Vol. 40, No. 4 Apr. ,2025

文章编号:1001-2060(2025)04-0207-08

基于 LSTM-XGBoost 集成模型的重型燃气轮机 负荷预测控制

刘一松,康英伟

(上海电力大学 自动化工程学院,上海 200090)

摘 要:为了克服重型燃气轮机负荷系统强非线性,提高负荷系统的设定值跟踪能力,基于 LSTM-XGBoost 集成模型设计了一种非线性模型预测控制策略。首先,结合 LSTM 和 XGBoost 两种网络构建集成模型,对燃气轮机负荷系统的输出功率及排气温度进行预测;然后,利用该模型设计了基于数据驱动的模型预测控制器;并采用蛇优化(SO)算法与目标函数结合,进行滚动优化。仿真结果表明:LSTM-XGBoost 集成模型可以实现两种输出参数在时间序列上的多步预测,输出功率和排气温度的测试集均方根误差分别为 0.060 3 和 0.064 1,且提高了单一模型的预测精度;与常规预测控制策略相比,引入 SO 算法的 LSTM-XGBoost 控制器在 50 MW 的下降和上升功率指令下的超调量分别缩小至 3.2% 和 0.2%,排气温度控制的超调量为零,实现了重型燃气轮机负荷系统的多输入多输出非线性预测控制,提高了设定值跟踪的准确性及快速性。

关 键 词:重型燃气轮机;非线性预测控制;数据驱动;LSTM-XGBoost 集成模型;蛇优化算法;负荷跟踪

中图分类号:TK221

文献标识码:A

DOI:10.16146/j. cnki. rndlgc. 2025.04.023

[引用本文格式] 刘一松,康英伟. 基于 LSTM-XGBoost 集成模型的重型燃气轮机负荷预测控制[J]. 热能动力工程,2025,40(4): 207-214. LIU Yisong, KANG Yingwei. Predictive control of heavy duty gas turbine load based on LSTM-XGBoost integrated model[J]. Journal of Engineering for Thermal Energy and Power,2025,40(4):207-214.

Predictive Control of Heavy Duty Gas Turbine Load based on LSTM-XGBoost Integrated Model

LIU Yisong, KANG Yingwei

(College of Automation Engineering, Shanghai University of Electric Power, Shanghai, China, Post Code: 200090)

Abstract: In order to overcome the strong nonlinearity of the heavy-duty gas turbine load system and improve the setpoint tracking ability of the load system, a nonlinear model predictive control strategy was designed based on the LSTM-XGBoost integrated model. Firstly, the integrated model was constructed by combining two different networks such as LSTM and XGBoost, to predict the output power and exhaust temperature of the gas turbine load system. Then, a data-driven model-based predictive controller was designed using this model. And the snake optimization (SO) algorithm was combined with the objective function for rolling optimization. The simulation results show that the LSTM-XGBoost integrated model can realize multi-step prediction of the two output parameters in the time serie. The root mean square errors of the output power and exhaust temsperature test sets are 0.060 3 and 0.064 1, respectively. And this model greatly improves the prediction accuracy of a single model. Compared with the conventional predictive control strategy, the overshoots of the LSTM-XGBoost controller with the introduction of the SO

收稿日期:2024-09-25; 修订日期:2024-12-24

基金项目:国家自然科学基金(61573239)

Fund-supported Project: National Natural Science Foundation of China (61573239)

作者简介:刘一松(2000-),男,上海电力大学硕士研究生.

通信作者:康英伟(1980-),男,上海电力大学副教授.

algorithm are reduced to 3.2% and 0.2% under the 50 MW drop and rise power commands, and the overshoot of the exhaust temperature control is zero, which realizes the multi-input and multi-output non-linear predictive control of the load system of the heavy-duty gas turbine, and improves the accuracy and rapidity of the setpoint tracking.

Key words: gas turbine, nonlinear predictive control, data-driven, LSTM-XGBoost integrated model, snake optimization algorithm, load tracking

引言

为了实现"双碳"目标,电力工业需要加强建设以新能源为主体的新型电力系统^[1]。重型燃气轮机作为联合循环机组的重要设备,主要以天然气为燃料,具有启停速度快、调峰性能好等优点^[2],在未来的新型电力系统中将扮演重要角色。

由于燃气轮机负荷系统具有非线性、时变等复 杂特性,因此亟需发展更为先进的控制策略。文献 [3]利用自适应模糊 PID 控制对微型燃气轮机进行 控制,但未脱离 PID 的线性控制局限。模型预测控 制(Model Predictive Control, MPC)是目前应用较为 广泛的先进控制方法[4],适用于燃气轮机负荷系统 多变量、有约束的非线性系统。文献[5]在微型燃 气轮机中应用了动态矩阵预测控制。文献[6]设计 了一种重型燃气轮机模型预测控制,通过与传统控 制器进行比较,证明了所提出方法的有效性。文献 [7]总结了神经网络在燃气轮机建模和控制领域的 成果,为燃气轮机建模提供了全新思路。文献[8] 研究了非线性预测控制在发电过程中的应用,详细 列举了优化算法,证明了基于数据驱动的非线性预 测控制在燃气轮机控制中应用的可行性。文献[9] 建立了带有外部输入的非线性自回归神经网络预测 模型,验证了其具有高精度和高抗扰能力。文献 [10]设计了基于 T-S 模糊模型的燃气轮机负荷系 统多目标预测控制,但对于系统的非线性问题仍需 要进一步研究。文献[11]开发了用于燃气轮机负 荷预测的 XGBoost 预测模型,发现了 XGBoost 在该 领域的潜力。

基于上述研究,本文提出一种基于 LSTM-XG-Boost 集成模型的燃气轮机系统负荷预测控制策略。通过采集燃气轮机的运行数据,建立 LSTM-XGBoost 集成模型,验证其精度后,嵌入模型预测控制 (MPC)中,作为预测模型。之后,选择蛇优化(SO) 算法进行目标函数的滚动优化寻优,以进一步提高

优化速度和设定值跟踪能力。

1 重型燃气轮机负荷控制系统概述

在运行过程中,重型燃气轮机的主要控制参数 是燃料流量和压气机进口导叶(IGV)开度,同时,也 有环境参数,如大气压力、环境温度等。燃气轮机的 负荷控制系统存在复杂的耦合关系以及高度非线 性,燃料流量及 IGV 开度均会对输出功率以及排气 温度产生影响,燃气轮机的输出功率需要稳定快速 地跟踪机组负荷指令。在联合循环机组中,燃气轮 机排气会被送至余热锅炉实现余热利用,排气温度 直接影响余热锅炉的运行状态,因此为保证机组的 整体发电效率,通常要求控制器兼顾燃气轮机排气 温度的控制。而传统的 PI 控制器对于解决此类型 多变量、非线性系统有较大的局限。

燃气轮机负荷预测控制系统结构如图 1 所示,图中, $y_r(k)$ 表示设定值, $y_m(k+j)$ 表示第 j 步预测值,u(k)为输入量,y(k)为输出量,J为目标函数。

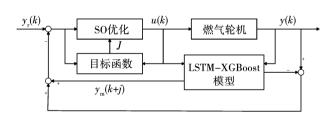


图 1 基于 SO-LSTM-XGBoost 集成模型的 预测控制系统图

Fig. 1 Block diagram of predictive control system based on SO-LSTM-XGBoost integrated model

选用型号为 GE9FA、额定功率为 255 MW 的联合循环机组燃气轮机作为建模对象,采集该机组正常运行条件下现场热启动数据。由于大气压力等环境因素对燃气轮机负荷系统的影响相对较小,为了简化模型,最终选择燃料流量和 IGV 开度为输入变量,输出功率和排气温度为输出变量,利用 LSTM 和XGBoost 两种网络分别建模,再进行模型的集成处理,并参与重型燃气轮机的负荷预测控制。在控制

器中,引入 SO 算法对目标函数进行优化,以此提高控制器的跟踪性能。

2 LSTM-XGBoost 集成模型动态建模

2.1 LSTM 神经网络模型

长短期记忆(Long Short Term Memory,LSTM)是一种用于处理时间序列数据的深度神经网络,通过引入门控机制和记忆单元来控制信息的流通和损失,有效地挖掘燃气轮机排气温度和实发功率等长时间序列数据中的非线性及非周期性特征。LSTM 网络单元结构如图 2 所示。[12]

LSTM 网络单元包含 3 个类型的门结构:遗忘门、输入门和输出门。

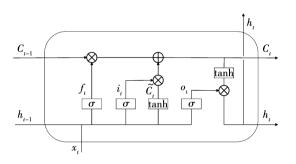


图 2 LSTM 网络结构

Fig. 2 LSTM network structure

其中,遗忘门会读取上一时刻 t-1 的网络隐藏 状态 h_{t-1} 和当前时刻输入 x_t ,通过 sigmoid 函数的非 线性映射,输出一个向量 f_t ,进而决定细胞状态 C_t 中 需要保留或丢弃的信息,表示为:

 $f_{\iota} = \sigma(\mathbf{W}_{fx}x_{\iota} + \mathbf{W}_{fs}h_{\iota-1} + \mathbf{b}_{f})$ (1) 式中: σ —sigmoid 函数; \mathbf{W}_{fx} 、 \mathbf{W}_{fs} —遗忘门的权重矩阵: \mathbf{b}_{ι} —遗忘门的偏置向量。

输入门通过 sigmoid 层和 tanh 层决定从细胞状态 C_{i-1} 中遗忘多少旧信息并控制新信息的写入,完成对细胞状态 C_i 的更新,相关计算式为:

$$i_t = \sigma(\boldsymbol{W}_{ix} \boldsymbol{x}_t + \boldsymbol{W}_{is} \boldsymbol{h}_{t-1} + \boldsymbol{b}_i)$$
 (2)

$$\tilde{C}_t = \tanh(\boldsymbol{W}_{Cx} \boldsymbol{x}_t + \boldsymbol{W}_{Cs} \boldsymbol{h}_{t-1} + \boldsymbol{b}_C)$$
 (3)

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t$$
 (4)
式中: i_t —输入门的激活值, 控制新信息的写入比例; $\mathbf{W}_{ix} \cdot \mathbf{W}_{is} \cdot \mathbf{W}_{Cx} \cdot \mathbf{W}_{Cs}$ —输入门的权重矩阵; $\mathbf{b}_i \cdot \mathbf{b}_c$ —输入门的偏置向量; \tilde{C}_t —侯选记忆, 细胞状态更新的中间变量.表示当前时刻生成的新信息。

输出门首先通过 sigmoid 层来确定细胞状态的

输出部分,之后,细胞状态通过 tanh 层进行处理并与 sigmoid 层输出相乘,最终实现重要信息的输出:

$$o_t = \sigma(\boldsymbol{W}_{ox} \boldsymbol{x}_t + \boldsymbol{W}_{os} \boldsymbol{h}_{t-1} + \boldsymbol{b}_{o}) \tag{5}$$

$$h_{t} = o_{t} \cdot \tanh(C_{t}) \tag{6}$$

式中: o_t —输出门的激活值,控制当前隐藏状态的输出比例; \mathbf{W}_{ox} 、 \mathbf{W}_{os} —输出门的权重矩阵; \mathbf{b}_{o} —输出门的偏置向量。

2.2 XGBoost 集成学习模型

极致梯度提升(eXtreme Gradient Boosting, XGBoost)是基于梯度提升决策树(Gradient Boosting Decision Tree, GBDT)的机器学习算法,旨在优化和加速 GBDT 的训练过程,并提高模型的准确性和泛化能力^[13],也是目前电力负荷预测中应用最为广泛的机器学习算法之一。

XGBoost 算法的训练流程如图 3 所示。其训练流程为:首先初始化构造目标函数,然后对目标函数运用泰勒展开式进行变换,最后将决策树引入目标函数。XGBoost 预测的数学表达式为:

$$\varphi(X) = \frac{1}{n} \sum_{k=1}^{n} f_k \tag{7}$$

$$L(\varphi) = \sum_{i} l(\hat{y}_{i}, y_{i}) + \sum_{k} \Omega(f_{k})$$
 (8)

式中:k—决策树的序数;i—第i 组数据;X—学习特征; $\varphi(X)$ —决策树的预测值; $L(\varphi)$ —目标函数; $l(\hat{y}_i,y_i)$ —损失函数; $\Omega(f_k)$ —模型的正则化项; f_k —模型的学习函数集; y_i —真实值; \hat{y}_i —预测值。

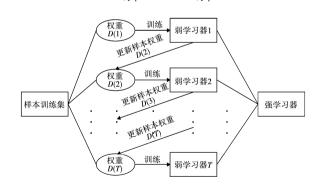


图 3 XGBoost 算法训练流程

Fig. 3 XGBoost algorithm training process

尽管 XGBoost 在各种数据挖掘、预测和分类任 务中有着极高的准确率,但是其超参数选取较为复杂,若不正确调整,模型性能也可能不佳[14]。

2.3 LSTM-XGBoost 集成模型动态建模

采用 LSTM-XGBoost 集成模型进行动态建模, 分别使用 LSTM 和 XGBoost 进行训练。其中,LSTM 擅长捕捉时序数据中的长期依赖关系,而 XGBoost 则擅长处理非线性关系之间的复杂关联。将二者组 合为集成式网络,衡量输出误差,对误差小的模型赋 予较大权值,并将预测结果进行加权组合,可以充分 利用两种模型优势,进一步提高预测模型的精度和 泛化能力。模型实现流程如图 4 所示,其预测的主 要步骤如下:

- (1) 数据预处理,将数据集划分为训练集、验证 集和测试集,并进行归一化处理:
- (2) 使用训练集分别进行两种模型的训练,同 时在验证集上进行测试,找到模型最佳超参数并记 录误差:
- (3) 比较两种模型在验证集上的误差,若误差 相差较大,选择误差小的模型作为最终模型。若两 模型间误差小于所设阈值,则进行权重组合。

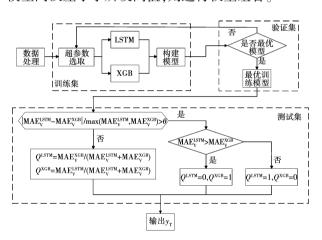


图 4 LSTM-XGBoost 集成模型实现流程

Fig. 4 LSTM-XGBoost integrated model implementation process

设 LSTM 与 XGBoost 训练后的模型分别为 fism 和 f_{xcR} ,验证集特征为 X_{y} ,真实值为 y_{y} ,预测值分别 为 γ_v^{LSTM} 和 γ_v^{XGB} ,可以得到绝对误差分别为 MAE $_v^{LSTM}$ 和 MAE_{v}^{XGB} , 通过验证集的误差来决定权重 Q^{LSTM} 和 Q^{XGB} ·

$$Q^{\text{LSTM}} = \frac{\text{MAE}_{V}^{\text{AGB}}}{\text{MAE}_{V}^{\text{LSTM}} + \text{MAE}_{V}^{\text{XGB}}}$$
(9)

$$Q^{\text{XGB}} = \frac{\text{MAE}_{\text{V}}^{\text{LSTM}}}{\text{MAE}_{\text{V}}^{\text{LSTM}} + \text{MAE}_{\text{V}}^{\text{XGB}}}$$
 (10)

为了进一步优化,定义一个阈值 θ ,若满足式 (11),即两算法相对差值比大于阈值,则不进行 结合。

$$\frac{\mid \text{MAE}_{\text{V}}^{\text{LSTM}} - \text{MAE}_{\text{V}}^{\text{XGB}} \mid}{\text{max}(\text{MAE}_{\text{V}}^{\text{LSTM}}, \text{MAE}_{\text{V}}^{\text{XGB}})} > \theta$$
 (11)

 $\stackrel{\text{def}}{=} MAE_v^{LSTM} > MAE_v^{XGB}, \text{ } Q^{LSTM} = 0, Q^{XGB} = 1;$

 $\stackrel{\text{def}}{=}$ MAE_V < MAE_V , M Q LSTM = 1, Q XGB = 0

得到测试集中的预测值分别为 γ_{T}^{LSTM} 和 γ_{T}^{XGB} , 模 型最终预测结果 γ_{T} 为:

$$y_{\rm T} = Q^{\rm LSTM} y_{\rm T}^{\rm LSTM} + Q^{\rm XGB} y_{\rm T}^{\rm XGB}$$
 (12)

针对机组点火至全速空载的启动过程,采集并 处理热态启动过程 15 000 组运行数据,采样周期为 1 s,训练集、验证集和测试集比例为8:1:1。

将上一时刻的输出参数与当前时刻的输入参数 作为神经网络的特征值,建立2×2的LSTM-XG-Boost 集成网络模型,从而实现对未来时刻输出功率 和排气温度的多步预测。经过训练后,各模型对输 出参数的预测效果如图 5 所示。

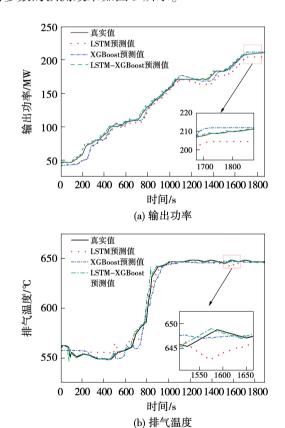


图 5 各模型预测效果对比

Fig. 5 Comparison of predictive effects of various models

由图 5 可知,LSTM-XGBoost 集成神经网络预测 模型具有较高的准确度,拟合程度比单一的 LSTM 和 XGBoost 网络更好。使用均方根误差(Root Mean Square Error, RMSE)作为预测模型的性能评价指 标,计算式如下:

RMSE =
$$\sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2}$$
 (13)

式中:n—样本数量; y_i —第i 个输出的真实值; \hat{y}_i —第i 个输出的预测值。

经计算,预测模型预测值的均方根误差结果如表1所示,RMSE_{train}表示训练集的均方根误差,RM-SE_{test}表示测试集的均方根误差,通过表中数值可以确定,该模型基本满足建模需求,可以应用于燃气轮机多输入多输出非线性预测控制,增强控制效果。

表 1 预测值均方根误差

Tab. 1 Root mean square error of predicted value

输出特征	${\rm RMSE}_{\rm train}$	$RMSE_{test}$
输出功率/MW	0.2767	0.060 3
排气温度/℃	0.203 8	0.064 1

3 基于 LSTM-XGBoost 的燃气轮机负荷预测控制

3.1 SO 算法

本文采用蛇优化(Snake Optimizer, SO)算法作为控制器的滚动优化算法, SO 算法是 F. A. Hashim和 A. G. Hussien提出的模仿蛇特殊交配行为的新型智能优化算法^[15]。SO 算法分为探索和开发阶段,相关变量为温度 T 和食物量 F。

$$T = \exp(-t/t_{\text{max}}) \tag{14}$$

$$F = c_1 \times \exp((t - t_{\text{max}})/t_{\text{max}}) \tag{15}$$

式中:t—当前迭代; t_{max} —最大迭代次数; c_1 —常数参数, $c_1 = 0.5$ 。

SO 算法流程如图 6 所示。

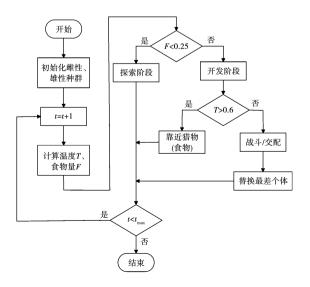


图 6 SO 算法流程图

Fig. 6 Flowchart of SO algorithm

具体计算流程如下:

步骤1:SO 初始化一个随机均匀分布的种群, 初始化公式为:

$$X_i = X_{\min} + r \times (X_{\max} - X_{\min})$$
 (16)
式中: X_i —第 i 个个体的位置; r —0 ~ 1 之间的随机数; X_{\max}, X_{\min} —待解决问题的上、下界。

将种群平均分为两部分,即雄性和雌性,这时的 X_i 可分别表示为 X_i^m 和 X_i^t ,其中 X_i^m 指雄性 SO 位置, X_i^t 为雌性 SO 位置。

步骤 2:判断 F 值, F < 0. 25, 进入探索阶段, 执行步骤 3; F > 0. 25, 进入开发阶段, 执行步骤 4。

步骤 3:对食物进行随机搜索并更新,搜索更新 公式如下:

$$X_i^{\text{m}} = X_{\text{rand}}^{\text{m}}(t) \pm c_2 \times A_{\text{m}} \times ((X_{\text{max}} - X_{\text{min}}) \times \text{rand} + X_{\text{min}})$$
(17)

式中: X_{rand} —随机 SO 位置; c_2 —常数参数; c_2 = 0.05; rand—0~1之间的随机数;A—SO 寻物能力。

雌性 SO 的更新方式与雄性类似:

$$X_i^{\rm f} = X_{\rm rand}^{\rm f}(t) \pm c_2 \times A_{\rm f} \times ((X_{\rm max} - X_{\rm min}) \times$$
rand + $X_{\rm min}$) (18)

步骤 4:判断 T 值, T > 0.6, 切换靠近猎物(食物)模式,执行步骤 5; $T \le 0.6$, 切换战斗/交配模式,执行步骤 6。

步骤5:SO 移动到猎物(食物)上:

$$X_{ij}(t+1) = X_{\text{food}} \pm c_3 \times T \times \text{rand} \times (X_{\text{food}} - X_{i,j}(t))$$
(19)

式中: X_{ij} 一整个 SO 种群位置(包括雄性和雌性); X_{food} 一全局最优位置; c_3 一常数参数, c_3 = 2。

步骤 6:蛇群切换为战斗模式或交配模式。 战斗模式:

$$X_i^{\text{m}}(t+1) = X_i^{\text{m}}(t) \pm c_3 \times FM \times \text{rand} \times (X_{\text{best}}^{\text{f}} - X_i^{\text{m}}(t))$$
(20)

$$X_i^{\mathrm{f}}(t+1) = X_i^{\mathrm{f}}(t) \pm c_3 \times FF \times \mathrm{rand} \times (X_{\mathrm{best}}^{\mathrm{m}} - X_i^{\mathrm{f}}(t))$$
 (21)
式中: FM 、 FF —雄性和雌性战斗值; X_{best} —雌性和雄

式中:FM、FF—雄性和雌性战斗值; X_{best} —雌性和雄性 SO 的最优位置。

交配模式:

 $(F \times X_i^{\mathrm{m}}(t) - X_i^{\mathrm{f}}(t))$

$$X_{i}^{\mathrm{m}}(t+1) = X_{i}^{\mathrm{m}}(t) \pm c_{3} \times M_{\mathrm{m}} \times \mathrm{rand} \times$$

$$(F \times X_{i}^{\mathrm{f}}(t) - X_{i}^{\mathrm{m}}(t))$$

$$X_{i}^{\mathrm{f}}(t+1) = X_{i}^{\mathrm{f}}(t) \pm c_{3} \times M_{\mathrm{f}} \times \mathrm{rand} \times$$

$$(22)$$

(23)

式中: M_m 、 M_f —雄性和雌性蛇群的交配能力。

步骤7:孵化新蛋,替换雄性蛇群中最差个体。

3.2 目标函数

在预测控制进行到第 k 时刻时,令 y_{r1} 表示为输出功率的设定值, y_{m1} 为输出功率预测值,j为时间步长,则输出功率的性能指标为:

$$J_{11} = \sum_{j=1}^{3} [y_{rl}(k+j) - y_{ml}(k+j)]^{2}$$
 (24)

令 y_{r2} 为排气温度的设定值, y_{m2} 为排气温度预测值,则排气温度的性能指标为:

$$J_{12} = \sum_{j=1}^{3} \left[y_{12}(k+j) - y_{m2}(k+j) \right]^{2}$$
 (25)

以第 k 时刻到第 k+2 时刻采样时间内的输入增量的平方和作为控制输入增量性能指标。

$$J_2 = \sum_{j=0}^{2} \{ [u'(k+j) - u'(k+j-1)]^T \times Q_u \times [u'(k+j) - u'(k+j-1)] \}$$
 (26) 式中: u' —优化算法优化所得输入; Q_u —对角阵,决定两种控制参数在目标函数中的权重。

结合以上性能指标后的目标函数 J:

$$J_{1} = \rho_{1}J_{11} + \rho_{2}J_{12}$$

$$J = J_{1} + J_{2} \tag{27}$$

$$J_{1} = J_{1} + J_{2} \tag{27}$$

式中:ho— J_{11} 和 J_{12} 所占权重,需根据目标函数寻优重点进行不断调试。

由于该预测控制算法以调峰为主要目标,因此 输出功率的性能指标项在下降梯度中应该占主导, 兼顾控制排气温度不发生剧烈变化甚至超温,所设 置目标函数参数如表 2 所示。

表 2 目标函数参数

Tab. 2 Objective function parameters

参 数	数值
输出功率指标项权重 ρ_1	20
排气温度指标项权重 $ ho_2$	1
控制参数增量项权重 Q_u	$\begin{bmatrix} 0.08 & 0 \\ 0 & 0.2 \end{bmatrix}$

3.3 仿真实验设计

选用 GE9FA 型机组的仿真模型作为控制器被控对象,已有研究验证了该模型在启动以及并网后加载过程仿真的准确性^[16],将 LSTM-XGBoost 集成模型作为预测模型,SO 算法作为滚动优化算法,实

现机组设定值跟踪控制,设计仿真实验如下:

(1) 控制器参数设定

该仿真实验的输入量为燃料流量和 IGV 开度,输出量为燃气轮机的输出功率和透平的排气温度,通过输入阶跃指令,使得实际被控对象的输出功率可以及时、准确地跟踪设定指令,完成机组调峰;同时,考虑到排气温度的稳定性,还需避免出现剧烈变化以及发生超温。

实验组选择的控制器为基于 LSTM-XGBoost 集成模型的预测控制器(LSTM-XGB-PC),利用 SO 算法优化控制序列;对照组选择的控制器为传统的模型预测控制器(MPC),将机组运行数据辨识为状态空间方程,作为 MPC 预测模型,利用二次规划(QP)优化控制序列。

在控制器的具体参数设置中,设置采样周期为 1 s,预测时域 P 为 10,控制时域 M 为 3,输入输出参数的上、下限数值如表 3 所示。

表 3 控制器输入输出参数上下限

Tab. 3 Upper and lower limits of controller input and output parameters

参 数	上限值	下限值	上下限增量
燃料流量/kg·s ⁻¹	12.48	5.11	±0.000 55
IGV 开度/(°)	83.80	48.90	±0.07
输出功率/MW	213.73	40.50	-
排气温度/℃	648.78	500.60	_

注:-表示无数据。

(2) SO 优化

由 3.2 节所述,基于 SO 算法的控制器优化目标如下:

$$\min J(y_{m}, u') = J(u)$$
s. t.
$$\begin{cases} u_{\min} \leq u' \leq u_{\max} \\ \Delta u_{\min} \leq \Delta u' \leq \Delta u_{\max} \\ y_{m2} \leq y_{2\max} \end{cases}$$
 (28)

式中: u_{max} 、 u_{min} 一输入参数的上、下限;u—最佳输入; $\Delta u'$ 、 Δu_{max} 、 Δu_{min} 一输入参数及输入参数上、下限的增量; $\gamma_{2\text{max}}$ —排气温度的上限。

综合考虑优化效率及效果,将 SO 在每一采样时刻内的种群数量设置为 100,迭代次数为 10,优化获得最佳控制输入,然后进入下一采样时间,循环滚动,最终实现燃气轮机输出功率和排气温度的跟踪控制。

3.4 仿真结果及分析

在系统启动过程中,当输出功率达到 200 MW 的稳态后,首先给定输出功率 50 MW、排气温度 100 ℃ 的下降阶跃指令;在稳定后 150 s 时给定输出功率 50 MW、排气温度 100 ℃的上升阶跃指令,分别判断控制器的设定值跟踪能力。两种控制器对于输出功率及排气温度指令的跟踪效果对比如图 7、图 8 所示,动态控制相关性能指标如表 4、表 5 所示。

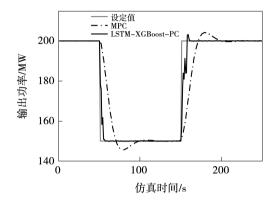


图 7 不同控制器输出功率变化曲线

Fig. 7 Variation curve of output power of

different controllers

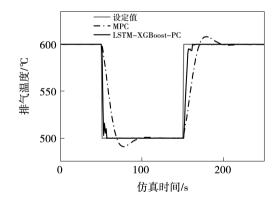


图 8 不同控制器排气温度变化曲线
Fig. 8 Variation curve of exhaust temperatures of
different controllers

表 4 输出功率控制性能 Tab. 4 Output power control performance

阶跃指令/	控制器	超调量 σ /	调节时间	耗时 t/
MW	7年,即9年前	%	$t_{\rm s}/{\rm s}$	min
- 50	MPC	4.3	22	0.52
	LSTM-XGB-PC	0.2	7	3.49
50	MPC	4.1	21	0.51
	LSTM-XGB-PC	3.2	9	3.23

表 5 排气温度控制性能

Tab. 5 Exhaust temperature control performance

阶跃指令/	控制器	超调量 σ/	调节时间	耗时 t/
$_{\mathcal{C}}$		%	$t_{\rm s}/{\rm s}$	min
- 100	MPC	8.9	22	0.52
	LSTM-XGB-PC	0	8	3.49
100	MPC	8.3	23	0.51
	LSTM-XGB-PC	0	9	3.23

由图7、图8可知,基于状态空间模型及QP优化的预测控制器(MPC)尽管可以跟踪设定的输出功率及排气温度,但是跟踪控制能力较弱;而基于LSTM-XGBoost集成模型的预测控制器(LSTM-XGBoost-PC)控制效果则更加显著。引入SO算法的LSTM-XGBoost控制器大幅度提升了负荷跟踪的快速性和准确性,也有效避免了排气温度的振荡和超温现象。

由表 4、表 5 可知,相较于 MPC 动态控制, LSTM-XGBoost 控制器超调量以及调节时间在上升 和下降阶段均有较为明显的提升,有效提高了燃气 轮机负荷控制系统的动态响应能力。而基于数据驱 动的非线性预测控制由于控制算法在每一采样时刻 均需要进行种群的迭代,并得到每一时刻的最佳控 制参数,因此,在克服了系统非线性的同时,其计算 总耗时比之线性控制有所不足。

4 结 论

- (1) 利用燃气轮机机组实际运行数据辨识得到 LSTM-XGBoost 集成网络非线性预测模型,该模型集 成了两种网络的优势,结构稳定、预测精度高。经过 验证,可以快速准确地预测燃气轮机负荷系统的 输出。
- (2) 采用 SO 算法参与预测控制的滚动优化, 仿真结果表明, SO-LSTM-XGBoost 控制器不仅对功 率指令的跟踪更加及时、准确,同时也有效避免了排 气温度的振荡,实现了燃气轮机负荷系统的多输入 多输出控制。
- (3) 基于 LSTM-XGBoost 集成模型以及 SO 算法的预测控制器,在计算时间上仍有较大的优化空间,后续将就进一步提高 SO 算法的优化效率、减少计算时间展开更深度的研究。

参考文献:

- [1] 王哮江,刘 鹏,李荣春,等."双碳"目标下先进发电技术研究 进展及展望[J]. 热力发电,2022,51(1):52-59.
 - WANG Xiaojiang, LIU Peng, LI Rongchun, et al. Research progress and prospects of advanced power generation technology under the goal of carbon emission peak and carbon neutrality $[\ J\]$. Thermal Power Generation, 2022, 51(1):52 –59.
- [2] 姚秀平. 燃气轮机与联合循环[M]. 2版. 北京:中国电力出版 社,2010. YAO Xiuping. Gas turbines and combined cycles[M]. 2th ed. Beijing: China Electric Power Press, 2010.
- [3] 张宏伟,陈 洁,孙 明,等. 微型燃气轮机可变论域自适应模糊 PID 控制[J]. 热能动力工程,2018,33(1):42-47.

 ZHANG Hongwei, CHEN Jie, SUN Ming, et al. Variable discourse domain self-adaptive fuzzy PID control over micro gas turbines[J].

 Journal of Engineering for Thermal Energy and Power, 2018, 33(1):42-47.
- [4] 席裕庚. 预测控制[M]. 2版. 北京:国防工业出版社,2013. XI Yugeng. Predictive control[M]. 2th ed. Beijing: National Defence Industry Press,2013.
- [5] 耿 健,杜 炜,杨冬梅,等. 动态矩阵预测控制在微型燃气轮机中的应用[J]. 电力工程技术,2020,39(1):118-123.

 GENG Jian, DU Wei, YANG Dongmei, et al. Application of dynamic matrix predictive control in micro-turbine [J]. Electric Power Engineering Technology,2020,39(1):118-123.
- [6] ROSINI A, PALMIERI A, LANZAROTTO D, et al. A model predictive control design for power generation heavy-duty gas turbines [J]. Energies, 2019, 12(11);2182.
- [7] ASGARI H, CHEN Xiaoqi. Gas turbines modeling, simulation, and control using artificial neural networks [M]. 鲁峰,李秋红译. 北京:科学出版社,2018.

 ASGARI H, CHEN Xiaoqi. Gas turbines modeling, simulation, and control using artificial neural networks [M]. Translated by LU Feng, LI Qiuhong. Beijing; Science Press, 2018.
- [8] 刘向杰,孔小兵,崔靖涵,等. 发电过程非线性模型预测控制 [M]. 北京:科学出版社,2021.

- LIU Xiangjie, KONG Xiaobing, CUI Jinghan, et al. Nonlinear model predictive control of power generation process[M]. Beijing; Science Press, 2021.
- [9] 张兆宇. 基于神经网络的重型燃气轮机建模与预测控制研究 [D]. 北京:清华大学,2020.
 - ZHANG Zhaoyu. Research on modelling and predictive control of heavy duty gas turbine based on neural network [D]. Beijing; Tsinghua University, 2020.
- [10] 侯国莲,戴晓燕,弓林娟,等. 基于 T-S 模糊模型的燃气轮机系统负荷跟踪多目标预测控制 [J] 中国电力, 2020, 53(11):212-219,226.
 - HOU Guolian, DAI Xiaoyan, GONG Linjuan, et al. Multi-objective predictive control of gas turbine system based on T-S fuzzy model[J]. Electric Power, 2020, 53 (11):212 –219,226.
- [11] SHAIK N B, JONGKITTINARUKORN K, BINGI K. XGBoost based enhanced predictive model for handling missing input parameters: A case study on gas turbine [J]. Case Studies in Chemical and Environmental Engineering, 2024, 10:100775.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8):1735 1780.
- [13] JOHANNA S, DIMITRIOS S, THOMAS P. Learning to tune XG-Boost with XGBoost[J]. Statistics, 2019, 3:15.
- [14] 方继辉,李 阳. 基于 IFA-XGBoost 的燃气轮机故障诊断[J]. 上海电力大学学报,2021,37(4):367-372,384. FANG Jihui, LI Yang. Fault diagnosis method of gas turbine based on IFA-XGBoost[J]. Journal of Shanghai University of Electric Power,2021,37(4):367-372,384.
- [15] HASHIM F A, HUSSIEN A G. Snake Optimizer: A novel metaheuristic optimization algorithm [J]. Knowledge-Based Systems, 2022,242:108320.
- [16] 张文杰. 基于 SIMULINK 单轴重型燃气轮机全工况仿真研究 [D]. 北京:清华大学,2011.
 - ZHANG Wenjie. Research on the full operating range simulation model of single shaft heavy-duty gas turbine [D]. Beijing; Tsinghua University, 2011.

(王治红 编辑)