DOI:10.13718/j.cnki.xsxb.2023.04.003

基于 AE-LSTM 混合神经网络模型的 NO_x 排放预测①

苏盈盈, 张气皓, 罗妤, 周昊, 何亚平, 阎垒

重庆科技学院 电气工程学院, 重庆 401331

摘要: 通过建立有效的 NO_x 浓度预测模型, 可降低垃圾焚烧厂产生的 NO_x 排放. NO_x 浓度受多个过程变量的影响, 针对变量的时序特征和空间特征, 提出了一种基于自动编码器(AE)和长短期记忆(LSTM)神经网络的 NO_x 浓度预测方法. 自动编码器用于提取原始数据的深层次多维信息特征, 并将其转换为低维数据特征. 这样可以保留原始数据的大量信息, 同时降低网络预测的复杂性. 长短期记忆神经网络则用于建立 NO_x 浓度预测模型, 该模型可以自动识别数据中的时序特征和空间特征, 并用于训练和优化 LSTM 网络参数. 该研究以重庆市某垃圾焚烧厂某锅炉的燃烧数据作为研究对象, 并使用数据挖掘技术对原数据进行处理. 接着, 使用自动编码器(AE)提取数据的深层次多维信息特征, 并将其输入到 LSTM 网络中进行建模. 通过标准化工况数据进行训练和优化 LSTM 网络参数, 最终建立了改进的 AE-LSTM 的 NO_x 浓度预测模型. 实验结果表明, 该改进模型相较于 LSTM 模型, 预测准确率提高了 5.4%且均方根误差降低了 0.128, 证明了该研究所采用的方法具有很好的应用价值, 可以有效降低垃圾焚烧厂产生的 NO_x 排放.

关 键 词: 预测模型; 长短期记忆神经网络; 混合神经网络

中图分类号: TK223 **文献标志码**: A **文章编号**: 1000-5471(2023)04-0023-09

NO_x Emission Forecasting Based on AE-LSTM Hybrid Neural Network

SU Yingying, ZHANG Qihao, LUO Yu,
ZHOU Hao, HE Yaping, YAN Lei

College of Electrical Engineering, Chongqing University of Science and Technology, Chongqing 401331, China

Abstract: By establishing an effective NO_x concentration prediction model, the NO_x emissions from waste incineration plants can be reduced. The NO_x concentration is affected by multiple process variables. A NO_x concentration prediction method based on an autoencoder (AE) and a long short-term memory neural network (LSTM) is proposed, taking into account the temporal and spatial features of the variables. The au-

① 收稿日期: 2022-04-17
基金项目: 重庆市自然科学基金项目(No. cstc2019jcyj-msxmX0220, No. CSTB2022NSCQ-MSX1425); 重庆市教育委员会科学技术研究项目 (KJQN202101510).
作者简介: 苏盈盈, 博士, 教授, 硕士生导师, 主要从事人工智能研究.
通信作者: 罗妤, 博士, 讲师.

toencoder(AE) is used to extract the deep-level multidimensional information features of the original data and transform them into low-dimensional data features, which can preserve a large amount of information from the original data while reducing the complexity of the prediction network. The long short-term memory neural network (LSTM) is used to establish the NO_x concentration prediction model, which can automatically identify the temporal and spatial features in the data and is used to train and optimize the LSTM network parameters. This study takes the combustion data of a boiler in a waste incineration plant in Chongqing as the research object and uses data mining technology to process the original data. Then, the autoencoder(AE) is used to extract the deep-level multidimensional information features of the data, which are input into the LSTM network for modeling. The improved AE-LSTM NO_x concentration prediction model is established by training and optimizing the LSTM network parameters with standardized operating condition data. Experimental results show that the improved model increases the prediction accuracy by 5.4% and reduces the root-mean-square error by 0.128 compared to the LSTM model, demonstrating that the method adopted in this study has good application value and can effectively reduce NO_x emissions from waste incineration plants.

Key words: prediction model; long and short-term memory neural network; hybrid neural network

从环境保护的角度考虑，垃圾焚烧厂需要建立一个能够反映锅炉燃烧变量和排放尾气 NO_x 浓度之间关系的模型，以便能够快速响应对 NO_x 尾气的控制. NO_x 是垃圾焚烧发电厂的主要排放物之一，对环境和人类健康有害[1]. 人们已经考虑采用不同的技术来减少 NO_x 的排放，例如低 NO_x 燃烧技术[2]、选择性催化还原(Selective Catalytic Reduction, SCR)和非催化还原(Selective Non-Catalytic Reduction, SNCR)技术[3-4].

随着机器学习的不断发展，许多研究者开始利用神经网络(Artificial Neural Network, ANN)[5]对 NO_x 浓度进行建模和预测. 其中，文献[6]引入了一个具有外部输入神经网络的非线性自回归模型，以建立一个动态模型来预测 NO_x 的排放. 文献[7]使用人工神经网络开发了一个预测 210MW 煤粉锅炉满负荷条件下 NO_x 排放的模型，并发现所提出的方法可用于生成可行的运行条件. 除了人工神经网络，支持向量机(Support Vector Machine, SVM)[8-9]和极限学习机(Extreme Learning Machine, ELM)[10-11]也被引入用以模拟燃煤电厂 NO_x 的排放. 这些预测模型和方法都是在原有模型上进行的改进，虽然预测精度有所提高，但是同时也带来了更大的时间开销.

由于浅层网络模型的泛化能力不强，不能很好地适用于多种对象，因此，通过加深网络深度可优化浅层网络模型. 文献[12-13]建立了最小二乘支持向量机 LS-SVM 预测模型，实现排放量等多种参数的软测量，随后将建立的模型与 BP(Back Propagation, BP)神经网络模型进行对比，结果表明基于最小二乘支持向量机的网络模型的预测结果和运行速度均优于 BP 神经网络模型. 文献[14]采用风驱动算法和基于混沌分组教与学算法优化极端学习机的 NO_x 模型，通过参数调整及模型优化方法对 NO_x 的预测提供了指导. 文献[15]采用混沌分组教与学优化算法对 NO_x 的预测建模，该模型具有较好的辨识与泛化能力，可以为解决工程实际问题提供思路. 文献[16]在超临界机组的基础上，提出了一种改进的差分量子粒子群(Differential Evolution Quantum Particle Swarm Optimization, DEQPSO)算法，将其与极限学习机 ELM 相结合从而达到对 NO_x 的排放预测. 文献[17]提出了一种改进的最优觅食算法，并用该算法对锅炉 NO_x 的排放特性进行建模. 然而，上述运用传统的方式搭建的神经网络注重于数据的内部时序特征，却忽略了数据内部的空间特征联系，导致其模型对 NO_x 的浓度预测精度低.

为了提高模型预测精度，本研究提出了一种基于自动编码器(AE)和长短期记忆神经网络(LSTM)的预测模型. 首先，对原始数据进行标准化处理，剔除掉数据的异常值和缺失值；然后，使用 AE 自动编码器来提取数据深层次的多维信息特征；最后，将标准化后得到的数据输入 LSTM 网络中进行建模，并优化网

络参数，建立基于 AE-LSTM 的 NO_x 浓度预测模型. 最终，以重庆市某垃圾焚烧厂某锅炉的燃烧数据作为研究对象来验证该预测模型的准确性.

1　LSTM 网络模型

长短期记忆(Long Short Term Memory，LSTM)网络是一种具有记忆机制的神经网络，可以处理不同时间步的序列长度，以及能够学习到时间序列的关系等特点，因此可以非常有效地进行时间序列的建模.

LSTM 与循环神经网络(Recurrent Neural Network，RNN)最主要的不同就是 LSTM 有多个门控机制，如图 1 所示的 LSTM 细胞图结构，其中，红色圆圈代表 Sigmoid 函数，蓝色圆圈代表 Tanh 函数，输入门可以控制数据信息通过该门进入到 LSTM 细胞中；遗忘门可以决定 LSTM 细胞对数据的遗忘程度，即保留或者丢弃数据信息；输出门则控制 LSTM 细胞的输出.

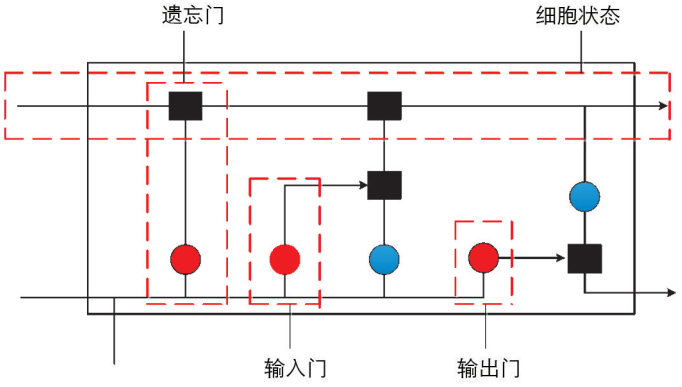

图 1　LSTM 细胞结构

数据在经过输入 x_t，隐藏层 h_t 的输出以及上一单元的输出 h_{t-1} 后，由此得到输入状态为 $\widetilde{C}_t$，输出状态为 C_t 和先前的状态为 C_{t-1}. 此外，门状态取 i_t，f_t 和 o_t. C_t 和 h_t 通过网络传播.

为了获得这 2 个值，第一，需要计算 3 个门的状态和单元输入的状态：

1) 输入门 Input gate

$$i_t=\sigma(\boldsymbol{W}_1^i\cdot x_t+\boldsymbol{W}_h^i\cdot h_{t-1}+b_i) \tag{1}$$

$$\widetilde{C}_t=\tanh(\boldsymbol{W}_1^c\cdot x_t+\boldsymbol{W}_h^c\cdot h_{t-1}+b_c) \tag{2}$$

其中，$\widetilde{C}_t$ 为输入状态，h_{t-1} 为上一单元的输出，x_t 为当前时刻的输入，b_i 为输入门的偏置，b_c 为细胞入口的偏置.

2) 遗忘门 Forget gate

遗忘门决定应丢弃或保留“哪些信息”.

$$f_t=\sigma(\boldsymbol{W}_1^f\cdot x_t+\boldsymbol{W}_h^f\cdot h_{t-1}+b_f) \tag{3}$$

其中，f_t 为 0 ～ 1 之间的数，h_{t-1} 为上一单元的输出，x_t 为当前时刻的输入.

3) 输出门 Output gate

$$o_t=\sigma(\boldsymbol{W}_1^o\cdot x_t+\boldsymbol{W}_h^o\cdot h_{t-1}+b_o) \tag{4}$$

$\boldsymbol{W}_1^0$ 为连接 x_t 到输出门的权重数组，$\boldsymbol{W}_h^0$ 为将 h_{t-1} 连接到输出门的权重矩阵.

第二，计算单元的输出状态：

$$C_t=i_t\cdot\widetilde{C}_t+f_t\cdot C_{t-1} \tag{5}$$

其中，C_t，i_t，$\widetilde{C}_t$，f_t，C_{t-1} 具有相同的矩阵大小.

第三，计算隐藏层的输出：

$$h_t=o_t\cdot\tanh(C_t) \tag{6}$$

单元的输出定义为

$$\tilde{x}_{t+1}=W_2\cdot h_t+b \tag{7}$$

其中，W_2 是2个元素之间的权重，b 为输入层和输出层的偏置.

LSTM网络模型如图2所示，包含输入层、2个隐含LSTM层、2个Dropout层和一个Dense全连接层，共6个部分组成. 该模型是用于 NO_x 数据处理的，数据首先经过输入层后进入第一层隐含LSTM层，LSTM单元计算处理后得到输出状态和隐藏状态. 为了避免过拟合，经过一个Dropout层进行正则化处理后，数据再次输入到第二层隐含LSTM层，得到新的输出状态和隐藏状态. 在这之后，数据再经过一个Dropout层进行正则化处理，以进一步减少过拟合. 最后，正则化后的数据输入到Dense全连接层，计算预测值，并输出 NO_x 浓度的预测结果.

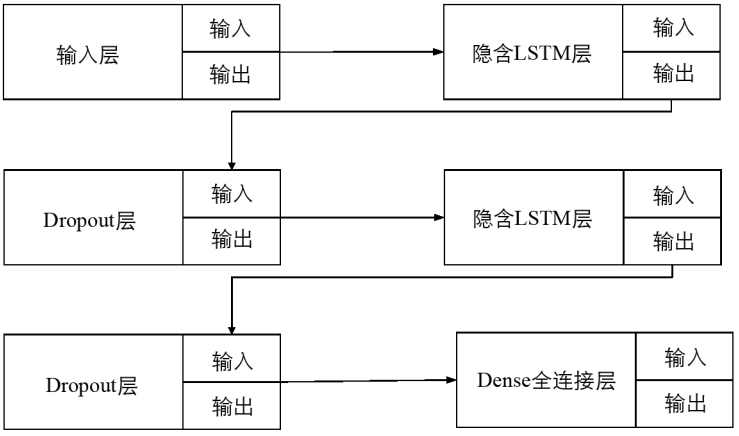

图2 LSTM网络模型结构

2 AE-LSTM混合神经网络模型

2.1 AE-LSTM网络结构

自动编码器(Autoencoder，AE)是一种网络模型，对于神经网络的发展起到了促进作用，尤其在对高维复杂数据的特征提取方面具有重要作用. 自动编码器的网络结构图如图3所示. 它是一种单隐含层的无监督学习模型，自动编码器通过对内在特征的不断持续学习，对输入层和输出层进行误差计算，使得两者之间的误差尽可能小，从而得到高维数据的特征输出. 这个过程起到了数据降维的作用，其作用类似于主成分分析法、因子分析法等. 与传统的数据降维方法相比，自动编码器能够更有效地提取新特征.

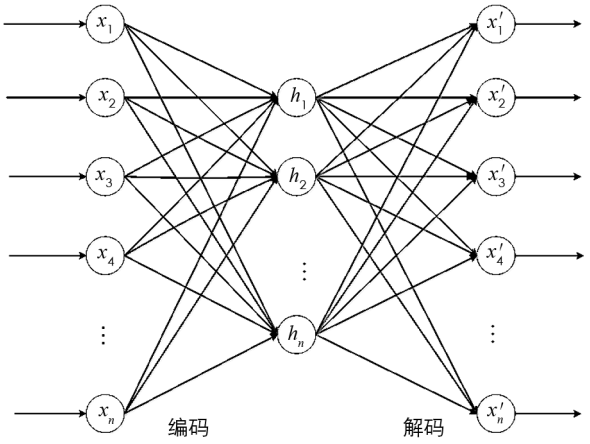

图3 自动编码器结构图

如上图所示，自动编码器的输入为 $x_1,x_2,x_3,\cdots,x_n$，通过编码过程得到隐含层的输出为 $h_1,h_2,h_3,\cdots,$

h_n，再将隐含层的输出经过解码过程到输出层得到 $x'_1, x'_2, x'_3, \cdots, x'_n$，计算输入层数据与输出层数据的误差 $(x_n - x'_n)^2$，人工创建编码器的输出特征，在特定范围内可以代表原始数据集. 编码过程如下所示：

$$h = S(\boldsymbol{W} \cdot x + b) \tag{8}$$

其中，h 为自动编码器的编码函数输出，也称之为隐含层的特征变量，S 为自动编码器编码过程的激活函数，一般使用 Sigmoid 函数，$\boldsymbol{W}$ 为输入层到隐含层的网络连接权重，b 为网络偏置. 通过解码过程得到输出层数据，再通过解码与编码的过程重构原始数据，保留原始数据中的重要特征. 解码过程为

$$x' = S(\boldsymbol{W}^{\mathrm{T}} \cdot h + b') \tag{9}$$

其中，x' 为解码器的重构信息，S 为自动编码器解码过程的激活函数，该激活函数使用 Sigmoid 函数，$\boldsymbol{W}^{\mathrm{T}}$ 为隐含层到输出层的网络连接权重，b' 为网络偏置.

经过自动编码器的编码和解码过程后，输入数据 x 映射为隐含层的特征 h，再将特征 h 重构后输出为 x'. 为了确保最后的输出特征能够有效地代表原始数据，保留有原始数据的大部分信息，所以需要计算输入数据和输出数据的误差，对于自动编码器的误差损失函数通常为均方误差，公式如下：

$$J(\boldsymbol{W}, b, b') = \frac{1}{2} \sum_{i=1}^{n} (x_i - x'_i) \tag{10}$$

自动编码器能够自动将高维数据特征提取至低维数据特征，同时还能保留原始数据的大量信息，保证数据的有效性不受破坏. 这些低维数据特征可以被输入到 LSTM 神经网络中，LSTM 网络通过不断学习权重参数来获得收敛，降低网络的预测复杂性，从而提高了预测的性能. AE-LSTM 神经网络的结构如图 4 所示，该网络结构由两部分组成，第一部分是自动编码器，利用自动编码器将输入数据的高阶特征转换为低阶特征，并保留原始数据的信息. 第二部分是 LSTM 神经网络，该部分将自动编码器输出的低阶有效数据输入到网络中，并对 NO_x 进行预测，从而得到预测值.

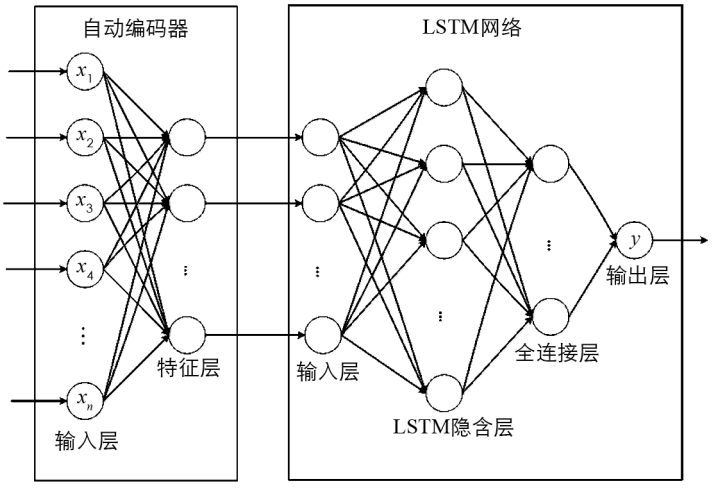

图 4　AE-LSTM 模型结构图

2.2　AE-LSTM 模型预测设计框架

AE-LSTM 模型的预测过程如图 5 所示. 首先，预处理好的数据集被划分为训练集和测试集. 训练集用于训练模型的内部参数，得到收敛的预测模型，而测试集用于监测模型的预测性能. 具体而言，原始数据首先输入自动编码器中，通过自动编码器的编码和解码过程得到低维度数据特征，然后将此数据输入 LSTM 网络中，经过 LSTM 网络的学习和调整，得到收敛的 AE-LSTM 网络. 最后，将训练好的模型用于测试集上，得到预测值和真实值，并使用准确率和误差等指标来评估模型的性能.

1）将处理好的数据矩阵划分成训练集与测试集；

2）将数据输入 AE 中得到低维数据特征；

3) 确定 AE-LSTM 网络的结构；

4) 计算网络神经元的 LOSS；

5) 利用优化算法调整各层的连接权重；

6) 达到迭代次数，网络训练结束，获得收敛的 AE-LSTM 网络；

7) 将测试集输入收敛的网络中，输出预测值，并计算准确率和误差，模型结束.

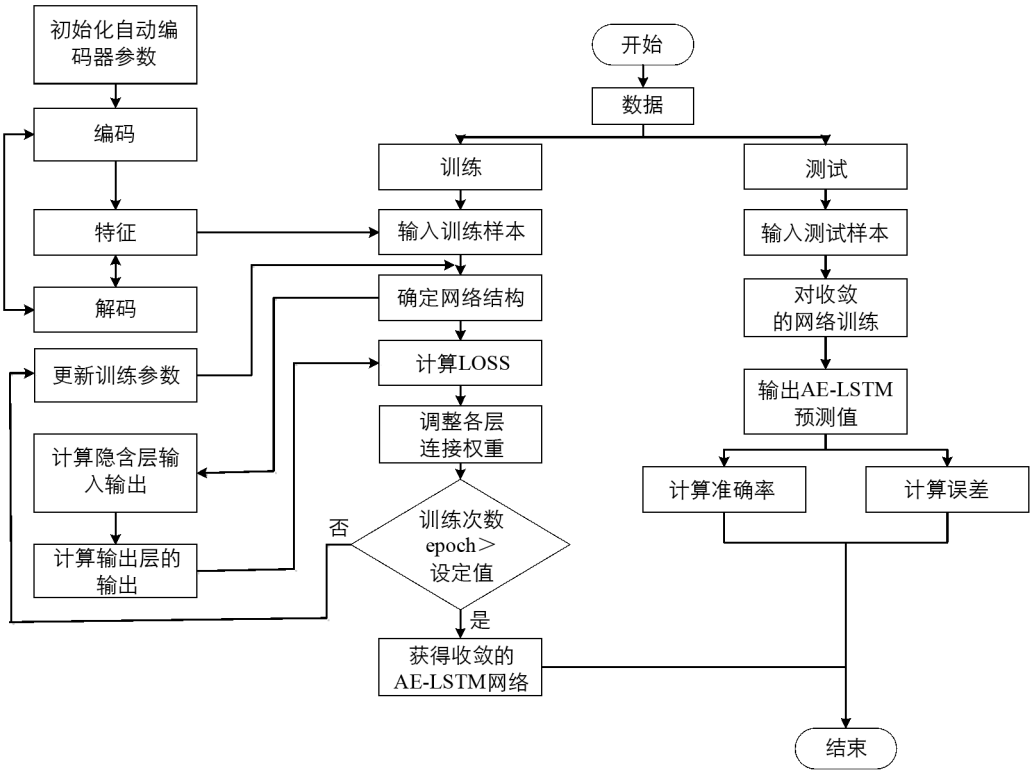

图 5 AE-LSTM 模型预测流程

3 基于 AE-LSTM 的 NO_x 排放预测

3.1 研究对象

工业预测的有效性很大程度上取决于数据的质量，因此数据预处理工作非常重要. 本文使用的变量相关数据集来自于重庆市某垃圾焚烧厂的锅炉垃圾焚烧系统，如下表 1 所示. 通过数据挖掘技术对原始数据中的异常值、缺失值进行处理，再消除数据共线性，最后对数据进行标准化处理，这些操作可以获得有效和可用的数据，有利于提高预测模型的性能.

表 1 某垃圾焚烧厂燃烧过程的各工况变量

变量序号	过程变量符号	过程变量含义
1	PY104A	1#锅炉一炉膛进口左侧烟气压力
2	PY105A	1#锅炉一炉膛进口右侧烟气压力
3	PY106A	1#锅炉一炉膛中部左侧烟气压力
⋮	⋮	⋮
88	TE260A	1#焚烧炉二次风空预器出口右侧风温
89	FY103A	1#锅炉送汽机主蒸汽流量压差

3.2　数据异常值和缺失值的处理

根据数据缺失的机理，可以将缺失值分为以下 3 类：完全缺失、随机缺失和不完全缺失. 通过对每个变量定义合理的取值范围，检查数据是否符合实际工况要求，并消除原始数据中的噪声，可以提高原始数据的质量. 在数据预处理中，本文使用了样本均值来填充缺失镇，以提升数据的完整性. 如表 2 为通过数学统计的方法来对数据进行的分析，分别计算每个变量的平均值、中位数、最大值、最小值、1stQu(25%值)和 3stQu(75%值). 另外，本文的数据集会用平均值对缺失值进行填充.

表 2　数据的分析

	平均值	中位数	最小值	最大值	1stQu	3stQu
PY104A	−54.089 6	−55.230 0	−208.38	69.84	−70.640 0	−36.775 0
PY105A	−56.008 1	−56.200 0	−215.18	69.71	−71.850 0	−37.245 0
PY106A	−17.272 1	−18.080 0	−161.76	100.13	−33.780 0	−8.652 5
PY107A	−26.769 5	−28.240 0	−188.65	96.88	−43.920 0	−9.105 0
PY108A	−30.063 4	−29.965 0	−121.71	80.37	−40.300 0	−20.262 5
⋮	⋮	⋮	⋮	⋮	⋮	⋮
TE258A	32.759 0	33.410 0	26.32	36.58	31.610 0	34.140 0
TE259A	128.897 1	142.900 0	36.78	180.67	134.000 0	151.610 0
TE260A	124.458 9	138.100 0	34.59	176.19	129.105 0	146.795 0
FY103A	37 262.784 4	37 075.605 0	17 565.04	69 106.20	32 790.685 0	41 530.765 0

3.3　数据共线性的消除与标准化

垃圾焚烧锅炉中相关的工艺变量共 89 维，变量间存在普遍的相关关系即共线性会影响模型的运行，降低预测精度. 为了提高 NO_x 预测的精度，计算各变量的相关系数，以消除共线性. 通过反复测试，发现当删除相关性系数大于 0.9 的数据后，能够在线性范围内消除数据之间的共线性，使得模型精度最佳. 因此最终得到了 56 维的工艺变量.

标准化是一项重要技术，通常在许多机器学习模型之前作为预处理步骤执行. 本文的研究对象为垃圾焚烧 NO_x 预测，采用 Z-score 标准化的方式对数据的量纲进行统一的去量纲处理，该处理方法对于模型的学习速度和训练速度都有所提升. 利用 Python 软件对现场采集的数据进行 Z-score 标准化处理，标准化后数据集中共有 56×3612 维数据.

4　实验及结果分析

AE-LSTM 的初始参数设置如表 3 所示，对于自动编码器，主要由编码层和解码层两部分组成，其中解码层会将输入的数据进行压缩并提取特征，再对特征重新构造. 由于自动编码器具有成镜像的对称结构，所以通过实验可得到最优的自动编码器结构，前面对原始数据预处理中得到 56 维变量，进而可以确定输入层节点为 56 个. 为了减少权重的相互依赖，使用 Sigmoid 函数作为激活函数，损失函数使用均方误差，优化函数为 Adam 函数.

表 3　AE-LSTM 模型最优参数

参数	值
编码层结构	53-40-20-13
解码层结构	13-20-50-53
输入神经元个数	56
输出层神经元个数	13
LSTM 隐含层个数	3
隐含层节点数	15
滑动窗口	20
正规化	0.5

通过十折交叉检验，得到基于AE-LSTM的NO_x平均预测准确率如表4、图6和图7所示，其中图7为截取的图6部分片断以便观察. 表4展示了不同模型的平均预测准确率和RMSE指标，其中，AE-LSTM网络的预测准确率为85.1%，高于CNN-LSTM网络的预测准确率83.8%和LSTM网络的预测准确率79.7%. AE-LSTM网络的RMSE为0.705，低于CNN-LSTM网络的RMSE 0.725和LSTM网络的RMSE 0.833. 可见AE-LSTM在NO_x预测方面表现最优.

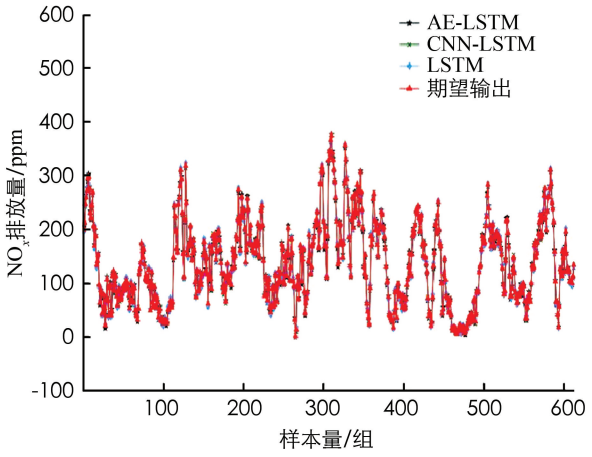

图6 基于AE-LSTM模型的NO_x预测结果

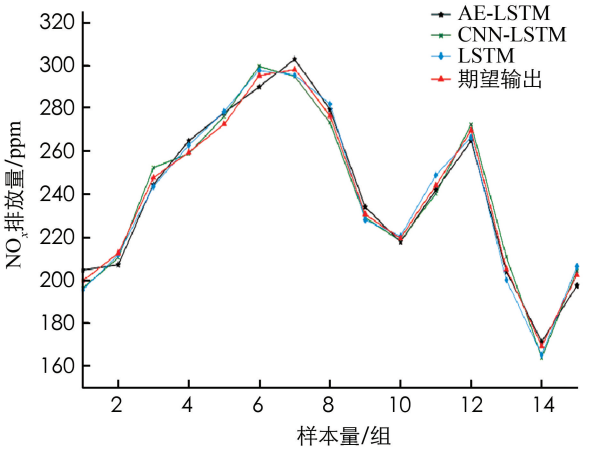

图7 截取的部分NO_x预测效果

表4 AE-LSTM与LSTM、CNN-LSTM模型对比

模型	准确率/%	RMSE
LSTM	79.7	0.833
CNN-LSTM	83.8	0.725
AE-LSTM	85.1	0.705

5 结语

通过建立有效的NO_x浓度预测模型，可以帮助垃圾焚烧厂提前做出规划，减少NO_x排放. 本文提出了一种基于自动编码器和长短期记忆神经网络的预测模型，针对垃圾焚烧NO_x数据的空间特征，实现对长短期记忆神经网络的改进. 长短期记忆神经网络主要关注数据的内部时序特征，而忽略了数据内部的空间特征联系，引入自动编码器可提升模型对数据内部的空间特征联系和数据多维度特征的提取能力. 本文以重庆市某垃圾焚烧厂锅炉的燃烧数据为研究对象，首先利用LSTM网络进行建模，并进行了网络参数优化，再使用自动编码器对数据深层次多维信息特征进行提取，建立改进的AE-LSTM的NO_x浓度预测模型. 研究表明，相比LSTM模型，AE-LSTM模型在时序特征、空间特征强的数据集方面，表现出较好的预测精度和泛化能力. 本文开展NO_x浓度预测研究，有望为下一步如何调控工艺变量操作指标，优化工艺参数，达到NO_x浓度减排目标奠定重要的理论依据.

参考文献：

[1] MUNAWER M E. Human Health and Environmental Impacts of Coal Combustion Andpost-Combustion Wastes [J]. Journal of Sustainable Mining, 2018, 17(2): 87-96.

[2] MCDONALD J, KIRK T, SURBEY D J, et al. Low NoX Burner Apparatus: US6394792 [P]. 2002-05-28.

[3] MISHRA Y, JUREMALANI J, NIHALANI S A. Emission Control Technologies for Thermal Power Plants [C]//International Conference on Recent Advances in Materials, Mechanical and Civil Engineering, Hyderabad, Indonesia:

ICRAMMCE 2017，2018：1054 - 1059.

[4] SHEN Z. Simulation of Nox Reduction in Power Plant Flue Gas [D]. Bethlehem ，United States：Lehigh University，2017.

[5] 苏盈盈，李太福，康东帅，等. 多层线性神经网络与单层线性神经网络的等效性研究 [J]. 西南师范大学学报(自然科学版)，2017，42(12)：105-112.

[6] OKO E，WANG M H，ZHANG J. Neural Network Approach for Predicting Drum Pressure and Level in Coal-Fired Subcritical Power Plant [J]. Fuel，2015，151：139-145.

[7] ILAMATHI P，SELLADURAI V，BALAMURUGAN K，et al. ANN-GA Approach for Predictive Modeling and Optimization of NO_x Emission in a Tangentially Fired Boiler [J]. Clean Technologies and Environmental Policy，2013，15(1)：125-131.

[8] TAN P，ZHANG C，XIA J，et al. NO_x Emission Model for Coal-Fired Boilers Using Principle Component Analysis and Support Vector Regression [J]. Journal of Chemical Engineering of Japan，2016，49(2)：211-216.

[9] LV Y，LIU J Z，YANG T T，et al. A Novel Least Squares Support Vector Machine Ensemble Model for NO_x Emission Prediction of a Coal-Fired Boiler [J]. Energy，2013，55：319-329.

[10] TAN P，XIA J，ZHANG C，et al. Modeling and Reduction of NO_x Emissions for a 700MW Coal-Fired Boiler with the Advanced Machine Learning Method [J]. Energy，2016，94：672-679.

[11] LI G Q，NIU P F. Combustion Optimization of a Coal-Fired Boiler with Double Linear Fast Learning Network [J]. Soft Computing，2016，20(1)：149-156.

[12] 顾燕萍，赵文杰，吴占松. 基于最小二乘支持向量机的电站锅炉燃烧优化 [J]. 中国电机工程学报，2010，30(17)：91-97.

[13] 李勤道，韩璞，高芳，等. 超超临界机组锅炉效率与 NO_x 排放的建模研究 [J]. 计算机仿真，2013，30(5)：129-132，147.

[14] 牛培峰，赵振，马云鹏，等. 基于风驱动算法的锅炉 NO_x 排放模型优化 [J]. 动力工程学报，2016，36(9)：732-738.

[15] 马云鹏，牛培峰，陈科，等. 基于混沌分组教与学优化算法锅炉 NO_x 模型优化研究 [J]. 计量学报，2018，39(1)：125-129.

[16] 董泽，马宁，孟磊. 基于差分量子粒子群算法的锅炉 NO_x 排放模型优化 [J]. 动力工程学报，2019，39(3)：191-197.

[17] 牛培峰，彭鹏. 基于改进最优觅食算法的锅炉 NO_x 排放预测研究 [J]. 计量学报，2020，41(7)：879-885.

责任编辑　崔玉洁