

基于长短时记忆神经网络的锅炉多参数协同预测模型

金志远¹, 李胜男¹, 谭鹏¹, 严杏初², 刘宇浓², 张成¹, 陈刚¹
(1. 华中科技大学能源与动力工程学院煤燃烧国家重点实验室, 湖北 武汉 430074;
2. 广东省能源集团有限公司沙角C电厂, 广东 东莞 523900)

[摘要] 锅炉协同控制是提高其灵活运行下蒸汽温度平稳的有效手段。以某660 MW燃煤锅炉为研究对象, 利用其历史运行数据, 建立基于长短时记忆(LSTM)神经网络的主蒸汽温度、再热蒸汽温度、炉膛出口NO_x质量浓度、炉膛出口CO质量浓度协同预测模型。模型预测结果表明, 该协同预测模型4个输出的相关系数均大于0.94, 模型综合预测效果良好, 且有较好的泛化能力。该模型为锅炉蒸汽温度、NO_x、炉效协同优化控制提供了依据。

[关键词] 燃煤锅炉; LSTM神经网络; 蒸汽温度; NO_x/CO质量浓度; 多参数协同; 预测模型
[中图分类号] TK39 **[文献标识码]** A **[DOI编号]** 10.19666/j.rlfid.202007234

[引用本文格式] 金志远, 李胜男, 谭鹏, 等. 基于长短时记忆神经网络的锅炉多参数协同预测模型[J]. 热力发电, 2021, 50(5): 120-126. JIN Zhiyuan, LI Shengnan, TAN Peng, et al. Multi-parameter collaborative prediction model of boilers based on long-short-term memory neural network[J]. Thermal Power Generation, 2021, 50(5): 120-126.

Multi-parameter collaborative prediction model of boilers based on long-short-term memory neural network

JIN Zhiyuan¹, LI Shengnan¹, TAN Peng¹, YAN Xingchu², LIU Yunong², ZHANG Cheng¹, CHEN Gang¹
(1. State Key Laboratory of Coal Combustion, Huazhong University of Science and Technology, Wuhan 430074, China;
2. Shajiao C Power Plant of Guangdong Energy Group Co., Ltd., Dongguan 523900, China)

Abstract: Cooperative control of boiler is an effective approach to improve steam temperature stability under flexible operation. Taking a 660 MW coal-fired boiler as the research object, by using the historical operation data, a cooperative prediction model based on the long-short-term memory (LSTM) neural network for main steam temperature, reheated steam temperature, NO_x and CO mass concentration at the furnace outlet was established. The prediction results show that, all the correlation coefficients of the four outputs of the cooperative prediction model are larger than 0.94, indicating the model has good comprehensive prediction effect and generalization ability. The research provides a foundation for collaborative optimization control of boiler steam temperature, pollutants emission reduction and furnace efficiency enhancement.

Key words: coal-fired boiler, LSTM neural network, steam temperature, mass concentration of NO_x/CO, multi-parameter collaboration, prediction model

近年来随着能源结构调整, 可再生能源发电装机容量迅速增加^[1]。大规模可再生能源入网给电网稳定运行带来较大冲击, 导致频繁出现弃光、弃风等问题^[2]。在现阶段储能技术没有重大突破的前提下, 提高可再生能源入网比例必须提高其他发电机

组灵活性。火电机组技术成熟度高, 可调性较大, 成为平衡电网负荷的重要支柱^[3-4]。然而, 大范围变负荷运行给燃煤火电机组带来一系列安全与经济运行难题。

以再热蒸汽温度控制为例, 部分火电机组调节

修回日期: 2020-09-21

基金项目: 中央高校基本科研业务费资助(HUST:2020kfyXJJS030); 中国博士后科学基金(2018M632852)

Supported by: Fundamental Research Funds for the Central Universities (HUST:2020kfyXJJS030); China Post-doctoral Science Foundation (2018M632852)

第一作者简介: 金志远(1996), 男, 硕士研究生, 主要研究方向为烟气脱硝过程建模、控制与优化, kingzy@hust.edu.cn。

通信作者简介: 谭鹏(1989), 男, 博士, 讲师, 主要研究方向为燃煤发电过程建模、控制与优化, tanpeng@hust.edu.cn。

手段匮乏,只有燃烧器摆角和喷水减温2种调节手段。其中燃烧器摆角调节由于机械原因,难以投入自动控制;喷水减温调节简单、有效,但会影响机组发电效率^[5]。常规运行条件下蒸汽温度变化幅度较小,采用手动调整燃烧器摆角与喷水减温调节相结合的方式即可获得满意的控制效果;而灵活运行阶段蒸汽温度变化程度加剧,传统控制方法难以维持其稳定,导致蒸汽温度大幅波动。除燃烧器摆角外,调节氧量、燃尽风也可以改变炉膛火焰中心位置,从而实现主蒸汽温度及再热蒸汽温度控制的效果,但这些调节手段同样对燃烧侧有较大的影响^[6-8]。对锅侧的主蒸汽温度、再热蒸汽温度和炉侧的 NO_x 、CO质量浓度进行协同建模,有助于丰富灵活运行下蒸汽温度调节手段,保证机组的安全、经济、环保运行。

数据建模主要是通过基于燃煤电厂的历史运行数据,利用各种算法,建立能够反映机组主要动态特性和非线性特性的模型,研究燃煤机组的运行规律。随着可再生能源入网,要求煤电机组提高调峰能力,煤电机组产生了大量宽负荷运行数据,这些数据为燃煤机组数据建模提供了基础。随着计算机、大数据技术的快速发展,基于智能算法的燃煤电厂动态建模逐渐增多。Shakil M等^[9]建立了基于动态神经网络的CO、 NO_x 质量浓度预测模型。LYU Y等^[10]使用偏最小二乘支持向量机建立了 NO_x 质量浓度预测模型,并对其进行改进,使模型能够根据机组实时运行数据进行更新。张凤南^[11]和吕正鑫^[12]利用长短时记忆(LSTM)神经网络对主蒸汽温度进行预测,并建立了基于LSTM神经网络预测模型的控制模型,从控制模型的效果对比说明了LSTM神经网络在安全性及鲁棒性上存在的优势。LYU Y等^[13]基于最小二乘支持向量机对循环流化床锅炉的床温建立了动态模型,建模过程中对输入数据进行时滞处理,预测结果发现模型可以很好地跟踪床温的变化。何彪^[14]和Tan P等^[15]利用LSTM神经网络,分析 NO_x 质量浓度影响因素,使用机组历史数据,对核心参数进行寻优,建立了A、B侧 NO_x 质量浓度预测建模,结果表明LSTM神经网络模型效果远远好于支持向量机(SVM)和人工神经网络(ANN)模型效果。

在电网系统提高对锅炉灵活运行能力的要求之前,研究者们主要关注 NO_x 排放问题,所以对 NO_x 进行单一目标的建模工作较多。随着对锅炉灵活运

行能力的要求逐渐提高,频繁的变负荷运行导致蒸汽温度出现大范围波动,单独对某一污染物进行建模研究已经难以满足实际需求,因此需要综合考虑污染物、蒸汽温度等因素,进行多参数协同建模。另一方面,锅炉系统各个运行参数之间并不独立,而是相互制约,具有很强的耦合性。在深度学习发展之前对于复杂问题的多参数建模难度较大,单目标建模往往以损失其他目标性能为代价,使特定的目标性能得到改善,对于锅炉系统整体性能的提升作用不大,甚至还会因其他目标性能的损失而降低整体性能。而锅炉多参数协同建模则是以锅炉系统整体性能优化为目标,针对锅炉系统中对于整体性能影响较大的多个参数进行协同建模,虽然每个目标性能可能没有达到最优,但可以使整体性能得到最大的提升。本文采用在锅炉系统动态建模研究中表现较好的LSTM神经网络对主蒸汽温度、再热蒸汽温度、炉膛出口 NO_x 质量浓度、炉膛出口CO质量浓度进行协同建模,为锅炉蒸汽温度、污染物、炉效协同优化提供依据。

1 长短时记忆(LSTM)神经网络算法

递归神经网络(RNN)属于深度神经网络,通过网络权重,增加同层神经元之间的连接,模型可以共享时间维度上的信息,因此多用于处理时序问题。LSTM神经网络是一种递归神经网络,它通过增加“门”结构,使得信息在每个神经元中流动时,可以选择性地进行保留或遗忘,有效解决递归神经网络无法处理长距离依赖问题^[16],是目前应用效果最好的递归神经网络。

LSTM神经网络相对于递归神经网络,在相应位置增加了输入门、输出门、遗忘门。“门”的作用就是在相应位置对信息进行筛选,解决了信息冗余的问题,并且能够加强主要信息的权重,削弱无关信息的权重,解决“梯度爆炸”和“梯度消失”问题。图1为LSTM神经网络单个包元(cell)的结构^[17]。

各个门结构的具体计算公式为:

遗忘门

$$f_t = \sigma \cdot (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

输入门

$$i_t = \sigma \cdot (W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

状态更新

$$g_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot g_t \quad (4)$$

输出门

$$o_t = \sigma \cdot (W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$




图1 LSTM神经网络单个包元结构示意图
Fig.1 Schematic diagram of a single LSTM cell

针对本文的预测模型，需要在单层 LSTM 神经网络的基础上，增加 1 层全连接层，即神经网络层 (NN 层)，增加 LSTM 神经网络层数只需要在全连接层之前增加 LSTM 神经网络层即可。模型输入为 $[(X+Y)_{t-K}, (X+Y)_{t-(K-1)} \dots (X+Y)_t]$ ，输出为 $[Y_{t+1}]$ 。输入为三维结构，维度为样本数、截止时间步长 K 、输入变量数；输出为二维结构，维度为样本数、输出变量数。图 2 为多参数协同预测单层 LSTM 神经网络模型示意。

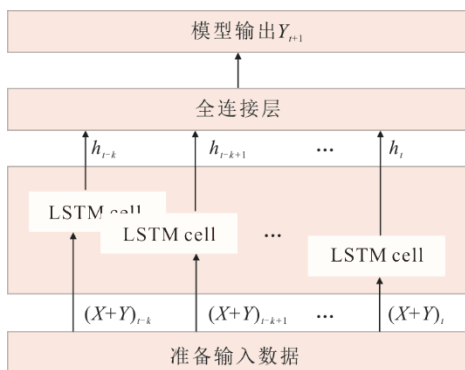


图2 多参数协同预测单层 LSTM 神经网络模型示意
Fig.2 Schematic diagram of a single-layer LSTM model for multi-parameter collaborative prediction

2 建模过程

本文研究对象为某 660 MW 燃煤机组锅炉。该锅炉是美国 ABB-CE 公司设计生产的亚临界参数、单汽包一次中间再热、控制循环锅炉，锅炉最大连续蒸发量为 2 100 t/h，膜式水冷壁，单炉膛 Π 型布置，四角布置双切圆燃烧方式。

锅炉是一个多变量、非线性、多耦合的系统。燃烧过程中，炉膛内的风速、风量、燃烧器倾角、过量空气系数、燃烧火焰中心位置、烟气挡板位置、

进入炉膛煤种及煤量、磨煤机组合运行方式等因素，影响了炉膛出口 NO_x 和 CO 质量浓度。本文研究锅炉主蒸汽温度的额定值为 540 °C，再热蒸汽温度的额定值为 542.7 °C，运行过程中允许偏离额定值的范围为 -10~8 °C。

主蒸汽温度的影响因素主要有蒸汽流量扰动、烟气传热量扰动、减温水扰动。蒸汽流量扰动时，沿过热器长度上各点的温度几乎是同时变化的，延迟时间比较小，约 15 s。从控制角度而言，蒸汽流量扰动是由外界负荷决定，属于外扰，不能作为调节信号。所以电厂主蒸汽温度调节采用以减温水为主、燃烧器倾角为辅的方式。烟气传热量扰动主要包括给煤机给粉不均匀、煤中水分变化、蒸发受热面结渣、过剩空气系数改变、给水温度变化、燃烧火焰中心位置变化等。由于烟气传热量扰动是沿过热器整个长度使烟气传热量同时发生变化，故蒸汽温度变化较快，其滞后时间和时间常数比其他扰动小，延迟时间为 10~20 s。减温水扰动有延迟和惯性，由于现代大型锅炉的过热器管道很长，所以减温水扰动的延迟时间较长，为 30~60 s。

再热蒸汽温度的影响因素与主蒸汽温度类似。由于再热蒸汽压力低，在相同的烟气传热量扰动下，再热蒸汽温度的变化会比主蒸汽温度大。汽轮机高压缸的排汽参数会由于负荷变化及汽轮机运行方式而改变，致使再热器入口蒸汽温度有较大变化。为了保证再热蒸汽温度不变，需要增大调节幅度。再热减温水会使整个机组经济性下降，一般每喷入 1% MCR 再热减温水，机组循环热效率下降 0.1%~0.2%。总的来说，再热蒸汽温度的变化比主蒸汽温度大，且调节不宜用减温水方式。所以电厂再热蒸汽温度调节一般采用燃烧器倾角为主、减温水为辅的调节方式。

负荷是一个非常重要的变量，但对燃煤机组而言，负荷是给定的，不能调节，且通过回归建模也可以由其他输入变量得到负荷，所以本文模型负荷不作为输入变量。综上，多参数协同预测模型输入为：1) 总燃煤量、2) 炉膛倾角位置、3) 炉膛压差、4) 过量空气系数、5) SOFA 风挡板开度、6) 二次风挡板开度、7) 给水流量、8) 给水温度、9) 过热减温水开度、10) 再热减温水开度、11) 1 号磨煤机给煤量、12) 2 号磨煤机给煤量、13) 3 号磨煤机给煤量、14) 4 号磨煤机给煤量、15) 5 号磨煤机给煤量、16) 6 号磨煤机给煤量 (采样时间内 6 号磨煤机未运行)。模型输出为：1) 主蒸汽温度、2) 再热

蒸汽温度、3) 炉膛出口 NO_x 质量浓度、4) 炉膛出口 CO 质量浓度。其中炉膛压差表征炉膛风速，二次风挡板开度表征炉膛风量，过量空气系数由氧量计算得到。各输入输出参数以及负荷变化范围见表 1，其中总燃煤量以额定负荷燃用设计煤种时所需煤量（262 t/h）为 100%进行换算。

表 1 各输入输出参数及负荷变化范围
Tab.1 The variation range of each input and output parameter and the unit load

参数	数值范围
负荷/MW	288~660
总燃煤量/%	46~115
炉膛倾角位置	-15.6~14.3
炉膛压差/kPa	0.37~1.86
过量空气系数	1.1~1.4
SOFA 风挡板开度/%	24.8~42.3
二次风挡板开度/%	17.7~66.6
给水流量/(kg s ⁻¹)	225~587
给水温度/°C	224~268
过热减温水开度/%	0~65.9
再热减温水开度/%	0~28.3
1 号磨煤机给煤量/(t.h ⁻¹)	27.2~56.5
2 号磨煤机给煤量/(t.h ⁻¹)	27.3~57.0
3 号磨煤机给煤量/(t.h ⁻¹)	26.1~56.2
4 号磨煤机给煤量/(t.h ⁻¹)	26.6~56.0
5 号磨煤机给煤量/(t.h ⁻¹)	0~51.4
6 号磨煤机给煤量/(t.h ⁻¹)	
主蒸汽温度/°C	510~555
再热蒸汽温度/°C	506~552
炉膛出口 NO _x 质量浓度/(mg.m ⁻³)	209~493
炉膛出口 CO 质量浓度/(mg.m ⁻³)	0~1 914

建模所用数据从该电厂的实时监控系 统（SIS）中采集，采样频率为 1 Hz，共 360 000 组数据。为了保证训练集和测试集的数据具有不同分布，采集了 2 个不同运行时间段数据，分别得到 252 000 组和 108 000 组数据。前者作为训练集，用于训练模型；后者作为测试集，用于验证模型，不参与建模训练。

在建模前对数据进行预处理。首先，排查数据中的奇异值和非正常运行数据，对明显不正常（如零值、极大值、坏值等）的数据进行剔除或修正。

其次，由于电厂的实际运行环境比较恶劣，一般存在电磁干扰、噪声干扰等，故原始数据通常有噪声，或者突刺，会影响建模效果。所以须对数据进行滤波处理，一定程度上去除数据噪声。锅炉历

史数据是确定性信号，因此采用有限脉冲响应(FIR)数字滤波器对数据进行滤波。其中，窗函数选择汉宁窗，低通滤波截止频率选择 0.02~0.03 Hz，滤波器阶数选择 50，单次滤波数据段长度选择 4 000。

原始数据的采样间隔为 1 s，为了减小数据量同时保留数据的动态特征，在滤波处理之后，对数据进行了重采样分析。选取一部分原始数据，分别进行间隔为 10、30、60 s 的平均重采样处理，图 3 为炉膛出口 NO_x 质量浓度的重采样分析结果。由图 3 可以看出，间隔为 10 s 的重采样数据与原始数据基本一致，包含了一部分的微小波动，冗余信息较多。间隔为 30 s 的数据在保留原始数据动态特征的同时滤除了可能是噪声的微小波动。而间隔为 60 s 的重采样数据虽然能够滤除小波动，但是已经偏离了原始数据，信息损失较大。另一方面，考虑到 LSTM 神经网络的结构和锅炉自身的延迟时间，数据重采样间隔选择为 30 s 较为合适。




图 3 数据重采样结果
Fig.3 The data resampling results

模型中使用 EarlyStopping^[18]和 Dropout^[19]方法来防止过拟合，当增加 LSTM 神经网络层数时，每层均使用 Dropout。EarlyStopping 用来监视模型的训练过程，当训练集的损失(loss)变化幅度小于一定值，就停止训练，这就可以有效减少模型训练时间，防止模型继续训练从而过拟合。Dropout 的作用是模型训练更新时，将单元的一部分随机设置为 0，以防止模型依赖于个别单元，从而防止过拟合。模型使用 Adam 训练方法，学习率取 0.001，使用均方差（ δ_{MSE} ）作为学习目标。

模型使用均方根误差（ δ_{RMSE} ）、平均相对误差（ δ_{MRE} ）、相关系数（ δ_R ）3 个评价标准，其计算公式为：

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (7)$$

$$\delta_{MRE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (8)$$

$$\delta_R = \frac{\text{Cov}(\hat{Y}, Y)}{\sqrt{\text{Var}[\hat{Y}]\text{Var}[Y]}} \quad (9)$$


式中, \hat{y}_i 、 \hat{Y} 表示预测值, y_i 、 Y 表示实际值。

为了降低参数量级对模型性能的影响, 需要对模型参数进行调参寻优。使用 4 个输出参数的 δ_R 平均值作为调参标准。调参计算时, Dropout 参数选择 0.3, 数据集长度为 6 000, 其中前 70% 作为训练集, 剩下 30% 作为测试集。经过对模型参数及结构的调整, 选定截止时间步长为 7, LSTM 神经网络层数为 1 层, 隐层节点数为 256。


3 结果及讨论

多参数协同预测模型训练及测试数据长度为 12 000, 采样间隔为 30 s; 训练集和测试集的数据量之比为 7:3, 其余参数使用调参时设置的参数。


图 4 为模型输出主蒸汽温度、再热蒸汽温度、炉膛出口 NO_x 质量浓度、炉膛出口 CO 质量浓度的预测值与实际值的拟合曲线以及预测误差变化。




a) 主蒸汽温度



b) 再热蒸汽温度



c) 炉膛出口 NO_x 质量浓度预测结果



d) 炉膛出口 CO 质量浓度

图 4 模型 4 种输出参数的预测结果
Fig.4 The prediction results of four output parameters

从图 4 可以看出: 训练集中输出参数的预测值能够很好地跟随实际值变化, 模型对于 4 个输出均有较好的预测能力; 测试集中参数预测值与实际值的拟合程度也较好, 误差相对于训练集变化不大, 所以模型具有很好的扩展能力。对于炉膛出口 CO 质量浓度, 当变化梯度较大时, 不管是训练集还是测试集都难以很好地预测到尖刺变化的位置, 其误差较大点也都是 CO 质量浓度变化剧烈的时刻, 但模型能够很好地预测到变化趋势。

图 5 为模型输出主蒸汽温度、再热蒸汽温度、炉膛出口 NO_x 质量浓度、炉膛出口 CO 质量浓度训练集及测试集的误差分布。从图 5 可以看出, 4 个输出参数的误差基本为期望 0 的正态分布, 其测试集误差的标准差较训练集大, 训练集误差更集中。

对于主蒸汽温度, 72% 训练集及 42% 测试集样本的误差绝对值均小于 0.4 °C, 仅有 3% 训练集和 6% 测试集样本误差绝对值大于 1 °C。对于再热蒸汽温度, 51% 训练集及 49% 测试集样本的误差绝对值均小于 0.2 °C, 仅有 0.5% 训练集及 0.5% 样本误差绝对值大于 1 °C。对于炉膛出口 NO_x 质量浓度, 85% 训

训练集及 68%测试集样本误差绝对值小于 4 mg/m^3 ，仅有 0.6%训练集和 1.6%测试集的样本误差绝对值大于 10 mg/m^3 。对于炉膛出口 CO 质量浓度，由于其尖刺值预测不准，所以少量误差值较大；69%训练集及 67%测试集样本误差绝对值小于 40 mg/m^3 ，仅有 5%训练集样本误差绝对值大于 160 mg/m^3 ，5%测试集样本误差绝对值大于 200 mg/m^3 。

表 2 为多参数预测模型训练及测试结果。由于炉膛出口 CO 质量浓度有 0 的情况，所以其 δ_{MRE} 值无意义。从表 2 可知，主蒸汽温度及再热蒸汽温度

预测效果较好，训练集的 δ_{MRE} 均小于 0.06%，测试集的 δ_{MRE} 均小于 0.089%，相关系数 δ_{R} 均大于 0.98，其训练集的 δ_{RMSE} 均小于 $0.45 \text{ }^\circ\text{C}$ ，测试集的 δ_{RMSE} 均小于 $0.60 \text{ }^\circ\text{C}$ 。炉膛出口 NO_x 质量浓度训练集 δ_{RMSE} 小于 3.1 mg/m^3 ， δ_{MRE} 仅为 0.683%，而测试集的表现稍差， δ_{RMSE} 为 4.061 mg/m^3 ， δ_{MRE} 为 0.934%。炉膛出口 CO 质量浓度的预测效果欠佳，训练集的 δ_{RMSE} 为 68.8 mg/m^3 ， δ_{R} 值为 0.983，测试集的 δ_{RMSE} 为 89.7 mg/m^3 ， δ_{R} 值为 0.948。总得来说，4 个输出的 δ_{R} 值均大于 0.94，多参数输出模型综合预测效果较好。

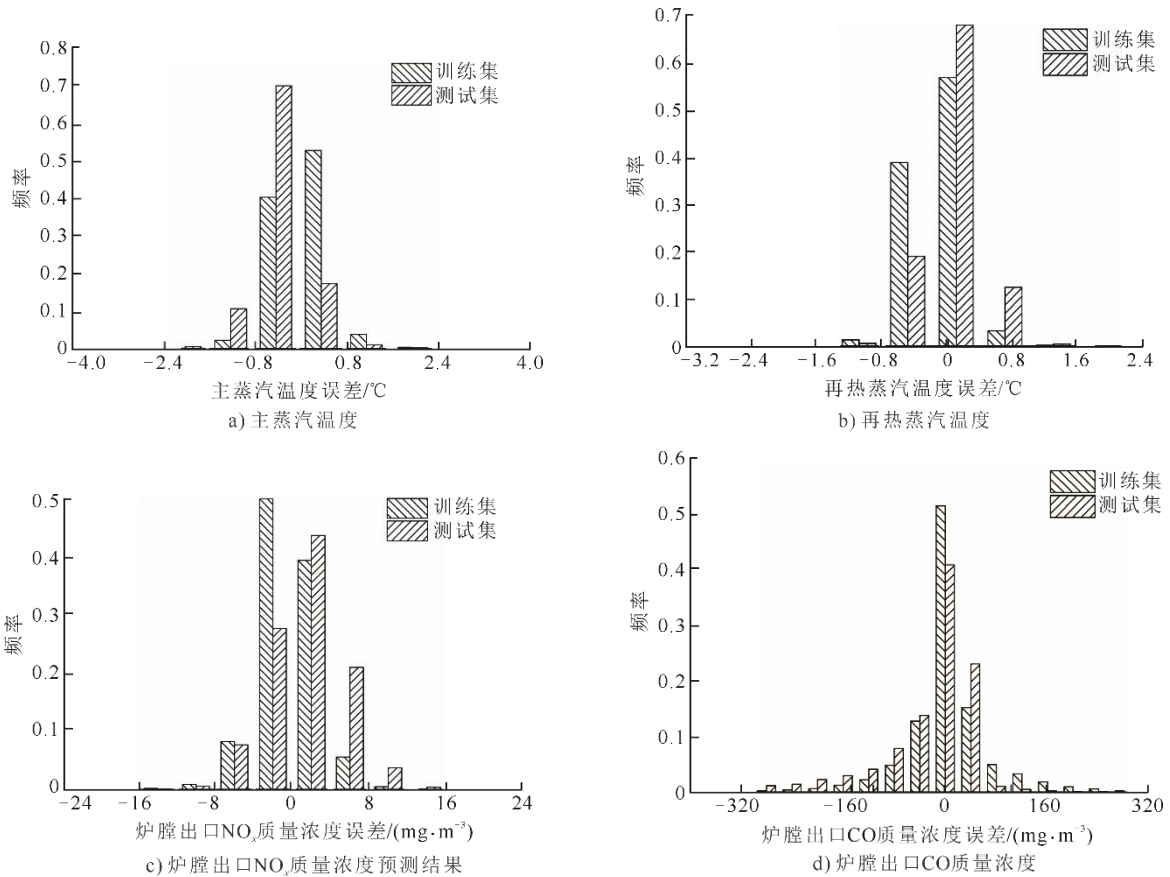


图 5 模型 4 种输出参数的误差分布
Fig.5 The error distribution of four output parameters

表 2 多参数预测模型训练及测试结果
Tab.2 The training and test results of the multi-parameter model

输出变量	δ_{RMSE}		$\delta_{\text{MRE}}/\%$		δ_{R}	
	训练集	测试集	训练集	测试集	训练集	测试集
主蒸汽温度/ $^\circ\text{C}$	0.424	0.579	0.059	0.089	0.994	0.982
再热蒸汽温度/ $^\circ\text{C}$	0.308	0.330	0.044	0.048	0.999	0.998
炉膛出口 NO_x 质量浓度/ $(\text{mg}\cdot\text{m}^{-3})$	3.073	4.061	0.683	0.934	0.998	0.997
炉膛出口 CO 质量浓度/ $(\text{mg}\cdot\text{m}^{-3})$	68.774	89.652	—	—	0.983	0.948

4 结 论

本文以某 660 MW 燃煤锅炉为研究对象，建立

了基于 LSTM 神经网络的主蒸汽温度、再热蒸汽温度、炉膛出口 NO_x 质量浓度、炉膛出口 CO 质量浓度协同预测模型。结果表明，该模型 4 个输出的相

关系数 δ_R 均大于 0.94, 主蒸汽温度及再热蒸汽温度测试集的 δ_{MRE} 均小于 0.089%, 炉膛出口 NO_x 质量浓度测试集的 δ_{RMSE} 小于 4.1 mg/m^3 , 炉膛出口 CO 质量浓度测试集的 δ_{RMSE} 为 89.7 mg/m^3 。总的来说, 基于 LSTM 神经网络的多参数协同预测模型对 4 个参数的综合预测效果较好, 且有很好的泛化能力, 相较于单参数模型, 该模型能够有效提升系统整体性能, 对实际运行更具指导意义。

【参考文献】

- [1] 中华人民共和国国家统计局. 中国统计年鉴 2019[R/OL]. (2019-09-01)[2020-06-01]. <http://www.stats.gov.cn/tjsj/dsj/2019/indexch.htm>.
Nation bureau of statistics of China. China statistical yearbook of 2019[R/OL]. (2019-09-01)[2020-06-01]. <http://www.stats.gov.cn/tjsj/ndsj/2019/indexch.htm>.
- [2] 吴迪, 王佳明, 李晖, 等. 以促进可再生能源消纳为目标的我国西北-西南联网容量与送电时序研究[J]. 电网技术, 2018, 42(7): 2103-2110.
WU Di, WANG Jiaming, LI Hui, et al. Research on capacity and delivery sequence of interconnected northwestern-southwestern power grid towards renewable energy accommodation[J]. Power System Technology, 2018, 42(7): 2103-2110.
- [3] 谢国辉, 栾凤奎, 李娜娜, 等. 新能源消纳影响因素的贡献度评估模型[J]. 中国电力, 2018, 51(11): 125-131.
XIE Guohui, LUAN Fengkui, LI Nana, et al. Contribution evaluating model for the new energy accommodation influencing factors[J]. Electric Power, 2018, 51(11): 125-131.
- [4] 刘吉臻, 曾德良, 田亮, 等. 新能源电力消纳与燃煤电厂弹性运行控制策略[J]. 中国电机工程学报, 2015, 35(21): 5385-5394.
LIU Jizhen, ZENG Deliang, TIAN Liang, et al. Control strategy for operating flexibility of coal-fired power plants in alternate electrical power systems[J]. Proceedings of the CSEE, 2015, 35(21): 5385-5394.
- [5] 肖平, 刘统华. 300 MW 机组摆动燃烧器调节再热汽温的改进建议[J]. 热力发电, 2006, 35(9): 44-46.
XIAO Ping, LIU Tonghua. Analysis of temperature regulating method using oscillatory burners for reheated steam of 300 MW unit and improvement recommendations thereof[J]. Thermal Power Generation, 2006, 35(9): 44-46.
- [6] 中华人民共和国国家发展和改革委员会, 中华人民共和国环境保护部, 中华人民共和国国家能源局. 煤电节能减排升级与改造行动计划(2014—2020 年)[EB/OL]. (2014-09-24)[2020-06-05]. http://www.mee.gov.cn/gkml/hbb/gwy/201409/t20140925_289556.htm.
National Development and Reform Commission of the People's Republic of China, Ministry of Environmental Protection of the People's Republic of China, National Energy Administration of the People's Republic of China. Action plan for upgrading and reforming energy saving and emission reduction of coal-fired power (2014—2020)[EB/OL]. (2014-09-24)[2020-06-05]. http://www.mee.gov.cn/gkml/hbb/gwy/201409/t20140925_289556.htm.
- [7] 崔修强. 低氮燃烧器改造对锅炉运行影响探析[J]. 华电技术, 2018, 40(11): 59-61.
CUI Xiuqiang. Safety analysis of boilers taken low-nitrogen burner reformation[J]. Huadian Technology, 2018, 40(11): 59-61.
- [8] 朱明磊. 浅析低氮燃烧器改造对锅炉运行影响[J]. 中国设备工程, 2020(2): 206-207.
ZHU Minglei. Analysis of boilers taken low-nitrogen burner reformation[J]. China Plant Engineering, 2020(2): 206-207.
- [9] SHAKIL M, ELSHAFEI M, HABIB M A, et al. Soft sensor for NO_x and O_2 using dynamic neural networks[J]. Computers & Electrical Engineering, 2009, 35(4): 578-586.
- [10] LYU Y, YANG T, LIU J. An adaptive least squares support vector machine model with a novel update for NO_x emission prediction[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 145: 103-113.
- [11] 张凤南. 基于历史数据的主汽温控制系统建模研究[D]. 北京: 华北电力大学, 2019: 12-20.
ZHANG Fengnan. Research on modeling of main steam temperature control system based on historical data[D]. Beijing: North China Electric Power University, 2019: 12-20.
- [12] 吕正鑫. 模糊控制算法研究及在火电厂主汽温控制的应用[D]. 北京: 华北电力大学, 2019: 13-18.
LYU Zhengxin. Research on fuzzy control algorithm and its application in main steam temperature control of thermal power plants[D]. Beijing: North China Electric Power University, 2019: 13-18.
- [13] LYU Y, HONG F, YANG T, et al. A dynamic model for the bed temperature prediction of circulating fluidized bed boilers based on least squares support vector machine with real operational data[J]. Energy, 2017, 124: 284-294.
- [14] 何彪. 基于历史数据的电站锅炉故障检测及动态建模[D]. 武汉: 华中科技大学, 2018: 30-35.
HE Biao. Fault detection and dynamic modeling of utility boilers based on historical data[D]. Wuhan: Huazhong University of Science and Technology, 2018: 30-35.
- [15] TAN P, HE B, ZHANG C, et al. Dynamic modeling of NO_x emission in a 660 MW coal-fired boiler with long short-term memory[J]. Energy, 2019, 176: 429-436.
- [16] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-166.
- [17] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [18] SHUGAO M, LEONID S, STAN S. Learning activity progression in LSTMs for activity detection and early detection[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Seattle, WA. IEEE, 2016.
- [19] HE Z. Improving LSTM based acoustic model with dropout method[C]. International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM). Dublin, Ireland. IEEE, 2019.

(责任编辑 杜亚勤)