.

[11] ZHU M,WU X,SHEN J,et al. Dynamic modeling, validation and analysis of direct air-cooling condenser with integration to the coal-fired power plant for flexible operation[J]. Energy Conversion & Management,2021,245:114601.

[12] SREEPRADHA C,PANDA R C,BHUVANESWARI N S. Mathematical model for integrated coal fired thermal boiler using physical laws[J]. Energy,2017,118:985 – 998.

[13] NIU Y,DU M,GE W,et al. A dynamic nonlinear model for a once-through boiler-turbine unit in low load[J]. Applied Thermal Engineering,2019,161:113880.

[14] WU X,SHEN J,LI Y,et al. Fuzzy modeling and predictive control of superheater steam temperature for power plant[J]. ISA Trans-

actions,2015,56;241 – 251.

[15] 孙安良,武利斌,湛 戊,等. SCR 脱硝系统 NO_x 浓度预测模型与应用 [J]. 重庆理工大学学报 (自然科学), 2023, 37(10);312 – 318.

SUN Anliang,WU Libin,ZHAN Xu, et al. Prediction model and application of NO_x emission of SCR denitrification system [J]. Journal of Chongqing University of Technology (Natural Science), 2023,37(10);312 – 318.

[16] 金 飞,郝晓光,王 斌,等. 基于 QPSO-LSTM 网络的火电机组一次调频能力建模 [J]. 热能动力工程, 2023, 38 (6); 80 – 87.

JIN Fei,HAO Xiaoguang,WANG Bin, et al. Modeling of primary frequency modulation capability of thermal power plant based on QPSO-LSTM network [J]. Journal of Engineering for Thermal Energy and Power,2023,38(6);80 – 87.

[17] CORRIGAN J,ZHANG J. Integrating dynamic slow feature analysis with neural networks for enhancing soft sensor performance [J]. Computers & Chemical Engineering,2020,139;106842.

[18] KARPATNE A,WATKINS W,READ J, et al. Physics-guided neural networks (PGNN): An application in lake temperature modeling [J]. ArXiv,2017,3(28);1 – 16.

[19] BEKELE Y W. Physics-informed deep learning for one-dimensional consolidation [J]. Journal of Rock Mechanics and Geotechnical Engineering,2021,13(2);420 – 430.

[20] WU H,QIAO R. Physics-constrained deep learning for data assimilation of subsurface transport [J]. Energy and AI, 2021, 3;100044.

[21] WANG N,CHANG H,ZHANG D. Efficient uncertainty quantification for dynamic subsurface flow with surrogate by theory-guided neural network [J]. Computer Methods in Applied Mechanics and Engineering,2021,373;113492.

[22] 王 鹏. 基于深度学习的热工过程建模及诊断方法研究 [D]. 南京:东南大学,2023.

WANG Peng. Research on thermal process modeling and diagnosis methods based on deep learning [D]. Nanjing;Southeast University,2023.

[23] WANG L N,ZHANG Y,ZHU F L, et al. Operation optimization approaches of thermal power units with big data-driven hybrid modeling [J]. Applied Mechanics and Materials, 2014, 3458 (631/632);362 – 366.

[24] QI J,ZHOU K,HUANG J, et al. Numerical simulation of the heat transfer of superheater tubes in power plants considering oxide scale [J]. International Journal of Heat and Mass Transfer,2018, 122;929 – 938.

[25] MEYER J P,EVERTS M,COETZEE N, et al. Heat transfer coefficients of laminar,transitional,quasi-turbulent and turbulent flow in circular tubes [J]. International Communications in Heat and Mass Transfer,2019,105;84 – 106.

[26] ZIMA W. Simulation of steam superheater operation under conditions of pressure decrease [J]. Energy,2019,172;932 – 944.

(刘 颖 编辑)