

基于 KPCA-AGRU 神经网络的火电机组 NO_x 排放预测

冯旭刚,文作银,章家岩,张泽辰

安徽工业大学 电气与信息工程学院,安徽 马鞍山 243002

摘要:针对火电机组锅炉燃烧过程中预测 NO_x 排放过程存在的非线性和时序性特点,提出一种基于核主成分分析(KPCA)和注意力机制(AM)的门控循环神经网络(GRU)氮氧化物预测模型。首先选用 KPCA 对模型的输入变量进行降维,消除冗余变量;其次,将筛选的变量数据作为 GRU 的输入,并采用网格搜索优化 GRU 的超参数;最后,引入 AM 计算权值,实现区分输入特征功能,提高 NO_x 预测模型精度。通过某 330 MW 电站锅炉实际数据对 AGRU 预测模型仿真验证,并将 AGRU 模型、GRU 模型和 BP 神经网络模型的预测结果进行对比。结果表明:基于 AGRU 的 NO_x 预测模型的均方根误差和平均绝对误差较 BP 神经网络和 GRU 模型均有减少,可精准预测非线性时序燃烧过程的 NO_x 排放。

关键词:核主成分分析;NO_x 排放预测;门控循环神经网络;注意力机制

中图分类号:TM621 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2023.0006.003

Prediction of NO_x Emissions from Thermal Power Units Based on KPCA-AGRU Neural Network

FENG Xugang, WEN Zuoyin, ZHANG Jiayan, ZHANG Zechen

School of Electrical and Information Engineering, Anhui University of Technology, Anhui Maanshan 243002, China

Abstract: Aiming at the nonlinear and sequential characteristics of NO_x emission prediction in the boiler combustion process of thermal power units, a NO_x prediction model of gated recurrent unit (GRU) neural network based on kernel principal component analysis (KPCA) and attention mechanism (AM) was proposed. Firstly, KPCA was selected to reduce the dimension of the input variables of the model and eliminate redundant variables. Secondly, the filtered variable data was used as the input of GRU, and the grid search was used to optimize the superparameters of GRU. Finally, AM calculation weight was introduced to realize the function of distinguishing input characteristics and improve the accuracy of the NO_x prediction model. The AGRU prediction model was simulated and verified by the actual data of a 330 MW power plant boiler, and the prediction results of the AGRU model, the GRU model, and the BP neural network model were compared. The results show that the root mean square error and average absolute error of the NO_x prediction model based on AGRU are less than those of the BP neural network and GRU model, which can accurately predict the NO_x emission in the nonlinear sequential combustion process.

Keywords: kernel principal component analysis; NO_x emission prediction; GRU neural network; attention mechanism

收稿日期:2022-05-28 修回日期:2022-09-05 文章编号:1672-058X(2023)06-0018-07

基金项目:安徽省自然科学基金(1908085ME134);安徽省高校自然科学研究重点项目(KJ2018A0060)。

作者简介:冯旭刚(1977—),男,教授,从事工业炉窑智能优化控制研究。

通讯作者:文作银(1997—),男,安徽六安人,硕士研究生,从事火力发电设备智能建模研究。Email:wenzuoy2022@163.com。

引用格式:冯旭刚,文作银,章家岩,等.基于 KPCA-AGRU 神经网络的火电机组 NO_x 排放预测[J].重庆工商大学学报(自然科学版),2023,40(6):18—24.

FENG Xugang, WEN Zuoyin, ZHANG Jiayan, et al. Prediction of NO_x emissions from thermal power units based on KPCA-AGRU neural Network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(6): 18—24.

1 引言

NO_x作为火电机组燃烧过程所排出气体的主要污染物之一,极大地影响着生态环境及人类健康^[1]。为了防止发电过程中NO_x过度排放使得生态环境进一步恶化,我国对其制定了严格的排放标准^[2],这使得火电厂在正常生产的同时需控制NO_x的排放量。现阶段火电机组降低烟气中NO_x浓度以达到烟气排放标准的有效控制技术手段之一为选择性催化还原法(SCR),以低成本、高效率等优点被很多电站采用^[3]。这种烟气处理手段的高效性主要依赖对SCR设备入口烟气中NO_x的精准实时测量,以改变脱硝过程中的喷氨量。但是电厂现场工况复杂多变,干扰较大,SCR设备入口的NO_x浓度频繁多变,这极大影响着SCR的脱硝功效及锅炉燃烧设备。SCR设备入口处NO_x预测技术的精准与否对火电机组能否节能减排有着重要的作用^[4]。

火电机组NO_x排放预测方法是智能发电技术领域的研究难点,有部分学者基于NO_x的生成机理和过程进行机理建模。高明明等^[5]通过对NO_x生成机理分析,以循环流化床锅炉燃烧产生的燃料型NO_x为主体,结合应用数学和仿真方案,在以给煤量、风量等作为输入的炉膛出口一氧化碳浓度预测模型的基础上结合即燃碳模型建立了炉膛出口NO_x浓度预测模型,仿真表明模型具有较好的精确度;Zhang等^[6]通过对增压锅炉的工艺分析对锅炉进行了合理简化,通过炉膛结构、工艺参数搭建炉膛几何模型并利用应用数学知识建立稳态三维湍流模型,完成了锅炉在3种不同负荷下NO_x排放的数值模拟。事实上,锅炉燃烧过程中排放的NO_x浓度受多种因素影响,且锅炉变量之间存在着强耦合,很难通过机理建模建立满足现代工业生产所需求的准确性及可靠性。

相较于机理建模,现技术成熟的数据建模因不需太关注系统内部结构及良好的非线性拟合能力等优点被大量地使用。郭建民等^[7]利用火焰诊断系统对炉膛温度场进行多次测量以研究温度与NO_x生成机理的关联,应用支持向量机(SVM)模型通过两者间的关联建立了锅炉NO_x排放特性模型;Ahmed等^[8]在之前研究最小二乘支持向量机(LSSVM)NO_x排放预测模型的基础上融入实时更新技术建立实时NO_x排放预测模型,实验结果表明新方案在较长时间的鲁棒性预测具有更高的准确度;Lyu等^[9]提出软模糊c均值聚类算法,

对原始数据进行分解并应用偏最小二乘(PLS)消除模型的冗余变量,建立最小二乘支持向量机(LSSVM)NO_x排放预测模型。人工神经网络(ANN)是另一种对非线性函数有良好拟合能力的人工智能技术。Wang等^[10]采用主成分分析(PCA)处理原始数据,消除冗余变量建立以遗传算法优化网络参数的BP神经网络,实验表明PCA降低了NO_x预测模型的复杂度,提高了精准度。以上研究虽有良好的NO_x预测效果,但锅炉NO_x的产生是由锅炉之前的状态和锅炉各变量此时的输入混合作用而成,上述建模方法难以反映变量数据之间存在着时序联系。

综上所述,考虑NO_x排放所具备的非线性和时序性等特点,本文提出一种基于核主成分分析(KPCA)和注意力机制(AM)的门控循环(GRU)神经网络NO_x排放预测模型。采用核主成分分析法对采集到的变量数据进行冗余变量去除处理;引入注意力机制,突出与输出变量有强相关因素的影响,降低弱相关因素的影响,实现深层次关键信息的挖掘,提高预测效果,且针对GRU神经网络超参数手动调参的困难,采用网格搜索对其寻优,加快网络的学习效率,提高模型的准确性。

2 门控循环神经网络

循环神经网络(RNN)对时间序列具备强大的特征表征和映射能力,能够有效处理变量数据之间存在的时序联系,其建立的模型也更为精确。然而RNN存在着梯度消失和梯度爆炸的问题,这使得模型无法正常训练^[11]。长短期记忆(LSTM)神经网络引入门单元,改进了RNN模型的结构,通过时序记忆可控的能力弥补了RNN模型的缺陷,并在火电机组NO_x的排放预测中具备了良好的预测效果^[12]。而GRU神经网络是对LSTM神经网络结构进一步改进所得到的产物。

GRU内部结构如图1所示: r_t 与 z_t 分别是GRU的更新门和重置门,其阈值区间为 $[0,1]$ 。由图1可知:此时的门控状态信息是由上一时刻的状态与当前时刻输入决定的。相比于采用3个门单元(输入门、遗忘门和输出门)控制输入输出的LSTM神经网络,GRU只存在两个单元门(更新门和重置门),这在继承LSTM神经网络有效处理时序序列能力的同时简化了模型结构,缩减了网络的训练参数,提高了网络计算效率。这使得GRU神经网络具有更好的时序序列处理能力。而火电机组的NO_x排放预测需要注意NO_x浓度数据的时间相关性。使用GRU神经网络可以充分地利用样

本数据中的时序特征,以达到更好的预测效果。

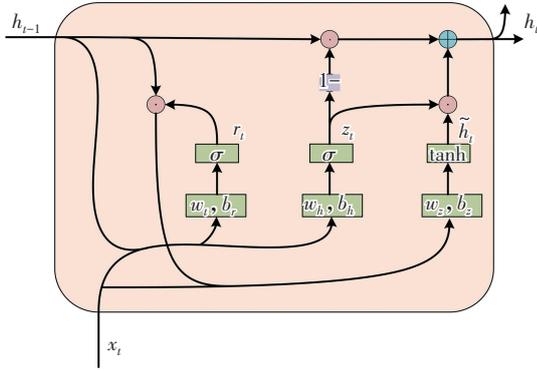


图 1 GRU 内部结构图

Fig. 1 Internal structure of GRU

GRU 单个隐含层传播过程如下:

(1) 更新门 z_t 逻辑为门控制状态,它的作用是处理上一时刻隐含层输出 h_{t-1} 和当前时刻输入样本 x_t 。

$$z_t = \sigma(x_t W_{xz} + h_{t-1} W_{hz} + b_z) \quad (1)$$

(2) 同理,重置门 r_t 逻辑为门控制状态,作用也是处理上一时刻隐含层输出 h_{t-1} 和当前时刻输入样本 x_t 。

$$r_t = \sigma(x_t W_{xr} + h_{t-1} W_{hr} + b_r) \quad (2)$$

(3) 当前时刻节点即时信息 \tilde{h}_t 由重置门对上一时刻隐含层输出进行重置,再与当前时刻样本输入 x_t 乘以相应偏置求和后,经 \tanh 函数激活得到更新。

$$\tilde{h}_t = \tanh(x_t W_{xh} + (r_t \odot h_{t-1}) W_{hh} + b_h) \quad (3)$$

(4) 当前隐含层输出 h_t 由更新门对上个时刻隐含层输出和当前时刻节点即时信息的选择和遗忘得到。

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \quad (4)$$

式(1)一式(4)中: x_t 是当前时刻样本输入, h_{t-1} 是上一时刻隐含层输出, r_t 与 z_t 是重置门与更新门, h_t 是当前时刻的输出, \tilde{h}_t 是当前时刻节点即时信息, σ 与 \tanh 分别是 Sigmoid 型和双曲正切型激励函数, W_{xz} 、 W_{xr} 、 W_{hz} 、 W_{hr} 、 W_{xh} 与 W_{hh} 是权重参数, b_z 、 b_r 与 b_h 是偏置参数。

3 氮氧化物预测模型构建

3.1 核主成分分析

输入变量的筛选在数据建模中极大地影响着模型的质量。火电机组燃烧过程中产生的 NO_x 与锅炉的众多参数有关,如果将其相关变量都作为模型的输入变量会使模型引入冗余信息,降低模型的质量和预测精度。

KPCA 利用核函数映射低维空间数据,当这些数据

转换至高维空间后再利用 PCA 对数据进行简约处理。与传统的 PCA 相比,经过 KPCA 处理的数据保留了原始数据的非线性特征,弥补了 PCA 算法处理非线性数据方面的劣势^[13]。

设原始数据集构成原始空间为 \mathbf{R}^n ,输入数据为 \mathbf{X} , \mathbf{X} 有 m 个样本,每个样本具有 n 维数据。故 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]$, $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]$, $i = 1, 2, \dots, m$ 。设 H 为高维特征空间,设定 Φ 为原始空间数据到高维空间的非线性映射,则任意 \mathbf{x}_i 通过映射至高维空间中为

$$\mathbf{x}_i \rightarrow \Phi(\mathbf{x}_i) \quad (5)$$

在映射完成后, H 空间中映射数据的协方差矩阵 \mathbf{C}_H 可表示为

$$\mathbf{C}_H = \frac{1}{m} \sum_{i=1}^m \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_i)^T \quad (6)$$

求解 \mathbf{C}_H 的特征值 λ 和特征向量 \mathbf{V}_H ,即

$$\lambda \mathbf{V}_H = \mathbf{C}_H \mathbf{V}_H \quad (7)$$

其中,特征值 $\lambda \geq 0$,特征向量 $\mathbf{V}_H \in H \neq \{0\}$ 。则有

$$\lambda (\Phi(\mathbf{x}_k) \mathbf{V}_H) = \Phi(\mathbf{x}_k) \mathbf{C}_H \mathbf{V}_H \quad (8)$$

非零特征值 λ 对应的特征向量 \mathbf{V}_H 是由 $\{\Phi(\mathbf{x}_1), \Phi(\mathbf{x}_2), \dots, \Phi(\mathbf{x}_m)\}$ 张成的空间,则 \mathbf{V}_H 可由其线性表示为

$$\mathbf{V}_H = \sum_{j=1}^m \alpha_j \Phi(\mathbf{x}_j) \quad (9)$$

将式(6)、式(8)与式(9)联合整理后得到

$$\lambda \sum_{j=1}^m \alpha_j (\Phi(\mathbf{x}_k) \Phi(\mathbf{x}_j)) = \frac{1}{m} \sum_{j=1}^m \alpha_j (\Phi(\mathbf{x}_k) \sum_{i=1}^m \Phi(\mathbf{x}_i)) (\Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)) \quad (10)$$

引入核函数 $k(\mathbf{x}_i, \mathbf{x}_j) = \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$,本文采用高斯核函数分析,如式(11)所示;核矩阵为 $\mathbf{K} = [k(\mathbf{x}_i, \mathbf{x}_j)]_{m \times m}$ 。对式(10)进行化简整理可得式(12):

$$k(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right) \quad (11)$$

$$m\lambda\alpha = \mathbf{K}\alpha \quad (12)$$

由此可得 \mathbf{K} 矩阵的特征值与特征向量。

上式中的 \mathbf{K} 矩阵是经过中心化处理的。中心化的计算如式(13):

$$\mathbf{K} - \mathbf{I}_m \mathbf{K} - \mathbf{K} \mathbf{I}_m + \mathbf{I}_m \mathbf{K} \mathbf{I}_m \rightarrow \mathbf{K} \quad (13)$$

式(13)中: \mathbf{I}_m 是每个元素为 $\frac{1}{m}$ 的 $m \times m$ 矩阵。

\mathbf{K} 的特征值 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$,其中特征值 λ_i 的累

计贡献率 η_i 计算公式为

$$\eta_i = \frac{\lambda_i}{\sum_{k=1}^m \lambda_k} \quad (14)$$

依据各主成分贡献率和累计贡献率,设定累计贡献率阈值从而确定数据的主成分和模型的输入变量。

3.2 注意力机制

注意力学习机制是对人脑注意力的仿生,其核心思想是人脑会对重要信息分配更多的注意力,以获得更多的重要信息^[14]。AM 在模型中的体现是通过模型自主学习出一组权重系数并将其赋予输入数据,以此来突出对结果影响较大的输入,忽略无关信息。本文引入 AM,给予输入特征不同权重,突出与 NO_x 浓度相关性较大的输入特征,弱化相关性较小的输入特征来提高模型精度与计算效率。AM 结构如图 2 所示。

图 2 中, $x_1, x_2, \dots, x_{n-1}, x_n$ 为输入数据; $h_1, h_2, \dots, h_{n-1}, h_n$ 为某一时刻输入数据的状态值。AM 的运算步骤主要如下:采用注意力打分函数对将要输入至 AM 的输入特征进行打分计算;然后利用打分计算结果得到注意力分布,即为权重系数;将不同的权重系数分配给输入特征进行乘积求和得到最终结果。

其计算公式如下:

$$\text{Scor}(e_i) = v \tanh(w h_i + b) \quad (15)$$

$$a_i = \frac{\exp(\text{Scor}(e_i))}{\sum_{i=1}^n \exp(\text{Scor}(e_i))} \quad (16)$$

$$C = \sum_{i=1}^n a_i h_i \quad (17)$$

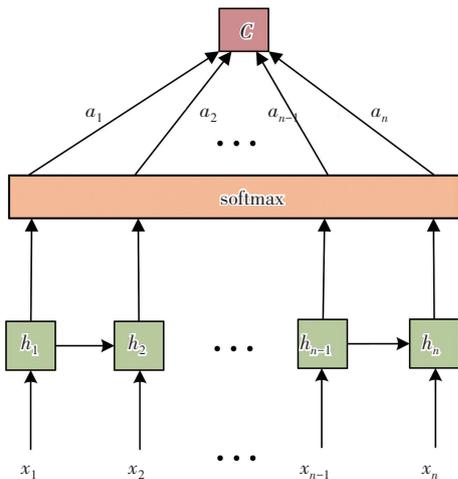


图 2 注意力机制结构图

Fig. 2 Structure of attention mechanism

式(15)一式(17)中: $\text{Scor}(e_i)$ 为注意力打分函数; a_i 为注意力权重; v, w, b 分别是计算注意力权重时的多层感

知机的权重与偏置参数; h_i 是隐藏层状态; C 是 AM 加权求和后的输出。

3.3 网络训练

批量梯度下降(BGD)、随机梯度下降(SGD)和小批量梯度下降(MBGD)是常见的网络训练方式,但这3种方法在训练中各有特点^[15]。在迭代过程中,BGD需要对所有样本的梯度和权重进行重新计算,这严重拖累了训练过程。SGD通过随机选定一个样本来更新权重参数,这样的随机性会导致样本存在大量噪声。MBGD通过将输入样本小批量化来计算梯度和相应权重参数,从而降低计算量。小批量梯度下降法是本研究采用的训练方式。网络以均方误差(F_{MSE})为损失函数,其计算公式如式(18):

$$F_{\text{MSE}} = \sum_{i=1}^N (y_i - \hat{y}_i)^2 / N \quad (18)$$

式(18)中: N 为样本总数, y_i 为真实值, \hat{y}_i 为预测值。

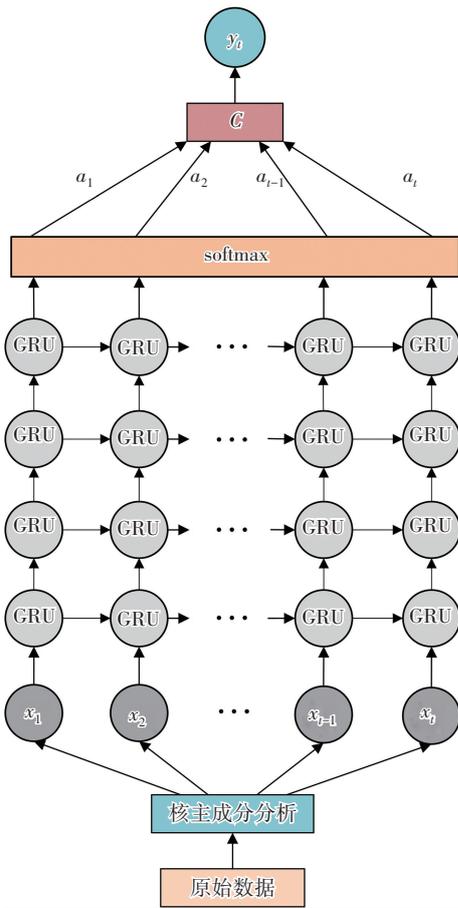
采用自适应动量估计(Adam)来优化训练中的学习率,Adam结合了动量法与 RMSprop 算法的优点,在迭代过程中不仅可以使动量作为参数更新方向,而且可以自适应调整学习率,提高参数优化精度。Adam的迭代过程如式(19):

$$\begin{cases} g_t = \nabla_{\theta} G_t(\theta_{t-1}) \\ u_t = \beta_1 u_{t-1} + (1 - \beta_1) g_t \\ \hat{u}_t = u_t / (1 - \beta_1^t) \\ w_t = \beta_2 w_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{w}_t = w_t / (1 - \beta_2^t) \\ \theta_t = \theta_{t-1} - \alpha \hat{u}_t / (\sqrt{\hat{w}_t} + \epsilon) \end{cases} \quad (19)$$

式(19)中: t 为迭代次数; $G_t(\theta_{t-1})$ 为损失函数; θ_t 为权重参数; g_t 为损失函数梯度; $u_t, w_t, \hat{u}_t, \hat{w}_t$ 分别为修正前后的一、二阶矩估计; β_1 与 β_2 的值为 0.999; α 为学习率; ϵ 为 10^{-8} 。

3.4 模型构建

将工业现场采集的原始数据经过数据预处理后先进行核主成分分析,消除冗余变量,然后将其划分数据集,利用训练集训练 GRU 神经网络,并采用网格搜索对 GRU 神经网络超参数进行寻优。同时,运用 Adam 算法对网络内部参数进行优化,最后引入注意力机制计算权值,实现区分输入特征处理,从而建立 NO_x 排放预测模型。图 3 是基于核主成分分析和注意力机制的门控循环神经网络 NO_x 预测模型。

图 3 KPCA-AGRU NO_x 预测模型Fig. 3 NO_x prediction model based on KPCA-AGRU

4 实验设计与结果分析

实验采用 Intel Core i5 12400 处理器、32G 内存, GPU 选用 NVIDIA RTX2060 12G 显卡, 操作系统为 Windows 系统, 开发语言是 Anaconda 集成环境中的 Python3.8 编写实验代码, 开发工具为 PyCharm Community Edition。

4.1 输入变量选择

建模数据来自某燃煤电厂 330 MW 机组 DCS 系统, 锅炉负荷在 300 MW 上下浮动, 采样周期为 300 s。燃煤机组工作过程中生产的氮氧化物主要由燃料型、热力型和快速型 3 种组成。快速型 NO_x 在锅炉正常运行时含量较小可忽略不计, 燃料型和热力型 NO_x 为锅炉燃烧产生 NO_x 的主要成分, 并且其产生与多种锅炉参数有关^[16]。依据氮氧化物生成机理与电厂现场运行工况, 初步选定 20 种参数作为模型的输入变量, 分别为锅炉负荷(1 组)、烟气含氧量(2 组)、空气预热器入口烟温(2 组)、给煤量(5 组)、一次风量(5 组)、一次风温(5 组)。

将采集到的变量参数进行数据预处理。首先采用拉

以达准则对各参量数据中的异常值进行剔除; 接着使用线性插值法按照时间标签对数据中的缺失值和去除的异常值空位进行补位; 最后将数据归一化至 $[0, 1]$ 。

选定的变量之间存在着较强的相关性, 直接作为模型输入会产生维数灾难。KPCA 在保留数据非线性特性的同时消除了冗余变量, 减少了输入维数, 降低了模型复杂度。对所有输入变量进行编号后经过核主成分分析的结果如图 4 所示。由图 4 可知: 前 9 种成分的累计贡献率已达到 95.15%, 这表示这 9 种成分已包含原始数据 95% 的信息, 故摒弃其他成分, 只选取这 9 种主成分作为模型的输入。

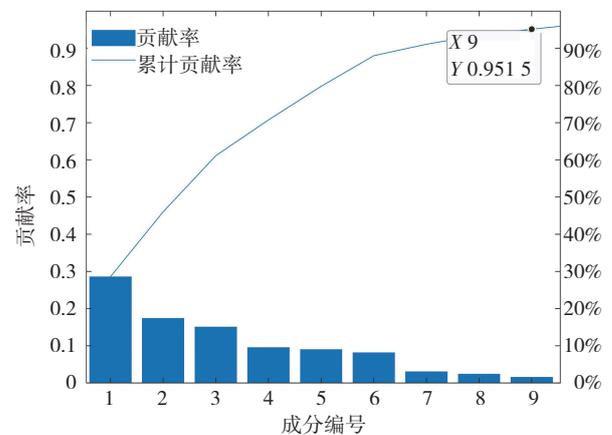


图 4 核主成分分析结果

Fig. 4 Results of kernel principal component analysis

4.2 参数设置

4.2.1 网络初始化

采集数据有 2 000 组, 训练集与测试集划分比例为 8 : 2, 建立 4 层 GRU 神经网络, 采用 MBGD 和训练网络, 通过 Adam 优化学习率。

根据实验和参数设定经验, 初步确定模型的初始参数: 批量大小为 64, 时间序列长度为 5, 学习率为 0.01, 四层隐含层神经元个数分别为 $[128, 128, 64, 32]$, 训练总次数为 500。

4.2.2 超参数调整

由于 GRU 神经网络模型是一个时间序列递归神经网络模型, 不同时间步长模型的预测精度和网络拟合精度有着差异。在网络参数进行初始化的基础上, 对其时间步长进行调整, 并以均方根误差 (F_{RMSE})、平均绝对误差 (F_{MAE}) 作为网络的预测精度和拟合效果的评价标准。计算公式如式 (20)、式 (21)。调整结果如表 1 所示, 式中 N 为样本总数, y_i 为真实值, \hat{y}_i 为预测值。

$$F_{RMSE} = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (20)$$

$$F_{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (21)$$

表1 GRU网络模型时间序列长度选择对比

Table 1 Comparison of time step selection of GRU network model

时间步长	$F_{RMSE}/(\text{mg} \cdot \text{m}^{-3})$	$F_{MAE}/(\text{mg} \cdot \text{m}^{-3})$
5	16.314	5.358
8	15.620	5.245
16	19.788	6.678
24	14.134	4.205
32	6.326	2.412
40	7.425	3.263
48	15.317	5.967

由表1所示:随着时间步长的增加,模型的精度在总体上得到提升,当时间步长为32时,所得的 F_{RMSE} 、 F_{MAE} 最小,网络的预测效果最好。但是当时间步长持续增加时,模型的预测精度在降低。这为下一步GRU的超参数调试做好了准备。

在时间步长得到最优后,为了进一步提高网络模型的预测精度和拟合效果,采用网格搜索对网络的隐含层单元数、批量大小、学习率进行寻优。隐含层单元数的寻优范围为[16, 32, 64, 128, 256],批量大小范围为[16, 32, 64, 128, 256],学习率寻优范围为[0.01, 0.001, 0.0001]。参数网格搜索的步骤:初步确定隐含层单元数、批量大小、学习率的选取范围;计算网络模型预测精度;比较不同参数网络的预测精度并选择使网络预测精度达到最大值的参数。经参数寻优后,当各隐含层单元数为[64, 128, 64, 256]、批量大小为16、学习率为0.01时,其均方根误差和平均绝对误差最小,模型的预测精度最好(F_{RMSE} 值为 $3.332 \text{ mg} \cdot \text{m}^{-3}$, F_{MAE} 值为 $3.022 \text{ mg} \cdot \text{m}^{-3}$)。

4.3 模型预测结果

采用网格搜索对GRU神经网络的超参数进行寻优后,引入注意力机制对经过GRU处理后的信息进行深度挖掘,提高模型的精准度。为了验证KPCA-AGRU网络模型在火电机组SCR系统入口NO_x浓度的预测效果,本节在同样输入变量基础上,将AGRU预测模型、GRU预测模型和传统BP神经网络预测模型的测试集

预测结果进行对比。这3种NO_x预测模型针对测试集的结果见图5。可以看到:融入了AM的GRU模型相比于另外两种模型有着更好的跟随趋势变化能力,尤其在NO_x变化幅度较大时,有着更好的预测效果。3种预测模型的评价指标对比见表2。由表2可知:AGRU相比于BP预测模型,其 F_{RMSE} 值降低了62.79%, F_{MAE} 值降低了63.20%;相比于GRU预测模型,其 F_{RMSE} 值降低了37.36%, F_{MAE} 值降低了34.14%。对比结果表明:GRU神经网络对时序序列具有较好的处理能力,并且引入注意力机制可以有效减小GRU神经网络预测模型的预测误差,提高整体模型的准确性。

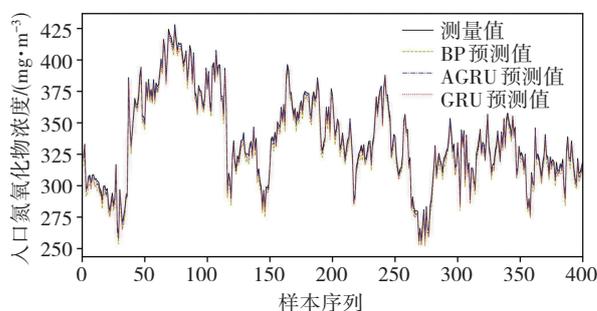


图5 3种模型预测结果

Fig. 5 Prediction results of three models

表2 不同模型的预测精度

Table 2 Prediction accuracy of different models

模型	$F_{RMSE}/(\text{mg} \cdot \text{m}^{-3})$	$F_{MAE}/(\text{mg} \cdot \text{m}^{-3})$
AGRU	2.087	1.990
GRU	3.332	3.022
BP	5.610	5.409

5 结论

利用对时序数据有良好处理能力的GRU神经网络建立火电机组氮氧化物排放预测模型有着不错的预测效果。但是使用原始数据直接建模会发现输入维数过高,此外网络处理的结果没有很好地体现对输出变量有较大贡献的输入特征的作用。针对这两点不足,利用KPCA降低模型维数,引入注意力机制增强不同信息的敏感度,突出对输出贡献较高的输入特征,提高模型预测精度。某330 MW机组运行数据对比实验表明:AGRU预测模型的均方根误差和平均绝对误差较BP和GRU模型小,可较为准确地预测NO_x浓度。在后续的研究中,可在本研究的基础上探究集成算法在锅炉NO_x浓度预测上的有效性。

参考文献(References):

- [1] 杨景瑞,王莹,陈虎,等. 烟气中 NO_x 脱除技术的研究进展[J]. 化工环保, 2020, 40(5): 461—466.
YANG Jing-rui, WANG Ying, CHEN Hu, et al. NO_x in flue gas research progress of x removal technology[J]. Chemical Environmental Protection, 2020, 40 (5): 461—466.
- [2] 中华人民共和国生态环境部. 燃煤电厂超低排放烟气治理工程技术规范: HJ 2053—2018[S]. 北京: 中国环境科学出版社, 2018.
Ministry of Ecological Environment of the People's Republic of China. Technical code for ultra low emission flue gas treatment engineering of coal fired power plants: HJ 2053-2018[S]. Beijing: China Environmental Science Press, 2018.
- [3] 方久文. 燃煤锅炉运行技术[M]. 西安: 陕西科学技术出版社, 2021.
FANG Jiu-wen. Coal fired boiler operation technology[M]. Xi'an: Shaanxi Science and Technology Press, 2021.
- [4] 马子然,周佳丽,马静,等. 燃煤电厂脱硝催化剂宽负荷运行的现状与发展[J]. 中国电机工程学报, 2022, 42(23): 1—16.
MA Zi-ran, ZHOU Jia-li, MA Jing, et al. Current situation and development of denitration catalyst in coal-fired power plants under wide load operation [J]. Chinese Journal of Electrical Engineering, 2022, 42(23): 1—16.
- [5] 高明明,于浩洋,吕俊复,等. 循环流化床氮氧化物排放预测模型及优化控制研究[J]. 洁净煤技术, 2020, 26(3): 46—51.
GAO Ming-ming, YU Hao-yang, LYU Jun-fu, et al. Study on prediction model and optimal control of NO_x emission in circulating fluidized bed[J]. Clean Coal Technology, 2020, 26 (3): 46—51.
- [6] ZHANG H Y, ZHAO J, YANG L B, et al. Numerical simulation of NO_x emission in supercharged boiler[J]. Advanced Materials Research, 2014(3286): 983—990.
- [7] 郭建民,刘石,姜凡,等. 基于 SVM 的对冲燃煤锅炉 NO_x 排放特性[J]. 燃烧科学与技术, 2006(3): 243—247.
GUO Jian-min, LIU Shi, JIANG Fan, et al. NO_x emission characteristics of hedge coal-fired boiler based on SVM[J]. Combustion Science and Technology, 2006(3): 243—247.
- [8] AHMED F, CHO H J, KIM J K, et al. A real-time model based on least squares support vector machines and output bias update for the prediction of NO_x emission from coal-fired power plant [J]. Korean Journal of Chemical Engineering, 2015, 32(6): 1029—1036.
- [9] LYU 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] WANG Q, NIU B, SUN Q, et al. Prediction of NO_x generation concentration of CFB boiler based on PCA-GA-BP algorithm[C]//Proceedings of the 32nd China Process Control Conference. 2021: 1157.
- [11] ALEX S. Fundamentals of recurrent neural Network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, C (404): 1—28.
- [12] 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.
- [13] 李军,常燕芝. 基于 KPCA-KMPMR 的短期风电功率概率预测[J]. 电力自动化设备, 2017, 37(2): 22—28, 36.
LI Jun, CHANG Yan-zhi. Probability prediction of short-term wind power based on KPCA-KMPMR[J]. Power Automation Equipment, 2017, 37(2): 22—28, 36.
- [14] 王继东,杜冲. 基于 Attention-BiLSTM 神经网络和气象数据修正的短期负荷预测模型[J]. 电力自动化设备, 2022, 42(4): 172—177, 224.
WANG Ji-dong, DU Chong. Short term load forecasting model based on Attention-BiLSTM neural network and meteorological data correction[J]. Power Automation Equipment, 2022, 42(4): 172—177, 224.
- [15] 王天翔. 深度学习中梯度下降算法的应用研究[D]. 杭州: 浙江师范大学, 2019.
WANG Tian-xiang. Research on the application of gradient descent algorithm in deep learning [D]. Hangzhou: Zhejiang Normal University, 2019.
- [16] 王圣,朱法华,王慧敏,等. 燃煤电厂氮氧化物产生浓度影响因素的敏感性和相关性研究[J]. 环境科学学报, 2012, 32(9): 2303—2309.
WANG Sheng, ZHU Fa-hua, WANG Hui-min, et al. Study on sensitivity and correlation of influencing factors of NO_x concentration in coal-fired power plants[J]. Journal of Environmental Science, 2012, 32 (9): 2303—2309.