

基于 CNN-LSTM 的燃气轮机 NO_x 排放预测研究

董渊博,茅大钧,章明

(上海电力大学 自动化工程学院,上海 200090)

摘要:针对燃气轮机电站存在 NO_x 超标排放的问题,建立精准的 NO_x 预测模型是降低其排放的基础。提出一种基于卷积神经网络(Convolutional Neural Network,CNN)和长短期记忆神经网络(Long Short-term Memory,LSTM)组合模型的 NO_x 排放预测方法。将 NO_x 排放历史数据和燃气轮机燃烧的状态参数通过滑动窗口法构建成特征图格式输入到 CNN 中,利用其卷积层和池化层提取表征 NO_x 动态变化的特征向量,并转化为时间序列格式输入到 LSTM 中进一步挖掘内部规律,从而实现 NO_x 的排放预测。最终以某三菱燃气轮机的历史运行数据进行试验,结果表明:CNN - LSTM 的相对均方误差 e_{RMSE} 为 1.811 mg/m^3 ,并通过与 PCA - BP、PCA - RNN 和 PCA - LSTM 模型进行比较验证本方法的可行性。

关键词:燃气轮机; NO_x 预测; 卷积神经网络; 长短期记忆神经网络

中图分类号:TK477 文献标识码:A DOI:10.16146/j.cnki.rndlge.2021.09.017

[引用本文格式]董渊博,茅大钧,章明. 基于 CNN-LSTM 的燃气轮机 NO_x 排放预测研究[J]. 热能动力工程,2021,36(9):132-138. DONG Yuan-bo, MAO Da-jun, ZHANG Ming-ming. Research on NO_x emission prediction of gas turbine based on CNN-LSTM [J]. Journal of Engineering for Thermal Energy and Power, 2021, 36(9): 132-138.

Research on NO_x Emission Prediction of Gas Turbine based on CNN-LSTM

DONG Yuan-bo, MAO Da-jun, ZHANG Ming-ming

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

Abstract: In view of the current problem of excessive NO_x emissions in gas turbine power plants, the accurate prediction model of NO_x emission is the basis of reducing NO_x emission. Therefore, a new NO_x emission prediction method based on the combined model of CNN and LSTM is proposed. The historical NO_x emission data and the state parameters of gas turbine combustion are constructed into a feature map format by sliding window algorithm, which are input into CNN, its convolutional layer and pooling layer are used to extract feature vectors that characterize the dynamic changes of NO_x , which are transformed into a time series format and then input into LSTM to further explore the internal rules, and realize the NO_x emission prediction. In the end, the historical operation data of a Mitsubishi gas turbine are used for the test. The result shows that the relative mean square error e_{RMSE} of CNN-LSTM is 1.811 mg/m^3 , and the feasibility of this method is verified by comparing with PCA-BP, PCA-RNN and PCA-LSTM models.

Key words: gas turbine, NO_x prediction, CNN, LSTM

收稿日期:2021-04-16; 修订日期:2021-05-29

基金项目:上海市“科技创新行动计划”地方院校能力建设专项项目(19020500700);中国华电集团有限公司2020年度科技项目(CHDKJ20-02-149)

Fund-supported Project: Shanghai Science and Technology Innovation Action Plan Local University Capacity Building Project (19020500700); China Huaneng Group Limited 2020 Annual Science and Technology Project (CHDKJ20-02-149)

作者简介:董渊博(1997-),男,山东泰安人,上海电力大学硕士研究生。

通讯作者:茅大钧(1966-),男,上海人,上海电力大学教授。

引言

随着国家对大气污染的高度关注,燃气—蒸汽联合循环发电机组凭借其绿色、清洁的优点在我国发电结构中所占的比重不断攀升。国家的相关要求^[1]也对燃气电厂的 NO_x 排放浓度进行了一定的限制。目前主要有两种降低 NO_x 排放的举措,一种是燃烧调整,通过挖掘燃气轮机运行参数,分别找到燃气轮机的燃烧脉动和 NO_x 排放与各运行参数之间的关系^[2],建立机组安全燃烧的稳定边界,将燃烧设定到安全燃烧稳定边界的中心区域。因此,建立精确的 NO_x 排放模型是燃烧调整的基础^[3]。另一种是通过在燃烧器的尾部加装选择性催化还原(Selective Catalytic Reduction, SCR)脱硝系统,由于 NO_x 排放对燃烧具有滞后性且脱硝系统具有大惯性、非线性的特性,因此建立精确的 NO_x 排放模型也可以实现喷氨量的超前调节,从而达到准确控制燃气电厂 NO_x 排放且进行针对性处理的目的^[4-6]。

考虑到 NO_x 生成机理十分复杂,难以建立精确的 NO_x 物理预测模型。因此,学者们通过挖掘燃气轮机的历史运行数据,找到燃气轮机实时运行数据和 NO_x 排放之间的关系。传统的机器学习方法如神经网络能充分解决大规模数据中存在的非线性问题,广泛应用在各种预测环节^[7]。文献[8]利用互信息对众多运行参数进行筛选,在降低模型复杂度的同时使模型的泛化能力得到增强。但是 NO_x 排放量是动态变化的,即模型的输出不仅与当前输入有关,也与过去的输出有关,虽然上述方法也取得了一定成果,但是缺少对时序数据的相关性考虑,最终导致预测的准确度不高^[9]。

作为机器学习的一个组成部分,深度学习比传统方法效果更好,已经成为预测领域的热点^[10-12]。文献[13]通过变分模态将风速序列分解为模态函数,从中提取原始数据特征,然后建立基于 LSTM 的短期风速预测模型;文献[14]将 t-SNE 方法应用到机械振动信号的特征提取中,然后利用 LSTM 进行剩余使用寿命预测,结果表明 LSTM 优于 SVM 和 BP 神经网络。LSTM 凭借对时间序列学习的特点从而保持良好的预测精度,但是其对寻找非连续数据之间关系的能力较差^[15]。

为了提高 NO_x 排放的预测精度,本文提出了一种基于 CNN-LSTM 模型的 NO_x 排放预测方法,将某三菱燃气轮机 NO_x 排放历史数据以及反映 NO_x 排放的燃烧状态参数按滑动窗口构造连续的特征图作为输入,通过 CNN 挖掘特征图中的潜在关系,然后作为 LSTM 的输入特征,最终实现 NO_x 的排放预测。

1 NO_x 预测模型原理

1.1 CNN 模型

卷积神经网络主要由 5 部分构成:输入层、卷积层、池化层、全连接层和输出层。

以 $X = [x_1, x_2, \dots, x_n]^T \in R^{n \times m}$ 表示输入的数据矩阵,其中 n 表示时间序列长度, m 为数据的特征个数。时间序列数据经过卷积运算得到:

$$\mathbf{o}_c = f_c(X \otimes \mathbf{W}_c + b_c) \quad (1)$$

其中, \otimes 为卷积运算, 卷积核 $\mathbf{W}_c \in R^{j \times m}$ 是权值向量, j 为卷积核尺寸, 即提取时间序列特征的时间窗宽度, b_c 为该层的偏置, $f_c(\cdot)$ 表示卷积层激活函数, 其中激活 ReLU 函数能够加速模型收敛, 因此选用其作为激活函数, \mathbf{o}_c 为卷积核的特征映射结果。

池化运算用于选择卷积层序列最重要的特征,形成池化层。池化运算有最大池化和平均池化两种,通常用的池化方法为最大池化,最后一次池化运算时采用全局最大池化,表达式为:

$$\mathbf{o}_p(k) = \max(\mathbf{o}_c(2k-1), \mathbf{o}_c(2k)) \quad (2)$$

$$\mathbf{o}_p = \max(\mathbf{o}_c) \quad (3)$$

式中: $\mathbf{o}_p(k)$ — 第 k 次池化的输出结果; \mathbf{o}_p — 全局最大池化的输出结果。

时序特征的组合通过全连接层实现:

$$\mathbf{o}_d = f_d(\mathbf{o}_p \times \mathbf{W}_d + b_d) \quad (4)$$

其中, \mathbf{W}_d 为全连接层的权值矩阵, b_d 为偏置,全连接层的激活函数 $f_d(\cdot)$ 有 ReLU、Tanh 和 Sigmoid 3 种。

输出层将全连接层的结果输出:

$$y = f_o(\mathbf{o}_d \times \mathbf{W}_o + b_o) \quad (5)$$

其中, \mathbf{W}_o 为输出层的权值矩阵, b_o 为偏置,激活函数 f_o 为 softmax 函数。

1.2 LSTM 模型

LSTM 的结构主要包括输入层、堆叠隐藏层和

输出层,其单元结构如图 1 所示。

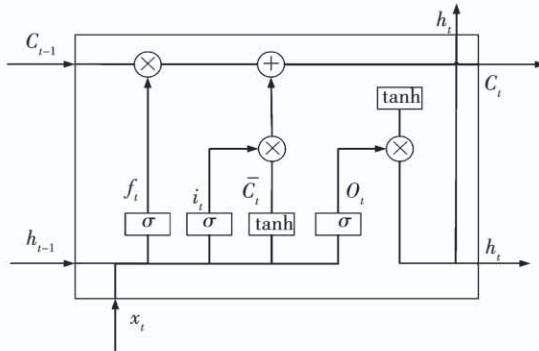


图 1 LSTM 单元结构

Fig. 1 Framework of LSTM

LSTM 主要利用门机制进行一系列操作,3 个机制门分别为输入门 i 、遗忘门 f 和输出门 o ,两个基本单元分别为元胞状态 C 和隐藏单元 h 。第一步要控制历史信息的保留程度,由遗忘门的 Sigmoid 函数完成:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (6)$$

其中, W_f 和 b_f 为 f_t 的权重矩阵和偏置。第二步要对当前输入信息的保留程度进行控制,由输入门的 Sigmoid 函数决定:

$$i_t = \sigma(W_i \times [h_{t-1}, x_t] + b_i) \quad (7)$$

其中, W_i 和 b_i 为 i_t 的权重矩阵和偏置。通过 Tanh 函数建立新的候选矢量 \bar{C}_t :

$$\bar{C}_t = \text{Tanh}(W_c \times [h_{t-1}, x_t] + b_c) \quad (8)$$

其中, W_c 为 Tanh 的权重矩阵, b_c 为偏置, C_{t-1} 和 \bar{C}_t 的权重分别为 f_t 、 i_t , 合并两个状态进而更新当前状态:

$$C_t = f_t \times C_{t-1} + i_t \times \bar{C}_t \quad (9)$$

第三步输出最新信息,由输出门的 Sigmoid 函数完成:

$$o_t = \sigma(W_o \times [h_{t-1}, x_t] + b_o) \quad (10)$$

$$h_t = o_t \times \text{Tanh}(C_t) \quad (11)$$

2 NO_x 预测模型构建

2.1 CNN-LSTM 模型

NO_x 预测模型的结构框架如图 2 所示。

模型中每一层的描述如下:

(1) 输入层。首先将 NO_x 排放量与大气温度、

负荷、燃料质量流量、旁路阀开度(BYCSO)、入口可调导叶开度(IGVCSO)和值班燃料比例(PLCSO)等能反映燃气轮机燃烧状态的运行数据进行奇异值分解和排查,剔除一些异常值、缺失项及非正常运行的数据。由于不同数据之间量纲不同,且数据和数据之间相差很大,为了便于模型训练,采用标准化方法进行转换,即:

$$\tilde{x} = \frac{x - \bar{x}}{\sigma} \quad (12)$$

式中: \bar{x} —某一参数数据 x 的平均值; σ —标准差; \tilde{x} —标准化处理后的值。

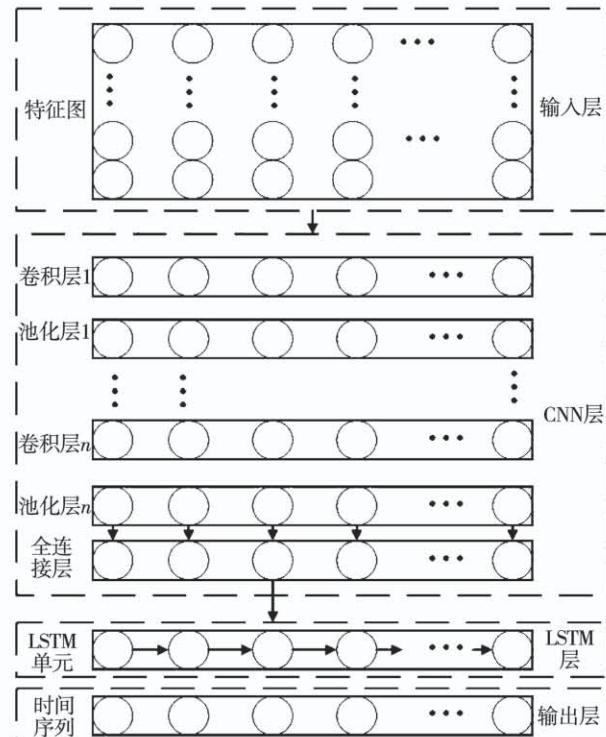


图 2 CNN-LSTM 预测模型结构

Fig. 2 Structure chart of CNN-LSTM prediction model

将已经进行预处理的数据串联成一维向量,得到新的序列,通过滑动窗口的方式依次将该序列变换为特征图,输入的特征图格式为:

$$\begin{bmatrix} X(T) & X(T+1) & X(T+2) & \cdots & X(T+k) \\ X(T+1) & X(T+2) & X(T+3) & \cdots & X(T+k+1) \\ \vdots & \vdots & \vdots & & \vdots \\ X(T+m) & X(T+m+1) & X(T+m+2) & \cdots & X(T+k+m) \end{bmatrix} \quad (13)$$

其中, $X(T)$ 表示 T 时刻反映燃气轮机燃烧状态

的运行数据串联形成的序列。

(2) CNN 层。本层将通过 CNN 神经网络将上述反映燃气轮机 NO_x 排放的特征图进行特征提取,其中卷积层和池化层可以压缩燃气轮机运行数据参数的数量,从而提取更明显反映 NO_x 变化的特征,并减小过拟合,全连接层可以汇总并输出上述特征。

(3) LSTM 层。本层将提取的特征转换为 LSTM 相应的数据格式,通过 LSTM 内部 3 个门机制对时间序列进行数据挖掘,获得其内部的变化规律,得到 NO_x 预测模型。

(4) 输出层。输出层的激活函数为 Sigmoid 函数,将 LSTM 预测的结果进行输出。

2.2 Nadam 优化算法

在神经网络的训练过程中,选择哪种优化方法寻找超参数对模型的性能有很大的影响。常用的优化算法可以通过 4 个步骤概括:

计算目标函数当前的梯度:

$$g_t = \nabla f(\omega_t) \quad (14)$$

计算一阶动量和二阶动量:

$$m_t = \varphi(g_1, g_2, \dots, g_t) \quad (15)$$

$$V_t = \gamma(g_1, g_2, \dots, g_t) \quad (16)$$

计算当前时刻的梯度:

$$\eta_t = \alpha \cdot m_t / \sqrt{V_t} \quad (17)$$

更新目标值:

$$\omega_{t+1} = \omega_t - \eta_t \quad (18)$$

式中: ω_t —待优化参数; α —学习率; $f(\omega_t)$ —目标函数。

随机梯度下降 (Stochastic Gradient Descent, SGD) 在对模型的优化过程中没有引入动量的概念,因此导致其收敛速度太慢,容易陷入局部最优值。

自适应动量估计 (Adaptive Moment Estimation, Adam) 是另一种常见的神经网络优化器,其引入了一阶动量和二阶动量,即:

$$m_t = \beta_1 \cdot m_{t-1} + (1 - \beta_1) \cdot g_t \quad (19)$$

$$V_t = \beta_2 \cdot V_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (20)$$

由于 Adam 优化器的自适应性会导致学习率在学习过程中发生剧烈变化,目标函数可能无法收敛。内斯特夫加速梯度 (Nesterov Accelerated Gradient, NAG) 是对一阶动量的改进:在更新过程中是以下一个时刻的梯度而非当前时刻的梯度,此时梯度定

义为:

$$g_t = \nabla f(\omega_t - \alpha \cdot m_{t-1} / \sqrt{V_{t-1}}) \quad (21)$$

NAG 利用了目标函数的二阶导数信息,使超参数随时间变化,保证学习率稳定变化。将 NAG 与 Adam 结合得到的 Nadam 能够对学习率有更强的约束,实现更好的搜索。

2.3 模型评价标准

为了更好地评价预测模型的精度,燃气轮机 NO_x 预测模型的评价指标选择平均相对误差 e_{MAPE} 和相对均方误差 e_{RMSE} :

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

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (23)$$

其中, y_i 和 \hat{y}_i 分别表示第 i 个数据的实际值和预测值, n 表示预测样本的数量。 e_{MAPE} 可以衡量模型预测结果的好坏, e_{RMSE} 可以评价预测的精度, 值越小说明预测结果越准确。

3 仿真结果及分析

3.1 实验环境和数据来源

实验台装有 NVIDIA TeslaP100 的 GPU 服务器,服务器配置为 16 核、200G 硬盘空间,采用 python 语言进行实验。

试验数据选取某电厂三菱燃气轮机组 2019 年 5 月 15 日至 2019 年 5 月 17 日共计 4 320 组,其数据的采样周期为 1 min,因为数据具有时序性,将前 4 200 组数据作为训练集,后 120 组作为测试集,在此基础上建立 CNN-LSTM 的 NO_x 预测模型。

3.2 模型训练及预测结果分析

先将得到的数据进行数据预处理,然后将某一时刻的 NO_x 排放量和与其相关的特征串联成向量表示,进而形成一个全新的时间序列数据,再利用滑动窗口的方式依次将该序列变换为特征图。在此,滑动窗口的宽度设置为 10,步长设置为 1,即输入前 10 个时刻的数据的历史数据用于预测。

CNN 模块参数设置如表 1 所示,其中,CW 为卷积核的宽度,CH 为卷积核的高度,CD 为卷积核的深度,Strides 为卷积核的步长,S 为池化层的池化带宽度,Drop 表示以一定的概率使某些神经元置为

零,在一定程度上抑制过拟合。

表 1 CNN 结构及参数

Tab. 1 CNN structures and parameters

编号	结构	参数
C1	卷积层 1	CH = 5, CW = 5, CD = 6, Strides = 4
S2	池化层 1	S = 2
C3	卷积层 2	CH = 5, CW = 5, CD = 6, Strides = 2
S4	池化层 2	S = 2
C5	卷积层 3	CH = 3, CW = 3, CD = 6, Strides = 1
S6	池化层 3	S = 2
F7	全连接层	240 个神经单元, Drop = 0.23

在 LSTM 神经网络中,将模型输入层的时间步数设置为 10。此外,适当增加模型的深度有助于提高其预测能力,但是隐含层过多也会增大计算量,经过试验调整,最终确定 LSTM 有两个隐含层,神经元数分别为 8 和 16,设置迭代步数为 1 000,损失函数选择 e_{RMSE} ,统计 3 种算法优化的模型在测试集上的相关指标如表 2 所示,3 种优化算法对应的损失函数在训练过程中的变化趋势如图 3 所示。

表 2 3 种优化算法对应的模型性能

Tab. 2 Model performance corresponded with three optimization algorithms

优化算法	$e_{\text{MAPE}} / \%$	$e_{\text{RMSE}} / \text{mg} \cdot \text{m}^{-3}$	耗时/s
SGD	7.985	2.382	215.265
Adam	4.158	1.875	162.541
Nadam	3.58	1.811	145.254

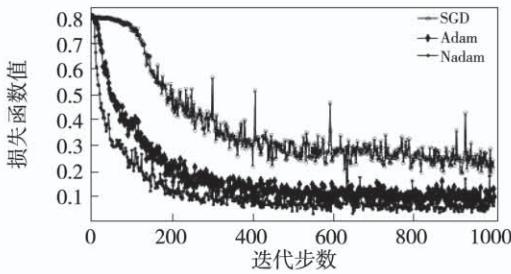


图 3 3 种算法优化的模型在训练过程中的损失函数值变化

Fig. 3 Variation of loss functions of the model optimized by three algorithms in the training process

由图 3 可知,SGD 算法对应的训练速度最慢而且损失函数值最大,最终为 0.266; Adam 在第 834

个迭代步数时的损失函数值为 0.122;而 Nadam 更快,仅用 761 个迭代步数就使得损失函数值达到稳定值 0.059,这表明选择 Nadam 算法能够使模型向着更好的方向学习,经过训练的模型准确度和速度都优于前者。通过表 2 可以看出,Nadam 算法优化模型的速度最快,同时可以更准确地得到 NO_x 的预测结果,为脱硝系统提供及时的控制指令。

3.3 典型模型对比

为验证本文方法的有效性,将其跟传统预测方法进行比较,通过主成分分析(Principal Component Analysis,PCA)提取影响 NO_x 的主要属性,作为预测模型 BP、RNN、LSTM 的输入,CNN-LSTM 和上述 3 种模型的预测结果如图 4~图 6 所示。

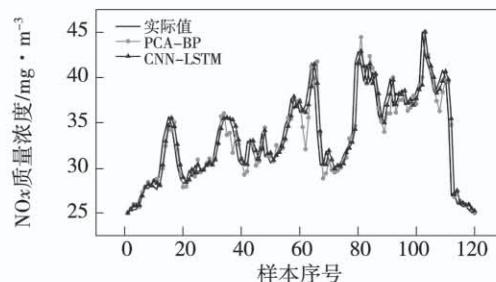


图 4 PCA-BP 和 CNN-LSTM 预测结果对比

Fig. 4 Comparison of PCA-BP and CNN-LSTM prediction results

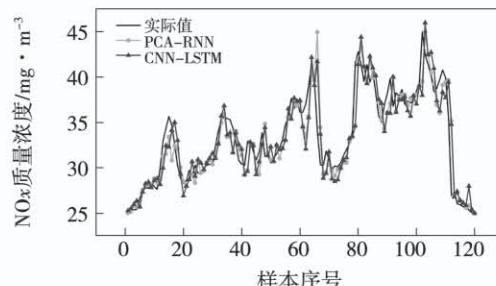


图 5 PCA-RNN 和 CNN-LSTM 预测结果对比

Fig. 5 Comparison of PCA-RNN and CNN-LSTM prediction results

由图 4~图 6 可知,BP 的预测误差最大,这是因为 BP 缺少对时序数据的相关性考虑;LSTM 及 RNN 能够对历史信息进行记忆,因此其预测误差均小于 BP,但是 RNN 容易产生记忆力缺失问题,所以预测后期的误差要比 LSTM 大;CNN-LSTM 模型弥补了单一 LSTM 的不足:通过 CNN 卷积层和池化层

的堆叠剔除冗余属性并构建特征向量,而并非像 PCA 那样进行特征提取,因此 CNN-LSTM 模型在生成特征的同时还保留了原始序列中完整的时间相关性,将这样的特征向量作为 LSTM 的输入可以更好地发挥其强大记忆力的优势。表 3 为不同模型预测误差。

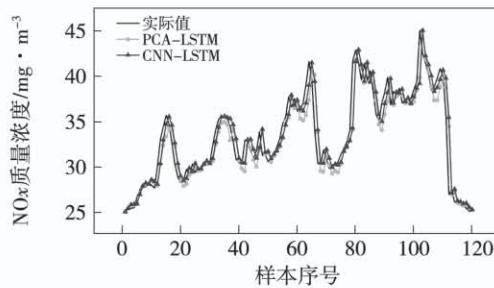


图 6 PCA-LSTM 和 CNN-LSTM 预测结果对比

Fig. 6 Comparison of PCA-LSTM and CNN-LSTM prediction results

表 3 不同模型的预测误差对比

Tab. 3 Comparison of prediction errors with different models

模型	e _{MAPE} /%	e _{RMSE} /mg · m ⁻³
PCA-BP	12.571	2.976
PCA-RNN	7.097	2.245
PCA-LSTM	4.7	1.963
CNN-LSTM	3.58	1.811

由表 3 可知,CNN-LSTM 在 e_{RMSE} 和 e_{MAPE} 指标上都有明显下降,表明其预测效果最好。相比于 PCA 降维的特征处理方式,LSTM 模型根据 CNN 提取的特征进行预测的效果有一定程度的提升,验证了 CNN 在形成特征的同时保证数据在时间维度上的关系不丢失,而 LSTM 又可以完整地考虑时间序列中长期的依赖性关系,因此组合 CNN 和 LSTM 可以更全面地发挥二者的优势,实现准确的 NO_x 排放预测,对掌握燃气轮机的燃烧优化调整技术和脱硝技术有一定的参考价值。

4 结 论

(1) 与 SGD、Adam 优化算法相比,Nadam 能更精确、更快速地训练神经网络模型,避免了因学习率剧烈下降带来的精度降低问题,使模型具有最好的

性能。

(2) 相比于 PCA 的特征提取处理方式,CNN 的卷积层和池化层可以更好地挖掘数据中蕴含的有效信息,而且保留数据在时间维度上的特征,有利于提高预测精度。

(3) 建立 CNN-LSTM 的燃气轮机 NO_x 预测模型,并以三菱燃气轮机的实时运行数据为例,对该模型进行了验证,对比 BP、RNN 等常见的机器学习模型,LSTM 更适合处理较长时间的序列数据,且该模型的 e_{RMSE} 为 1.811 mg/m³,表明该算法可以较好地对 NO_x 排放进行预测,为燃气轮机的燃烧优化调整技术和脱硝技术的研究积累了经验。

参 考 文 献:

- [1] 吴鹏,周锦晖,庄柯,等.燃气轮机脱硝技术现状及发展趋势[J].环境工程,2019,37(1): 103–105,181.
WU Peng, ZHOU Jin-hui, ZHUANG Ke, et al. Present status and development tendency of denitrification technology for gas turbines [J]. Environmental Engineering, 2019, 37(1): 103–105, 181.
- [2] 徐婷婷,丁阳,张梦可,等.燃气轮机燃烧调整国内外研究技术综述[J].华电技术,2018,40(12): 8–12.
XU Ting-ting, DING Yang, ZHANG Meng-ke, et al. Summary of domestic and overseas research on gas turbine combustion adjustment [J]. Huadian Technology, 2018, 40(12): 8–12.
- [3] 赵刚,朱华昕,李苏辉,等.基于数据和神经网络的燃气轮机 NO_x 排放预测与优化[J].动力工程学报,2021,41(1): 22–27.
ZHAO Gang, ZHU Hua-xin, LI Su-hui, et al. NO_x emission prediction and optimization of gas turbine based on data and neural network [J]. Journal of Chinese Society of Power Engineering, 2021, 41(1): 22–27.
- [4] 徐静馨,朱法华,王圣,等.超低排放燃煤电厂和燃气电厂综合对比[J].中国电力,2020,53(2): 164–172.
XU Jing-xin, ZHU Fa-hua, WANG Sheng, et al. Comprehensive comparison of ultra-low emission coal-fired power plants and gas-fired power plants [J]. Electric Power, 2020, 53(2): 164–172.
- [5] 温鑫,钱玉良,彭道刚,等.基于深度双向 LSTM 的 SCR 系统 NO_x 排放预测模型研究[J].热能动力工程,2020,35(10): 57–64.
WEN Xin, QIAN Yu-liang, PENG Dao-gang, et al. NO_x emission prediction model of SCR system based on deep bidirectional LSTM [J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(10): 57–64.

- [6] 郭瑞君,周磊,张国斌,等.基于 SCR 入口 NO_x 浓度和烟气流量预测的脱硝控制系统[J].热能动力工程,2020,35(9):141-147.
- GUO Rui-jun,ZHOU Lei,ZHANG Guo-bin,et al. Denitration control system based on SCR inlet NO_x concentration and flue gas flow prediction[J]. Journal of Engineering for Thermal Energy and Power,2020,35(9): 141 - 147.
- [7] 宋清昆,李源松. RBF 神经网络锅炉燃烧系统建模[J]. 哈尔滨理工大学学报,2016,21(1): 89-92.
- SONG Qing-kun,LI Yuan-song. Modeling of boiler combustion system based on RBF neural network[J]. Journal of Harbin University of Science and Technology,2016,21(1):89 - 92.
- [8] 马平,李珍,梁薇. 基于互信息的辅助变量筛选及在火电厂 NO_x 软测量模型中的应用[J]. 科学技术与工程,2017,17(22): 249-254.
- MA Ping,LI Zhen,LIANG Wei. Auxiliary variable selection based on mutual information and its application in NO_x soft sensor model of thermal power plant[J]. Science Technology and Engineering, 2017,17 (22) : 249 - 254.
- [9] 赵兵,王增平,纪维佳,等. 基于注意力机制的 CNN-GRU 短期电力负荷预测方法[J]. 电网技术,2019,43(12): 4370-4376.
- ZHAO Bing,WANG Zeng-ping,JI Wei-jia,et al. CNN-GRU short-term power load forecasting method based on attention mechanism [J]. Power System Technology,2019,43(12): 4370 - 4376.
- [10] 孔祥玉,郑峰,鄂志君,等. 基于深度信念网络的短期负荷预测方法[J]. 电力系统自动化,2018,42(5): 133-139.
- KONG Xiang-yu,ZHENG Feng,E Zhi-jun,et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems,2018,42(5) : 133 - 139.
- [11] 艾虎,李菲. 基于改进的长短期记忆神经网络方言辨识模型[J]. 科学技术与工程,2019,19(2): 163-169.
- AI Hu,LI Fei. Dialect recognition model based on improved short-term memory neural network[J]. Science Technology and Engineering,2019,19(2):163 - 169.
- [12] 李瑞凡,梁浩宇,史毅惠,等. Dual-CNN: a convolutional language decoder for paragraph image captioning[J]. Neurocomputing,2020,396: 92 - 101.
- [13] 王俊,李霞,周昔东,等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制,2020,48(11): 45 - 52.
- WANG Jun,LI Xia,ZHOU Xi-dong,et al. Ultra short term wind speed prediction based on VMD and LSTM[J]. Power System Protection and Control,2020,48 (11) : 45 - 52.
- [14] 葛阳,郭兰中,牛曙光,等. 基于 t-SNE 和 LSTM 的旋转机械剩余寿命预测[J]. 振动与冲击,2020,39 (7) : 223 - 231,273.
- GE Yang,GUO Lan-zhong,NIU Shu-guang,et al. Prediction of residual life of rotating machinery based on t-SNE and LSTM[J]. Vibration and Shock ,2020,39(7):223 - 231,273.
- [15] 陈亮,王震,王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术,2017,15(5):8 - 11.
- CHEN Liang,WANG Zhen,WANG Gang. Application of LSTM network in short-term power load forecasting under the framework of deep learning [J]. Power Information and Communication Technology,2017,15(5) : 8 - 11.

(王治红 编辑)