

DOI:10.19651/j.cnki.emt.2211530

# 基于 CNN(1D)-LSTM 模型的电站锅炉 SCR 入口 NO<sub>x</sub> 浓度预测

刘建军<sup>1,2</sup> 赵旭<sup>1,2</sup> 张卫东<sup>1,2</sup> 马达夫<sup>1,2</sup>

(1.上海交通大学电子信息与电气工程学院 上海 200240; 2.上海发电设备成套设计研究院有限责任公司 上海 200240)

**摘要:** 为了解决电站锅炉操作人员依赖经验调节锅炉运行参数降低 SCR 入口 NO<sub>x</sub> 浓度,提高脱硝效果的问题,提出一种 SCR 入口处 NO<sub>x</sub> 浓度预测方法。该方法建立了基于卷积神经网络和长短期记忆神经网络的 CNN(1D)-LSTM 模型,通过提取锅炉在时序上的特征参数,可预测 5 min 后 SCR 入口处 NO<sub>x</sub> 浓度。电厂运行人员可将该模型的预测结果作为 SCR 入口处 NO<sub>x</sub> 浓度的重要参考,更加有效地调节锅炉参数进行脱硝优化。结果表明,预测 3 min 后 SCR 入口处 NO<sub>x</sub> 浓度 LSTM 模型优于 CNN(1D)-LSTM;预测 5 min 后的 SCR 入口浓度 CNN(1D)-LSTM 模型相比于 LSTM 模型预测精度有很大的所提高,在测试集上  $E_{mape}$  为 7.05%,取得了期望的效果。

**关键词:** CNN(1D)-LSTM;SCR;NO<sub>x</sub> 浓度

**中图分类号:** TK223.7 **文献标识码:** A **国家标准学科分类代码:** 470.10

## Prediction of NO<sub>x</sub> concentration at SCR inlet of utility boiler based on CNN(1D)-LSTM model

Liu Jianjun<sup>1,2</sup> Zhao Xu<sup>1,2</sup> Zhang Weidong<sup>1,2</sup> Ma Dafu<sup>1,2</sup>

(1. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. Shanghai Power Equipment Research Institute Co., Ltd, Shanghai 200240, China)

**Abstract:** In order to solve the problem that power plant boiler operators rely on experience to adjust boiler operating parameters to reduce the NO<sub>x</sub> concentration at the SCR inlet and improve the denitration performance, a method for predicting the NO<sub>x</sub> concentration at the SCR inlet is proposed. This method establishes a CNN(1D)-LSTM model based on convolutional neural network and long short-term memory neural network. The NO<sub>x</sub> concentration at the SCR inlet can be predicted after 5 min. Power plant operators can use the prediction results of the model as an important reference for the NO<sub>x</sub> concentration at the SCR inlet, and more effectively adjust boiler parameters for denitrification optimization. The results show that the LSTM model for predicting the NO<sub>x</sub> concentration at the SCR inlet after 3 min is better than CNN(1D)-LSTM; the CNN(1D)-LSTM model for predicting the SCR inlet concentration after 5 min has a great prediction accuracy compared with the LSTM model. The  $E_{mape}$  on the test set is 7.05%. The desired effect was achieved.

**Keywords:** CNN(1D)-LSTM;SCR;NO<sub>x</sub> concentration

## 0 引言

在我国,大气污染物中氮氧化物(NO<sub>x</sub>)占有很大比例,是酸雨和光化学烟雾形成的主要原因,会对人类健康和环境保护造成很大危害。其中很大一部分的 NO<sub>x</sub> 来自于火力发电厂煤炭的燃烧,因此控制电厂 NO<sub>x</sub> 的排放对减少大气污染物的排放有很重要的意义。

现如今,多数火力发电厂采用选择性催化还原法

(selective catalytic reduction, SCR) 进行脱硝处理,因为 SCR 技术的脱硝率可达 90% 以上,而且因技术可靠、结构简单、氨气逃逸率小等优点已成为燃煤电站锅炉控制 NO<sub>x</sub> 排放的主要选择<sup>[1]</sup>。SCR 进行脱硝关键在于获取入口处 NO<sub>x</sub> 的浓度,以此来计算出喷氨量。如果获取的 SCR 入口处 NO<sub>x</sub> 浓度不准确,喷氨过多就会造成氨气逃逸,产生硫酸氢铵堵塞空预器,现已成为国内煤电机组的共性问题;而喷氨不足会造成氮氧化物排放量过高,对大气环境造成

污染<sup>[2]</sup>等一系列问题。因此及时准确的预测当下和未来一段时间的 NO<sub>x</sub> 浓度,对脱硝的效果至关重要。

锅炉是一个多参数、强耦合、非线性、大滞后、大惯性系统,影响 SCR 入口 NO<sub>x</sub> 浓度的参数非常复杂。锅炉众多参数和 SCR 入口处 NO<sub>x</sub> 浓度存在着高度非线性的函数关系,现今并没有明确的数学模型能够对其进行准确描述。目前操作人员多依据经验对锅炉运行参数进行调整,经常难以取得满意的效果。

近些年,随着计算机算力的提升,神经网络作为非线性模型得到了广泛的应用,国内研究人员使用神经网络在图像识别、短期电力负荷预测<sup>[3]</sup>、锅炉热效率预测<sup>[4]</sup>、锅炉受热面热偏差预测<sup>[5]</sup>、燃气轮机 NO<sub>x</sub> 排放预测<sup>[6]</sup>等方面取得了比较好的效果,在电站锅炉 NO<sub>x</sub> 排放预测方面邢红涛等<sup>[7]</sup>同样使用了卷积神经网络和长短期记忆神经网络的混合模型(CNN-LSTM)对当下 NO<sub>x</sub> 排放量做了预测并取得了良好效果。但其中也存在一些不足,文献[4]中的训练数据仅 174 条,文献[5]拥有 500 条训练数据,对于一个少则拥有十几万、数百万,多则拥有千万甚至上亿级别参数的网络来说,要在如此少量的训练数据中获取一个实用性较强的网络存在着明显的不足。文献[6-7]所给出的网络,并没有指出其中超参数选择的依据,例如长短期记忆神经网络(long short term memory, LSTM)层数和隐藏层神经元个数的选择依据,缺少一定的实验分析,其次这两篇文献都是使用的 2 维卷积神经网络(convolutional neural network, CNN)模型对锅炉参数进行特征提取,这样一定程度上会使得数据在时序上的信息被湮灭。赵文杰等<sup>[8]</sup>使用基于多最小二乘支持向量机方法预测 NO<sub>x</sub> 浓度,这种浅层网络比较适合在小样本数据集上使用,在大样本数据集上深层网络的鲁棒性一般会更好。本文在大量的运行数据,多次实验分析的基础上提出了一维卷积神经网络和长短期记忆神经网络的混合模型(CNN(1D)-LSTM)模型对电站锅炉 SCR 入口处未来 5 min NO<sub>x</sub> 浓度做出预测。

CNN 网络具有优秀的特征提取能力,在锅炉大量相互耦合的参数中能够自动提取出与 SCR 入口处 NO<sub>x</sub> 浓度有关系的参数特征,以此作为 LSTM 网络的输入参数。LSTM 模型可有效利用时序数据<sup>[9]</sup>,对当下和未来结果做出精准预测。本文将结合二者的优点,建立 CNN(1D)-LSTM 模型,预测未来 5 min 内 SCR 入口处 NO<sub>x</sub> 浓度。操作人员可将该模型的结果作为 SCR 入口处 NO<sub>x</sub> 浓度的重要参考,更加有效地调节锅炉参数进行脱硝优化。

## 1 CNN 网络结构

1998 年, Lecun 等<sup>[10]</sup>首次提出了基于梯度计算的 LeNet-5 卷积模型,凭借着局部连接和权值共享特点的网络结构,在手写数字识别方向上极大的提高了识别准确度,由此形成了 CNN 网络的最初模型。随着算力的进一步提升, CNN 依靠其权值共享、稀疏连接、降采样等特点,使得

其可以具有深层的结构, AlexNet<sup>[11]</sup>借助更深层网络结构提取了训练数据集中更加抽象的图像特征,在 Imagenet 图像识别大赛上极大的提高了图像识别准确率,极大地推动了后续 CNN 网络的发展。在此基础上的,后续出现的 VGGNet<sup>[12]</sup>、ResNet<sup>[13]</sup>,都在计算机视觉中取得了很好的效果。与浅层网络相比, CNN 以巨量的训练参数,更深的网络结构在特征提取上拥有了巨大的优势,其能在巨量的数据中提取出更加抽象的特征空间<sup>[14]</sup>,在实际使用中具有更好的泛化效果,近些年 CNN 网络在目标识别领域取得了巨大的成功。国内很多学者受此启发,将 CNN 网络应用于锅炉关键参数预测,取得了良好的效果。

如图 1 所示,卷积神经网络包括输入层、卷积层、池化层、全连接和输出层。CNN 通过多次卷积和池化操作能够提取原始数据中抽象特征,获取输入数据中的有效信息,建立能够完整描述训练数据的特征向量。卷积层负责在训练数据中提取特征,并将其映射到高纬度空间,因为其“局部连接”和“权值共享”特点,与全连接网络相比,大大减少了网络模型参数的数量,使得网络具备了稀疏连接的特性,降低了网络的训练难度,可以使得网络具有更深层次的结构,因此能够提取出数据中更加抽象的特征数据。同时, CNN 网络相对全连接神经网络训练参数的大幅度减少,使得模型训练的过程中可以有效避免梯度消失、过拟合等问题,增强模型泛化能力。激活层为网络加入了非线性单元,使得网络具备了非线性描述的能力,能够拟合复杂系统。池化层进一步简化了网络的复杂程度,由于池化层多采用平均池化和最大池化,模型具备了平移和旋转不变性,网络整体的鲁棒性进一步增强。




图 1 LeNet-5 模型

## 2 LSTM 网络结构

CNN 网络的输出只与对应的输入有关,无法处理在时间维度上有依赖关系的数据。为了构建一种能够有效利用时序数据关系的神经网络,美国科学家 Jeffrey 在前人的基础上提出了循环神经网络(recurrent neural networks, RNN), RNN 增加了一种反馈结构,当前时序的输出,不仅能利用当下数据还可以从历史数据中提取有效特征。

当在时间序列上分布的数据存在相互联系、相互影响时,就需要一种能够利用历史数据的结构。如图 2 所示的 RNN 网络由输入层、隐藏层和输出层组成,其隐藏层链式连接,当前隐藏层的输出不仅取决于当前输入,还与上一隐藏层的输出有关,对应的迭代公式如下:

$$S_i = f(U \cdot X_i + W \cdot S_{i-1}) \quad (1)$$

$$O_t = g(V \cdot S_t) \quad (2)$$

式中:  $S_t$  隐藏层输出;  $X_t$  神经元的当前输入;  $U$  为输入向量的权重;  $W$  为隐藏层权重;  $V$  为输出层权重;  $f$  为隐藏层激活函数;  $g$  输出层激活函数。由式(1)可知, 当前神经元的输出  $S_t$  不仅与当前输入  $X_t$  还与上一个神经元隐藏层的输出  $S_{t-1}$  有关, 这一结构的设计使得 RNN 网络具有了“记忆”的功能, 当前的输出能够利用之前时刻的数据信息。




图 2 RNN 模型

RNN 网络虽然结构简单, 但是当时间序列过长时候, 网络模型容易出现梯度爆炸和梯度消失等问题<sup>[15]</sup>。因此 Hochreiter 等<sup>[16]</sup>在 RNN 的基础上进行了改进, 提出了如图 3 所示的 LSTM。LSTM 在 RNN 的基础上增加了遗忘门、记忆门和输出门结构。




图 3 LSTM 模型

如图 4 所示, LSTM 网络的门结构在网络中起到了滤波的作用, 对之前时刻神经元的状态输出和当前的输入通过激活函数和权重向量选择性保留和舍弃, 为神经元的提供了更加丰富的数据结构。

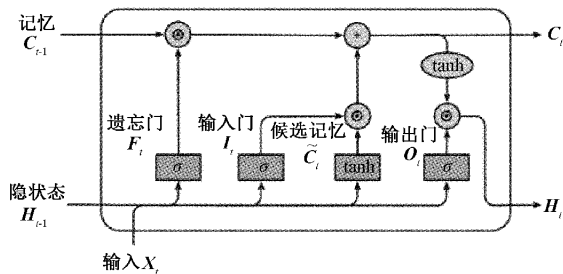


图 4 LSTM 模型门结构

LSTM 网络门结构公式如式(3)~(8)所示。其中式(6)中, 将遗忘门和输入门的数据做矩阵加和运算, 解决了 RNN 中的长期依赖导致的梯度爆炸和梯度消失的问题, 使得 LSTM 网络在长时序处理上的表现优于 RNN 网络。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (8)$$

式中:  $\sigma$  为 Sigmoid 激活函数;  $W_f, W_i, W_c, W_o$  分别为遗忘门、输入门、状态更新、输出门权重;  $b_f, b_i, b_c, b_o$  分别为遗忘门、输入门、状态更新、输出门偏执向量;  $h_{t-1}$  为 LSTM 的前一个单元的输出信号;  $x_t$  为当前时间步隐藏层神经元的输入;  $O_t$  输出门权重向量;  $\tilde{c}_t$  为候选记忆门状态矩阵; 神经元状态  $c_t$  为当前神经元状态更新矩阵。

### 3 NO<sub>x</sub> 预测模型

#### 3.1 CNN(1D)-LSTM 模型

为了分别利用 CNN(1D), LSTM 网络在特征提取、时序数据处理上的优势, 如图 5 所示, 本文提出了两者结合的模型结构: CNN(1D)-LSTM 网络。CNN(1D)网络负责在大量的电站锅炉运行参数中提取与 SCR 入口 NO<sub>x</sub> 浓度相关的特征向量, 利用卷积层和池化层对数据进行压缩, 减少网络的训练参数数量, 构建高维时序特征。在一定范围内, CNN(1D)网络特征提取能力和其深度成正比, 因此先设计一个浅层网络, 在欠拟合的基础上增加网络层数, 直至产生过拟合现象, 再引入 Dropout 层、正则化等措施减小过拟合现象, 来保证网络具有充足的特征提取能力, 在抽象出有效特征后, 将其进行 Flatten 操作。模型构建中利用 keras 的 TimeDistributed 函数以 15 个时间步为一组输入 LSTM 网络。

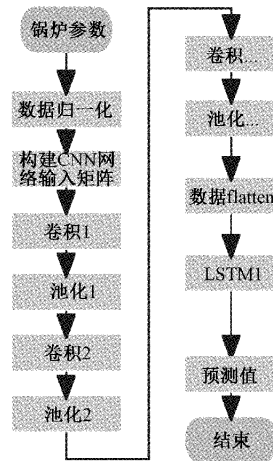


图 5 CNN(1D)-LSTM 模型

利用 LSTM 在处理时序数据上的优势, 以 CNN(1D) 抽象出的经过维度变换的特征向量作为输入进一步训练, 利用网络中的“门”结构对具有时间序列的数据进行非线性处理, 提取时序数据之间的关系, 构建锅炉参数与 NO<sub>x</sub> 浓度在时序上的非线性模型, 预测 SCR 入口的 NO<sub>x</sub> 浓度, 为

制定喷氨策略提供参考依据。

3.2 模型训练数据选取

首先选取直接对 SCR 入口 NOx 浓度有直接影响的参数: 锅炉负荷、主蒸汽压力、主蒸汽流量、总风量、一次风风量、二次风风量、运行氧量、SOFA(燃尽风)风量、层操二次风风门开度、燃烧器摆角、磨煤机组合、输入煤粉量、煤粉细度等。

除此之外, 炉膛出口温度数据反应了炉内燃烧的情况, 炉内燃烧从一定程度上与热力型 NOx 的生成有关<sup>[17]</sup>, 因此炉膛出口温度也间接的影响着 SCR 入口 NOx 浓度, 考虑到这种情况将其也加入到模型的训练数据中。

3.3 数据预处理

本文数据选取新疆五彩湾某电厂 #1 机组 2022 年 5 月 12 日~2022 年 5 月 23 日实际运行数据, 剔除异常值之后, 共计 16 368 条, 包含机组的负荷升降、各稳态工况, 建立了完整描述锅炉运行的数据集, 因此训练的模型, 不仅能够对稳态工况适用, 对升降负荷的情况同样具有良好的效果。采集数据按照训练集、验证集、测试集 85%、10%、5%划分。由于锅炉各个参数的纲量不同, 彼此之间差距很大, 因此需要对数据进行归一化处理, 来避免纲量小的数据信息被淹没。对数据进行归一化化处理后, 把特征参数缩放到 [0, 1] 之间, 公式如下:

$$Z_i = \frac{x_i - \text{Min}}{\text{Max} - \text{Min}} \quad (9)$$

式中:  $x_i$  为采集的特征数据; Min 为对应特征数据的最小值; Max 为对应特征数据的最大值;  $Z_i$  为归一化处理后的数据。

3.4 模型输入数据构建

本文采用均方误差 (mean-square error, MSE) 来作为网络模型的损失函数, 当模型使用归一化的数据训练网络模型, 损失函数较小, 不同参数下模型得出的 NOx 预测值和实际值差值不大, 选用的 MSE 误差函数能够易于比较不同参数下模型之间差值。同时为了直观的得到模型在测试集上的效果, 当模型训练好之后, 将归一化的数据还原为初始值, 使用平均百分比误差函数 MAPE 来评价模型在测试集上的效果。

$$MSE = \frac{1}{N} \sum_{i=1}^n (y'_i - y_i)^2 \quad (10)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \frac{|y'_i - y_i|}{y_i} \quad (11)$$

式中:  $y_i$  表示实际值;  $y'_i$  表示预测值;  $N$  表示样本的数量。

每个电厂的锅炉特性不同, 在运行参数调整之后, 需要多久能够对 SCR 入口处 NOx 浓度产生影响, 每个电厂不一而同。鉴于这种情况, 使用 CNN(1D)-LSTM 模型以一分钟作为一个时间步, 分别用 3、5、10、15 个时间步预测 1、3、5 min 后的 SCR 入口 NOx 浓度。

除了上述在数据构建上的超参数, 网络构建中的超参

数还有: CNN(1D) 网络层数、卷积核数目、LSTM 网络层数、LSTM 网络隐藏层神经元数目。为了找出其中最优的组合方式, 对所有超参数进行遍历, 进行 100 个 epoch 训练, 在每次训练过程中借助 Keras 框架提供的 ModelCheckpoint 方法, 把在验证集上损失函数取最小值的权重保存下来。在得到了所有超参数组合后的模型权重之后, 控制时间步和预测时间的组合, 选择在验证集上损失函数取得最小值的模型, 在测试集上的结果如表 1~3 所示。

表 1 CNN(1D)模型在不同时间步下预测不同时间下的误差 MAPE %

预测时间	时间步			
	3	5	10	15
1	14.23	16.70	15.10	14.65
3	15.30	17.70	14.96	14.35
5	16.52	16.27	15.12	14.22

表 2 LSTM模型在不同时间步下预测不同时间下的误差 MAPE %

预测时间	时间步			
	3	5	10	15
1	2.19	2.30	2.55	2.57
3	6.50	5.45	5.03	4.94
5	7.77	6.63	7.46	10.99

表 3 CNN(1D)-LSTM模型在不同时间步下预测不同时间下的误差 MAPE %

预测时间	时间步			
	3	5	10	15
1	2.23	2.53	3.51	3.23
3	5.42	5.92	5.87	5.73
5	7.69	7.25	7.19	7.05

由表 1 可知, CNN(1D) 模型在预测未来 SCR 入口处 NOx 浓度效果比较差, 之所有会出现这样的情况, 是因为 CNN 网络虽然在特征提取上具备优势, 但不能利用数据在时序上的关系。锅炉是一个大惯性系统, 运行参数调整后产生响应需要一定的时间。由表 2、3 可知, 整体上预测的时间越往后, 模型的预测精度越低, 预测难度越大。通过表 2、3 的对比分析可知, 当预测 1 min 后的 NOx 浓度时, LSTM 和 CNN(1D)-LSTM 模型均为使用 3 个时间步预测效果最好, 这是因为模型利用到了当下 NOx 浓度的信息而使得运行参数的权重下降。预测 3 min 的后的 NOx 浓度, LSTM 模型明显优于 CNN(1D)-LSTM, 主要是因为此时 NOx 与运行参数特征的关系比较容易提取, LSTM 模型完全能够胜任。但是当预测 5 min 后的 NOx 浓度时, CNN(1D)-LSTM 的预测精度明显优于 LSTM 网络, 尤其



是使用 15 个时间步时,LSTM 模型误差为 10.99%,而 CNN(1D)-LSTM 误差为 7.05%。因为此时运行参数与 NO<sub>x</sub> 浓度在时序上的距离更加遥远,之间的关系更加抽象,LSTM 网络已经不能够从原始的特征向量中提取到足够的有效信息。此时 CNN(1D)网络利用了其在特征参数提取上的优势,对数据进行维度变换,抽象出与 5 min 后 NO<sub>x</sub> 浓度有关的参数向量,以此作为 LSTM 模型的输入,因此 CNN(1D)-LSTM 模型取得了相对较好的效果。当预测 5 min 后的 NO<sub>x</sub> 浓度,使用 15 个时间步和 CNN(1D)-LSTM 更好。同时上述模型是在 100 个 epoch 训练中选取的最优模型,如果增加训练次数可以继续提高预测准确率。

将与 SCR 入口 NO<sub>x</sub> 浓度有关的参数特征串联起来,形成某一时刻的一维特征向量。用 1 维 CNN 网络对数据进行特征提取,为了保留下提取后数据在时序上的关系,引入 TimeDistributed 函数。TimeDistributed 函数能够把 1 维 CNN 网络的输出按照原来的时序特征按照顺序输出给 LSTM 网络。2 维的 CNN 模型在进行完特征提取后输出的进入 LSTM 网络的特征已经丧失了数据在时序的明确含义,而时序上的明确恰恰是 LSTM 网络需要的。这也是本文最终选择 1 维 CNN 网络的原因。

根据表 2、3 得出的结论,利用 15 min 的锅炉运行数据,通过 CNN(1D)-LSTM 模型对 5 min 后的 NO<sub>x</sub> 浓度预测效果较好。将生成一维特征向量,先卷积再利用 TimeDistributed 函数对数据时序特征保留的特性,构成具有 15 个时间步的输入数据,在数据进入 LSTM 网络模型之前保留了其在时序的关系。具体过程如图 6 所示。

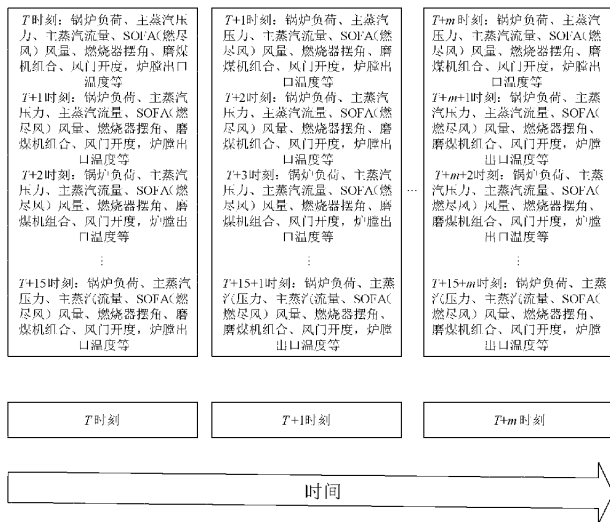


图 6 CNN(1D)-LSTM 网络模型输入数据模型

### 3.5 实验结果分析

通过上面的分析,最终模型使用 3 个 Conv1D 层,2 个 MaxPooling1D 层,1 个 LSTM 层,1 个 Dense 层,可以取得理想的结果。

具体的网络结构如表 4 所示。

表 4 CNN(1D)-LSTM 模型结构

名称结构	参数
Conv1D	卷积核个数:32;卷积核宽度:3
MaxPooling1D	池化层宽度:3
Dropout	0.25
Conv1D	卷积核个数:64;卷积核宽度:3
MaxPooling1D	池化层宽度:3
Dropout	0.25
Conv1D	卷积核个数:64;卷积核宽度:3
LSTM	隐藏单元数:16
Dense	输出单元数:1

如图 7 所示,随着训练迭代次数的增加,训练集和验证集的误差函数的损失值在前 20 个 epoch 急剧下降,在第 60 个 epoch 后达到最小。随着迭代次数的增加,训练集的损失值一直在减小,而验证集损失函数值略有增加,说明在后期模型出现过拟合现象,但并不明显。




图 7 CNN(1D)-LSTM 网络模型在验证集上的损失函数 MSE 值的变化

为了证明 CNN(1D)-LSTM 网络的效果,将 3 种模型分别在相同的完整数据集上进行训练和测试,结果如表 5 所示。

表 5 15 个时间步下不同模型的 MAPE %

模型	预测时间		
	1	3	5
CNN(1D)	14.65	14.35	14.22
LSTM	2.57	4.94	10.99
CNN(1D)-LSTM	3.23	5.73	7.05

在相同训练数据集的情况下,通过实验对比,当预测 3 min 后的 NO<sub>x</sub> 浓度时使用 LSTM 模型较好,误差 4.94% 在可接受范围内。但是当预测 5 min 后的 NO<sub>x</sub> 浓度时候使用 CNN(1D)-LSTM 混合模型较好,因为随着时间步的增加,在时间上预测 NO<sub>x</sub> 浓度的推迟,通过 CNN(1D)模型能够提取出更加抽闲的特征,这使得混合模型 7.05% 的误差远优于了单一模型 LSTM 的 10.99%。电站锅炉是一个多参数、大惯性的系统,在实际生产中 SCR 入口 NO<sub>x</sub> 测量误差在 ±15% 便可以满足制订喷氨策

略的要求,因此本模型在测试集上 7.05% 的误差,可以为运行人员提供有价值的参考意见。通过图 8 和 9 的对比可知,在预测 3 min 后的 NO<sub>x</sub> 浓度,LSTM 性能好于混合模型 CNN(1D)-LSTM;在预测 5 min 后的 NO<sub>x</sub> 浓度,混合模型优于 LSTM。




图 8 模型预测 3 min 后的 NO<sub>x</sub> 浓度




图 9 模型预测 5 min 后的 NO<sub>x</sub> 浓度

### 3.6 模型在实际生产中的指导意义

将本模型发布为 Web 服务,同时打通与电厂 SIS 系统之间的数据接口,模型就可以实时地获取到现场的生产数据,运行人员可以同步获取预测数据。在打通模型和生产数据的同时,开放出一个可供运行人员手动输入修改锅炉参数的数据接口,当需要对运行参数调整降低 SCR 系统入口处 NO<sub>x</sub> 浓度时,便可先在本模型上模拟调节锅炉参数,获取 SCR 入口处 5 min 后的 NO<sub>x</sub> 浓度,以此作为参考,得到满意的结果之后,再把合适的参数应用到实际生产中。这样就能极大的降低运行人员的试错成本,提高生产效率。

## 4 结 论

本模型很好地利用了 CNN 网络在特征提取中的优势,在海量的数据中通过反复迭代获取了能够充分反应 SCR 入口 NO<sub>x</sub> 浓度的特征参数。在得到了有效的特征参数之后,LSTM 发挥了其在时序数据处理上的优点,结合两者的优势,最终获得了一个良好的模型,在测试集上取得了 7.05% 的误差,能够满足实际生产的需求。

采用 CNN(1D)-LSTM 网络模型预测未来 5 min 内 SCR 入口处 NO<sub>x</sub> 浓度,能为运行人员提供直观的、有价值的参考,并且不影响锅炉的正常运行,降低试错成本,提高生产效率。

电站锅炉 SCR 入口处的 NO<sub>x</sub> 浓度受多种因素影响,例如二次风,燃尽风,燃烧器摆角,煤粉细度,磨煤机组合等多种因素,传统方法很难充分利用这些参数建立高度非线性的数学模型,在预测时候难免会有不小的误差。本模型的优势恰在于能够充分考虑到各种运行参数对 SCR 入口 NO<sub>x</sub> 的影响,又可以抽象出其中的有效信息,建立出预测 NO<sub>x</sub> 非线性模型。

本模型采集的数据超过 16 000 条,训练数据超过 13 000 条,不仅包括了不同负荷下的稳定工况,还包含了升降负荷情况,克服了传统方法只能在稳态工况下才能进行参数软计算的缺点。该模型能够适应锅炉各工况下 SCR 入口 NO<sub>x</sub> 浓度预测需求,并在实际生产数据上取得良好的测试效果。

### 参 考 文 献

- [1] 赵乾. SCR 烟气脱硝系统模拟优化及喷氨量最优控制[D]. 重庆:重庆大学,2012.
- [2] 李元浩. 基于神经网络的电站锅炉 NO<sub>x</sub> 排放预测方法研究[D]. 武汉:华中科技大学,2019.
- [3] 陆继翔,张琪培,杨志宏,等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化,2019,43(8):131-137.
- [4] 胡怀中,张建博,刘汉青,等. 采用卷积神经网络的电站锅炉燃烧效率建模方法[J]. 西安交通大学学报,2019,53(10):10-15.
- [5] 陈端雨,崇培安,陶丽,等. 神经网络在超临界锅炉热偏差优化调整中的应用[J]. 锅炉技术,2013,44(4):4-8.
- [6] 董渊博,茅大钧,章明明. 基于 CNN-LSTM 的燃气轮机 NO<sub>x</sub> 排放预测研究[J]. 热能动力工程,2021,36(9):132-138.
- [7] 邢红涛,郭江龙,刘书安,等. 基于 CNN-LSTM 混合神经网络模型的 NO<sub>x</sub> 排放预测[J]. 电子测量技术,2022,45(2):98-103.
- [8] 赵文杰,吕猛. 基于多 LS-SVM 集成模型的锅炉 NO<sub>x</sub> 排放量建模[J]. 电子测量与仪器学报,2016,30(7):1037-1044.
- [9] PALANGI H, LI D, SHEN Y, et al. Deep sentence embedding using long short-term memory networks: Analysis and application to information retrieval[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2016, 24(4): 694-707.
- [10] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural

- networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [12] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014, DOI: 10.48550/arXiv.1409.1556.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 770-778.
- [14] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C]. European Conference on Computer Vision. Springer, Cham, 2014: 818-833.
- [15] 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.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [17] 顾卫荣, 周明吉, 马薇. 燃煤烟气脱硝技术的研究进展[J]. 化工进展, 2012, 31(9):2084-2092.

#### 作者简介

刘建军, 硕士研究生, 主要研究方向为火力发电厂节能减排、电厂信息化方面的研究。

E-mail: liujianjun3@speri.com.cn

赵旭, 硕士, 工程师, 主要研究方向为火电灵活调峰、机组喷氨优化。

E-mail: zhaoxu3@speri.com.cn

张卫东, 博士生导师, 教授, 主要研究方向为智能控制、模式识别等理论研究及海洋机器人和智能电网等应用研究。

E-mail: wdzhang@sjtu.edu.cn

马达夫(通信作者), 高级工程师, 主要研究方向为火电灵活性与燃烧优化研究。

E-mail: madafu@speri.com.cn