

基于非负绞杀与长短期记忆神经网络的动态软测量算法

孙 凯¹, 隋 璘¹, 张芳芳¹, 杨根科^{2,3†}

(1. 齐鲁工业大学(山东省科学院) 电气工程与自动化学院, 山东 济南 250353;

2. 上海交通大学 自动化系, 上海 200240; 3. 上海交通大学 宁波人工智能研究院, 浙江 宁波 315000)

摘要: 现代工业过程建模中, 生产过程的多变量、非线性及动态性会导致模型复杂度增高且建模精度降低. 针对这一问题, 将非负绞杀算法(NNG)嵌入长短期记忆(LSTM)神经网络, 提出一种基于LSTM神经网络及其输入变量选择的动态软测量算法. 首先, 通过参数优化生成训练好的LSTM神经网络, 利用其出色的历史信息记忆能力处理工业过程中的动态、时滞等问题; 其次, 采用NNG算法对LSTM网络输入权重进行压缩, 剔除冗余变量, 提高模型精度, 并采用网格搜索法与分块交叉验证对其超参数寻优; 最后, 将算法应用于某火电厂脱硫过程排放烟气SO₂浓度软测量建模, 并与其它先进算法进行性能比较. 实验结果表明所提算法能有效剔除冗余变量, 降低模型复杂度并提高其预测性能.

关键词: 神经网络; 软测量; 长短期记忆; 动态建模; 变量选择; 模型简化

引用格式: 孙凯, 隋璘, 张芳芳, 等. 基于非负绞杀与长短期记忆神经网络的动态软测量算法. 控制理论与应用, 2023, 40(1): 83 – 93

DOI: 10.7641/CTA.2021.10529

Dynamic soft sensor algorithm based on nonnegative garrote and long short-term memory neural network

SUN Kai¹, SUI Lin¹, ZHANG Fang-fang¹, YANG Gen-ke^{2,3†}

(1. School of Electrical Engineering and Automation, Qilu University of Technology (Shandong Academy of Sciences), Jinan Shandong 250353, China;

2. Department of Automation, Shanghai Jiaotong University, Shanghai 200240, China;

3. Ningbo Institute of Artificial Intelligence, Shanghai Jiaotong University, Ningbo Zhejiang 315000, China)

Abstract: In modern industrial process modeling, the multivariable, nonlinearity and dynamics of the production process increase the model complexity and reduce the model accuracy. In response to this problem, a dynamic soft-sensing algorithm based on the long short-term memory (LSTM) neural network and its input variable selection is proposed by embedding the nonnegative garrote (NNG) into the LSTM neural network. First, a well-trained LSTM neural network is generated with parameter optimization, in which the dynamics and time-delay of industrial processes are handled by its excellent memory capacity of historical information. Then, the NNG algorithm is used to compress the input weights of the LSTM network to eliminate the redundant variables and improve the model accuracy. Grid search and blocked cross-validation are used to find the optimal hyperparameter of the algorithm. Finally, the algorithm is applied to the soft-sensing modeling of SO₂ concentration in the flue gas that is discharged from the desulfurization process of a thermal power plant, and the performance of the algorithm is compared with other state-of-the-art algorithms. Experimental results demonstrate that the proposed algorithm can effectively delete the redundant variables, reduce the model complexity and improve the prediction performance of the model.

Key words: neural networks; soft sensor; long short-term memory; dynamic modeling; variable selection; model reduction

Citation: SUN Kai, SUI Lin, ZHANG Fangfang, et al. Dynamic soft sensor algorithm based on nonnegative garrote and long short-term memory neural network. *Control Theory & Applications*, 2023, 40(1): 83 – 93

收稿日期: 2021-06-20; 录用日期: 2021-09-30.

[†]通信作者. E-mail: gkyang@sjtu.edu.cn; Tel.: +86 13651869523.

本文责任编辑: 夏元清.

山东省自然科学基金项目(ZR2021MF022), 国家重点研发计划项目(2019YFB1705702, 2020YFB1711204), 山东省重点研发计划项目(公益类专项)(2019GGX104037)资助.

Supported by the Shandong Provincial Natural Science Foundation (ZR2021MF022), the National Key Research and Development Program of China (2019YFB1705702, 2020YFB1711204) and the Shandong Provincial Key Research and Development Program (Public Welfare Project) (2019GGX104037).

1 引言

现代工业过程中,为保证产品质量与生产过程安全性,需要对某些难以直接测量却又与之密切相关的关键变量进行实时监测,以满足工业生产需求^[1].软测量技术通过挖掘易于获取的辅助变量与主导变量之间的关系建立数学模型,间接完成对主导变量的有效估计,被广泛应用于各种现代流程工业和过程控制领域^[2-4].

人工神经网络(artificial neural network, ANN)因其出色的非线性映射能力,不依赖系统先验知识的学习能力,常用于工业过程的关键参数软测量^[5].然而,实际工业过程本质上具有复杂的时滞特性与动态特性,某些关键参数的状态不仅与其他过程参数的当前时刻状态有关,也依赖于其过去某时刻或某时段的状态^[6].传统ANN多采用静态网络结构,难以捕获两者之间复杂的动态时序关系,因此所建立的软测量模型往往难以满足生产要求.

递归神经网络(recurrent neural network, RNN)通过引入时序反馈机制,在考虑当前过程状态的同时引入相关历史信息,能够有效描述时序数据间的动态行为^[7].然而,标准RNN在对具有较长时间间隔的时间序列建模时,会出现梯度消失的问题,难以将较早时间步的信息传递给后面的时间步^[8].为此, Hochreiter 等^[9]提出一种长短期记忆(long short-term memory, LSTM)神经网络结构,通过采用记忆单元和3个非线性门代替其基本隐含神经元,实现信息的长时记忆. LSTM独特的网络结构使其在长时间序列建模方面更为有效,被广泛应用于人类活动识别^[10]、语音识别^[11]、文本处理^[12]以及工业过程软测量^[13]等领域.

另一方面,复杂工业过程中存在过多特征变量,且具有高度相关性与强耦合性,包含大量冗余信息,从而使模型复杂度增大,性能降低.近年来,许多研究者致力于LSTM神经网络输入变量辨识与选择算法研究.文献[14]提出一种基于工厂数据的注意力LSTM网络辨识方法,在LSTM网络基础上考虑输入变量对目标变量的重要性,为输入序列中影响输出结果的关键特征分配更多注意力,提高了LSTM网络的泛化能力.文献[15]提出一种基于互信息特征选择与LSTM神经网络的风速预测模型,实现了对风电场中风速的动态预测,实验结果表明所建模型具有更少的输入变量与更高的预测精度.文献[16]利用注意力机制获取输入和目标变量之间的相关性,提出一种基于时空注意力的LSTM神经网络软测量算法,并应用于原油加氢裂化过程的软测量建模.

非负绞杀(nonnegative garrote, NNG)^[17]是一种嵌入式变量选择算法,能将变量选择与回归系数的优化过程融为一体,最初被用以解决线性回归子集选择问题.文献[18]将NNG算法与多层感知器(multi-layer perceptron, MLP)神经网络相结合,提出一种面向非

线性过程的软测量算法,可建立输入变量更少、预测精度更高的软测量模型.然而,MLP是一种前馈神经网络,在对动态过程建模时,需对原始数据集进行时序扩展,而随着数据集的不断扩展,模型输入变量将大幅增加,且各变量不同时间序列间存在相互耦合,导致变量选择准确性降低,建模精度下降.

针对现代工业过程建模中面临的多变量、非线性、动态性等难题,将NNG算法与LSTM神经网络相结合,提出一种基于LSTM输入变量选择的动态软测量(NNG-LSTM)算法.一方面利用LSTM神经网络的动态信息处理能力处理相关历史信息,保证辅助变量与主导变量间的时序对应关系,实现动态建模;另一方面采用NNG算法辨识高维特征变量间的冗余信息,删除冗余输入变量,提高模型的预测精度.最后基于某火电厂脱硫过程生产数据,建立SO₂排放浓度的软测量模型,并通过与不同软测量算法的性能对比,验证了算法的有效性.

2 LSTM神经网络

如图1所示, LSTM单元通常包含3个输入,分别为前一时刻单元状态 $C_{(t-1)}$ 、前一时刻隐含状态 $h_{(t-1)}$ 及当前时刻输入变量 $x_{(t)}$;两个输出,分别为当前时刻单元状态 $C_{(t)}$ 与当前时刻隐含状态 $h_{(t)}$,并同时作为下一时刻单元输入参与运算.




图1 LSTM单元结构

Fig. 1 The structure of the LSTM unit

为更清晰地描述LSTM单元运行机理,将其内部物理架构展开,如图2所示. LSTM独特的门控机制由遗忘门(forget gate, $f_{(t)}$)、输入门(input gate, $i_{(t)}$)与输出门(output gate, $o_{(t)}$)3个门控制器以及候选单元状态(candidate cell state, $c'_{(t)}$)组成.

来自 $h_{(t-1)}$ 与 $x_{(t)}$ 的信息共同传递到3个门控制器与 $c'_{(t)}$ 中,经由相应的激活函数得到一系列0~1与-1~1的向量输出以控制信息的留存程度.其中 $f_{(t)}$ 通过控制 $C_{(t-1)}$ 遗忘前一时刻的无用信息; $i_{(t)}$ 用于确定 $c'_{(t)}$ 中重要信息的保留,从而实现 $C_{(t-1)}$ 中信息的更新; $o_{(t)}$ 则用来决定 $C_{(t)}$ 需要输出给 $h_{(t)}$ 哪些相关信息.其中各门控单元结构相同,均由经典的前馈神经网络构成,以遗忘门为例,其拓扑结构如图3所示.




图 2 LSTM单元内部物理架构

Fig. 2 The internal physical architecture of LSTM unit




图 3 LSTM遗忘门拓扑结构

Fig. 3 The topology structure of forgetting gate in LSTM

LSTM神经网络正是通过这些门控单元以实现 $C(t)$ 与 $h(t)$ 中的信息更新与动态记忆, 其运算公式如下所示:

$$f(t) = \sigma\left(\sum_{i=1}^p x_i^t W_{ik}^{xf} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hf} + b_k^f\right), \quad k = 1, 2, \dots, q, \quad (1)$$

$$i(t) = \sigma\left(\sum_{i=1}^p x_i^t W_{ik}^{xi} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hi} + b_k^i\right), \quad k = 1, 2, \dots, q, \quad (2)$$

$$o(t) = \sigma\left(\sum_{i=1}^p x_i^t W_{ik}^{xo} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{ho} + b_k^o\right), \quad k = 1, 2, \dots, q, \quad (3)$$

$$c'_{(t)} = \tanh\left(\sum_{i=1}^p x_i^t W_{ik}^{xc} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hc} + b_k^c\right),$$

$$k = 1, 2, \dots, q, \quad (4)$$

式中: $f(t)$, $i(t)$, $o(t)$, $c'_{(t)}$ 分别代表遗忘门、输入门、输出门与候选单元状态的输出; x_i^t 表示当前时刻的输入; h_i^{t-1} 表示前一时刻的隐藏状态; W, b 分别为各门控单元对应权重矩阵与偏置向量; p 与 q 分别表示网络输入维度与隐含层节点数; $\sigma(\cdot)$ 表示 Sigmoid 激活函数; $\tanh(\cdot)$ 表示双曲正切激活函数. 更新后的单元状态 $C(t)$ 与单元输出 $h(t)$ 为

$$C(t) = f(t) \odot C(t-1) + i(t) \odot c'_{(t)}, \quad (5)$$

$$h(t) = o(t) \odot \tanh(C(t)), \quad (6)$$

其中 $\odot$ 为向量点乘运算, 则网络输出 $y(t)$ 表示为

$$y(t) = g\left(\sum_{k=1}^q W_k^y(o(t) \odot \tanh(f(t) \odot C(t-1) + i(t) \odot c'_{(t)})) + b^y\right). \quad (7)$$

如上所述, LSTM 单元的信息存储结构及门控机制使其可长时记忆、动态分析、处理相关历史信息, 建立变量间的时序依赖关系, 并实现信息的留存持久化.

3 NNG-LSTM 动态软测量算法

本章节详细阐述了 NNG-LSTM 算法原理及算法流程.

3.1 NNG 算法原理

NNG 算法通过对回归模型添加惩罚项以实现变量系数的收缩, 从而实现输入变量的选择与系数优化. 对线性子集回归问题

$$\mathbf{y} = \beta \mathbf{x} + \varepsilon, \quad (8)$$

其中: $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_p]$ 与 $\mathbf{y}$ 分别代表输入、输出变量, $\beta = [\beta_1 \ \beta_2 \ \dots \ \beta_p]^T$ 为系数矩阵, ε 为随机误差.

差. 算法设计了一组收缩算子 $\theta = [\theta_1 \ \theta_2 \ \cdots \ \theta_p]$, 并将其添加到最小二乘(ordinary least squares, OLS)回归表达式, 即

$$\begin{aligned} \theta^*(s) = \operatorname{argmin}_{\forall(x,y) \in \{X,Y\}} \sum_{i=1}^p \{(\mathbf{y} - (\theta \odot \hat{\beta})\mathbf{x})^2\}, \\ \theta_i \geq 0, \sum_{i=1}^p \theta_i \leq s, \end{aligned} \quad (9)$$

其中: $X \in \mathbb{R}^{n \times p}$ 为输入样本矩阵, 每一列代表一个候选输入变量, n 为样本总数; $Y \in \mathbb{R}^n$ 为输出样本矩阵; $\hat{\beta}_i$ 表示OLS系数估计; s 为给定的绞杀超参数. 求解式(9)可得优化的收缩向量 $\theta^* = [\theta_1^* \ \theta_2^* \ \cdots \ \theta_p^*]$, 将 θ^* 代入式(8), 即可获得新的系数估计

$$\tilde{\beta}_i = \theta_i^* \hat{\beta}_i, \quad i = 1, 2, \cdots, p, \quad (10)$$

则优化后的模型可表示为

$$\tilde{y} = \sum_{i=1}^p \tilde{\beta}_i x_i. \quad (11)$$

在NNG算法中, s 值的大小决定了算法的绞杀强度: 当 $s \geq p$ 时, 式(9)中约束 $\sum_{i=1}^p \theta_i \leq s$ 无效, 即 $\tilde{\beta}_i = \hat{\beta}_i$, 模型将保留所有输入变量; 随着 s 逐渐减小, 算法绞杀强度增强, 更多 θ_i^* 趋向于0, 意味着更多的变量被删除; 当 s 减小到0时, 所有输入变量都将被删除. 因此, 算法可以通过调整 s 值来改变绞杀强度, 从而实现输入变量的选择及参数优化.

3.2 算法设计

NNG-LSTM算法共分为两个阶段: 第1阶段, 通过对LSTM神经网络超参数进行优化设置, 训练得到一个较好的LSTM神经网络作为初始模型, 如式(7)所示. 第2阶段, 将NNG算法的收缩算子 θ 嵌入LSTM网络输入权重, 建立新的神经网络表达式, 即

$$\begin{aligned} y(t) = & g\left(\sum_{i=1}^q W_i^y (\hat{o}_{(t)} \odot \tanh(\hat{f}_{(t)} \odot C_{(t-1)} + \right. \\ & \left. \hat{i}_{(t)} \odot \tilde{c}'_{(t)})) + b_i^y\right), \end{aligned} \quad (12)$$

其中各门控单元输出更新为

$$\begin{aligned} \hat{f}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t (\theta_i \odot \hat{W}_{ik}^{xf}) + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hf} + b_k^f\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (13)$$

$$\begin{aligned} \hat{i}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t (\theta_i \odot \hat{W}_{ik}^{xi}) + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hi} + b_k^i\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (14)$$

$$\begin{aligned} \hat{o}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t (\theta_i \odot \hat{W}_{ik}^{xo}) + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{ho} + b_k^o\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (15)$$

$$\tilde{c}'_{(t)} = \tanh\left(\sum_{i=1}^p x_i^t (\theta_i \odot \hat{W}_{ik}^{xc}) + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hc} + b_k^c\right),$$

$$k = 1, 2, \cdots, q, \quad (16)$$

则NNG-LSTM算式可表示为

$$\begin{aligned} \theta^*(s) = \operatorname{argmin} \left\{ \sum_{i=1}^n (y_k - g\left(\sum_{i=1}^q W_i^y (\hat{o}_{(t)} \tanh \odot \right. \right. \\ \left. \left. (\hat{f}_{(t)} \odot C_{(t-1)} + \hat{i}_{(t)} \odot \tilde{c}_{(t)}) + b_i^y\right))^2 \right\}, \\ \theta_i \geq 0, \sum_{i=1}^p \theta_i \leq s. \end{aligned} \quad (17)$$

显然, 式(17)是一个非线性不等式约束最优化问题, 对于给定的绞杀超参数 s , 可通过信赖域法求解该问题获得最优收缩向量 θ^* . 本文采用的优化求解算法为文献[19–20]所提出的基于内反射牛顿法的子空间信赖域法. 算法通过使用一种新的仿射比例变换, 并遵循分段线性路径(反射路径)来生成严格可行的迭代, 不存在稳定性问题, 计算时间仅随输入变量的增加而适度增加. 将计算所得 θ^* 代入, 即可获得一组新的权重系数

$$\tilde{W}_{ik} = \theta^* \odot \hat{W}_{ik}, \quad (18)$$

其中: $\theta^* = [\theta_1^* \ \theta_2^* \ \cdots \ \theta_p^*]^T$, 对于 $\forall i$, 当 $\theta_i^* = 0$ 时, 输入变量 x_i^t 被删除, 各门控单元输出更新为

$$\begin{aligned} \tilde{f}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t \tilde{W}_{ik}^{xf} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hf} + b_k^f\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (19)$$

$$\begin{aligned} \tilde{i}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t \tilde{W}_{ik}^{xi} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hi} + b_k^i\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (20)$$

$$\begin{aligned} \tilde{o}_{(t)} = \sigma\left(\sum_{i=1}^p x_i^t \tilde{W}_{ik}^{xo} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{ho} + b_k^o\right), \\ k = 1, 2, \cdots, q, \end{aligned} \quad (21)$$

$$\begin{aligned} \tilde{c}'_{(t)} = \tanh\left(\sum_{i=1}^p x_i^t \tilde{W}_{ik}^{xc} + \sum_{j=p+1}^{p+q} h_j^{t-1} W_{jk}^{hc} + b_k^c\right), \\ k = 1, 2, \cdots, q. \end{aligned} \quad (22)$$

优化后的模型输出 $\tilde{y}_{(t)}$ 可表示为

$$\begin{aligned} \tilde{y}_{(t)} = g\left(\sum_{i=1}^q W_i^y (\tilde{o}_{(t)} \odot \tanh(\tilde{f}_{(t)} \odot C_{(t-1)} + \right. \\ \left. \tilde{i}_{(t)} \odot \tilde{c}'_{(t)})) + b_i^y\right). \end{aligned} \quad (23)$$

3.3 NNG-LSTM超参数调优与模型选择

NNG-LSTM算法涉及的超参数包括LSTM神经网络超参数与绞杀超参数. 不同超参数的选择对模型性能影响巨大, 为保证模型性能, 需对其进行超参数调优. 网格搜索法(grid search, GS)^[21]是一种指定参数值的穷举搜索方法, 具有简单实用、可并行计算且耗时可控等优点, 是解决超参数调优问题的一种有效方法.

交叉验证(cross validation, CV)^[22]是一种常用的模型评估与超参数调优方法,可用于评估模型预测结果在其它独立数据集上的泛化能力。然而,在对动态软测量模型进行验证评估时,由于数据间存在时序依赖性与时间演化效应,常规CV对数据集的划分方式会破坏数据的时序完整性,从而产生对模型的有偏估计。

因此,为了对模型性能进行更好的评估,本文采用针对时序数据的分块交叉验证(blocked cross-validation, BCV)^[23]评估模型性能,其验证过程如图4所示。BCV的关键在于划分数据集时保证了子集块之间的时序依赖性,采用正向链接策略将数据集分割成 K 块互斥子集,即按照时间顺序划分每一块子集,之后逐步滚动前向选择新的训练集与验证集。

3.3.1 LSTM神经网络超参数调优

LSTM神经网络超参数主要包括LSTM隐含层节点数、初始学习率、最大迭代次数等。首先依据先验知识确定不同超参数的候选置信取值,生成候选超参数网络;其次采用GS法对不同超参数组合进行验证寻

求;最后根据寻优后的超参数组合,获得训练好的初始LSTM网络。




图4 分块交叉验证

Fig. 4 Block cross-validation

优化后LSTM损失函数值变化曲线如图5所示,模型训练损失函数值随迭代次数的增加逐渐下降,在经过多次迭代后趋于稳定且减小到较小范围,表明模型训练效果较好且达到稳定状态。




图5 LSTM模型损失函数值变化曲线

Fig. 5 Loss function curve of LSTM model

LSTM神经网络的训练算法为跨时间的梯度反向传播算法(back-propagation through time, BPTT),其具体训练过程主要包括3步:

1) 前向计算: 计算各门控单元与LSTM单元的输出值,即 $f_{(t)}$, $i_{(t)}$, $o_{(t)}$, $c'_{(t)}$, $C_{(t)}$, $h_{(t)}$ 的值,其计算公式如式(1)–(6)所示。

2) 反向计算: 计算其损失函数值, LSTM模型损失函数为半均方根误差(half mean squared error, HMSE),计算方式如下:

$$HMSE = \frac{1}{2n_i} \sum_{i=1}^{n_i} (y_i - \hat{y}_i)^2, \quad (24)$$

其中: y_i 和 $\hat{y}_i$ 分别为数据样本的实际值与估计值, n_i 为数据样本数量。HMSE反映了网络的训练状态, HMSE值越小,表明数据集拟合效果越好。

3) 梯度更新: 基于相应误差项,采用Adam优化算法^[24]对网络权重进行更新。Adam优化算法是一种可以代替传统随机梯度下降算法的一阶优化算法,在相同的训练周期内具有更高的计算效率与更好的收敛性能,同时所需要的计算空间更少。

3.3.2 绞杀超参数调优

在NNG-LSTM算法中,绞杀超参数 s 值大小决定算法的绞杀强度,从而影响最终的模型复杂度与预测精度,其最优值 s^* 由线性等分向量 $\mathbf{S} = [s_1 \ s_2 \ \cdots \ s_u]$ 枚举后,BCV评估获得。其中 $s_1 = 0$ 为向量下限, $s_u = p$ 为向量上限, u 为向量个数, Δs 为相邻元素间的差值,具体过程如下:

1) 数据划分: 将数据集 $\delta = \{X, Y\}$ 按时间顺序划分为 K 块子集: $\delta = \{\delta_1, \delta_2, \cdots, \delta_J, \cdots, \delta_K\}$, 首先令

$\tilde{\delta}_J = \{\delta_1, \delta_2, \dots, \delta_J\}$ 为训练集, $\tilde{\delta}_J = \delta_{J+1}$ 为验证集, 之后逐步前向滚动选择新的训练集与验证集, 直至 $K - J$ 折交叉验证结束.

2) 模型验证: 由训练集 $\tilde{\delta}_J$ 与 NNG-LSTM 算法获得网络模型, 验证集 $\tilde{\delta}_J$ 验证模型性能, 计算当前 s 值下, 验证集 $\tilde{\delta}_J$ 实际值与预测值间的均方根误差 (root mean square error, RMSE), 计算方式如下:

$$\text{RMSE}^J = \sqrt{\frac{1}{n_i} \sum_{i=1}^{n_i} (y_i^{(J)} - \tilde{y}_i^{(J)})^2}, \quad (25)$$

其中: n_i 表示验证集样本数, $y_i^{(J)}$ 与 $\tilde{y}_i^{(J)}$ 分别为每个数据样本的实际值与预测值.

3) 参数选择: 在当前 s 值下进行 $K - J$ 折交叉验证, 计算求得其平均值, 计算方式如下:

$$\overline{\text{BCV}}_{(s)}^{K-J} = \frac{1}{K - J} \sum_J \text{RMSE}^J, \quad (26)$$

s 的最优值 s^* 可以通过最小化 $\overline{\text{BCV}}_{(s)}^{K-J}$ 求得,

$$s^* = \underset{(s_{lb} < s < s_{ub})}{\text{argmin}} (\overline{\text{BCV}}_{(s)}^{K-J}). \quad (27)$$

3.4 算法流程

所提出的 NNG-LSTM 软测量算法流程如下:

步骤 1 采用留出法将预处理后的数据前 80% 作为训练、验证, 用于模型验证与超参数调优; 剩余 20% 作为测试集, 用于性能测试.

步骤 2 首先依据先验知识确定不同超参数的候选置信取值, 生成待搜索网格; 然后采用 GS 法对 LSTM 神经网络超参数进行寻优, 选择最优超参数组合; 最后训练生成初始 LSTM 神经网络, 获得网络初始输入权重.

步骤 3 将 NNG 算法收缩算子 θ 嵌入 LSTM 网络输入权重, 建立新的 LSTM 神经网络.

步骤 4 初始化 s, J, K : 令 $s \leftarrow s_1, J \leftarrow 5, K \leftarrow 10$, 采用标准 5 折分块交叉验证.

步骤 5 对于当前 s, J, K , 由式 (17) 求得训练集 $\tilde{\delta}_J$ 下的收缩系数: $\theta(s) = [\theta_1 \ \theta_2 \ \dots \ \theta_p]$.

步骤 6 将 θ 代入式 (18) 以更新网络输入权重, 获得新的网络输出表达式, 如式 (23) 所示.

步骤 7 求解式 (25), 获得当前验证集 $\tilde{\delta}_J$ 的预测值 $\tilde{y}^{(J)}$ 与实际值 $y^{(J)}$ 之间的 RMSE^J.

步骤 8 令 $J \leftarrow J + 1$, 若 $J < K$, 重复步骤 5.

步骤 9 由式 (26) 求得当前 s 值下, $K - J$ 折交叉验证的平均值 $\overline{\text{BCV}}_{(s)}^{K-J}$.

步骤 10 令 $s \leftarrow s + \Delta s$, 且若 $s < s_u$, 则令 $J \leftarrow 5$, 重复步骤 5.

步骤 11 由式 (27) 最小化 $\overline{\text{BCV}}_{(s)}^{K-J}$ 求得最优交叉超参数 s^* .

步骤 12 根据步骤 11 所求得的 s^* , 求解非线性不等式约束优化表达式 (17), 得到优化收缩系数 $\theta^*(s) = [\theta_1^* \ \theta_2^* \ \dots \ \theta_p^*]$.

步骤 13 由式 (18)–(22) 更新网络, 获得优化的 LSTM 神经网络, 其输出表达式如式 (23) 所示.


4 仿真实例验证与分析

本章节对某火电厂脱硫工艺过程进行分析研究, 将所研究算法应用于该过程 SO₂ 烟气排放浓度的软测量建模, 并与其它先进算法进行了性能比较, 证明了该算法的优越性.

4.1 研究对象

该火电厂采用双吸收塔结构与石灰石-石膏湿法烟气脱硫技术进行烟气脱硫, 该方法反应速度快、脱硫效果好、原料成本低, 是当前通用的大机组火电厂烟气脱硫工艺. 其基本原理是利用石灰石浆液中的 CaCO₃ 与原烟气中 SO₂ 气体反应, 生成固体石膏, 以达到脱硫的效果^[25]. 整个脱硫工艺系统主要由烟气系统、吸收剂制备系统、烟气吸收系统、石膏处理系统、工艺水系统、事故浆液系统等子系统组成. 其中烟气吸收系统是脱硫过程的核心部分, 其工艺流程如图 6 所示.

首先, 块状石灰石经湿式球磨机研磨粉碎成石灰石粉末, 与水混合后生成一定浓度的石灰石浆液, 再经进一步处理后进入吸收塔内的氧化反应池, 形成循环浆液; 其次, 变频循环水泵将循环浆液送入喷淋层, 经喷淋层雾化后与烟气充分接触, 生成符合密度要求的石膏浆液; 最后, 石膏浆液经石膏处理系统脱水后形成副产物石膏. 同时, 经净化处理的烟气通过吸收塔除雾器除去水分, 再经静电除尘器除尘后通过烟囱排向大气. 其化学反应基本原理如下所示:



在该系统中, 二级吸收塔烟气排放中的 SO₂ 浓度是需要被重点监测、控制的关键变量, 企业需确保其排放浓度及总量符合国家污染物排放标准. 然而, 实际生产过程中该变量波动较大, 在线分析仪工作不够稳定, 需定期维护, 因此需要设计软传感器提供校验信息, 提高系统的可靠性. 另一方面, 有效的软测量模型的建立可为该过程控制系统的优化设计提供技术支撑.

与单塔结构相比, 双塔结构可更加有效地去除烟气中的 SO₂. 然而, 双塔结构的设计也增加了整个流程的复杂性, 两级吸收塔之间过程变量存在高度动态性与时序关联性. 同时双塔结构使得过程变量众多, 会增加建模难度、降低模型精度. 因此, 如何处理系统的动态性、时序关联性和有效地选取特征变量对该过程的软测量建模至关重要.




图6 烟气吸收系统工艺流程图

Fig. 6 Process flow chart of flue gas absorption system

4.2 仿真实验设置

经对该电厂脱硫过程研究及数据分析、预处理后,最终确定了由30个辅助变量组成的候选输入变量集,如表1所示。

仿真实验以该电厂脱硫过程实际历史数据为研究对象,包括表1所示的30个候选输入变量和1个目标输出变量,即排放烟气中的 SO_2 浓度,数据采样间隔为1 min,总共2676组样本数据。将处理后的数据前80%作为训练、验证数据集,用于建立软测量模型,另外20%作为测试数据集,用于验证算法性能。NNG-LSTM算法所建模型的基本结构及超参数设定如表2所示。

为体现NNG-LSTM算法优越性,本文将其与MLP, RNN, LSTM及MI-LSTM等4种软测量算法进行性能比较。各算法均采用三层网络结构,超参数调优过程与NNG-LSTM算法一致,所建模型的基本结构及参数设定如表3所示。

表3中,MI-LSTM算法以互信息“最小冗余最大相关”为准则采用直方图概率密度估计法对特征变量进行重要性排序;以模型预测精度为目标,采用序列前向选择方法对特征变量进行最优化选择;以筛选后的最优特征变量集作为LSTM网络输入,建立MI-LSTM动态软测量模型^[15]。

各算法仿真运行环境均为深度学习服务器: Intel (R) Core (TM) i7-7700 K CPU @ 4.20 GHz 处理器、64 GB内存、64位 Windows10操作系统下 MATLAB R2020a。

4.3 模型性能评价指标

本文采用的模型性能评价指标共有4个:

1) 模型规模M.S: 候选输入变量集中被选变量个数,其计算方式如下:

$$\text{M.S} = \sum_{i=1}^{n_i} S_i, S_i = \begin{cases} 1, & \theta_i \geq 10^{-5}, \\ 0, & \theta_i \leq 10^{-5}. \end{cases} \quad (29)$$

2) 校正决定系数 $A.R^2$: 自变量对因变量方差变化的解释程度,反映了模型数据预测的追踪能力与拟合程度, $A.R^2$ 越接近于1,模型预测效果越好,其计算方式如下:

$$A.R^2 = 1 - \frac{(n_i - 1) \sum_{i=1}^{n_i} (y_i - \hat{y}_i)^2}{(n_i - p - 1) \sum_{i=1}^{n_i} (y_i - \bar{y}_i)^2}. \quad (30)$$

3) 均方误差MSE: 模型预测误差平方的平均值,体现了真实值与预测值的偏离程度,MSE值越小,表明预测精度越高,模型稳定性越好,其计算方式如下:

$$\text{MSE} = \frac{1}{n_i} \sum_{i=1}^{n_i} (y_i - \hat{y}_i)^2. \quad (31)$$

4) 平均绝对百分比误差MAPE: 单个观测值与算数平均值之间偏差的绝对值平均,用以评价模型预测结果的准确性。MAPE值越大,模型预测误差越大,鲁棒性与稳定性越差,其计算方式如下:

$$\text{MAPE} = \frac{100\%}{n_i} \sum_{i=1}^{n_i} \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad (32)$$

其中: S_i 表示为各输入变量是否为模型最终选择变量,

θ_i 为各变量收缩系数, n_i 为测试集数据样本总数, y_i 和 $\hat{y}_i$ 分别为测试集数据样本输出变量的实际值与预测值, $\bar{y}_i$ 为 y_i 平均值, p 为模型输入变量个数.

表 1 脱硫工艺过程候选输入变量

Table 1 Candidate input variables for desulfurization process

序号	变量名称	单位
1	发电机功率	kW
2	炉原烟气SO ₂ 浓度	mg/m ³
3	一级吸收塔出口烟气SO ₂ 浓度	mg/m ³
4	一级吸收塔石膏浆液pH值	
5	石灰石浆液吸收塔流量	m ³ /h
6	二级吸收塔石膏浆液pH值	
7	二级吸收塔供浆流量	m ³ /h
8	#1机#1循环浆泵电流	A
9	#1机#3循环浆泵电流	A
10	吸收塔入口烟气温度	°C
11	总风量	CMH
12	总煤量	t
13	吸收塔出口烟气温度1	°C
14	吸收塔出口烟气温度2	°C
15	吸收塔出口烟气温度3	°C
16	炉烟囱入口净烟气流量	Nm ³ /h
17	炉烟囱入口净烟气压力	Pa
18	炉原烟气NO _x 浓度	mg/m ³
19	炉原烟气O ₂ 浓度	mg/m ³
20	机组脱硫效率中间值	%
21	二级吸收塔出口温度1	°C
22	二级吸收塔出口压力	Pa
23	一级吸收塔出口烟气O ₂ 浓度	mg/m ³
24	吸收塔液位计算值	m
25	二级吸收塔液位3	m
26	水环式真空泵	kW
27	石膏浆液排油泵A电流	A
28	石膏浆液旋流器入口压力	Pa
29	真空皮带脱水机	kW
30	皮带脱水机A石膏滤饼厚度	m

表 2 模型基本结构及参数设定

Table 2 Model basic structure and parameter setting

参数名称	数值
输入维度	30
网络隐含层数	1
隐含层节点数	128
输出维度	1
学习率	0.005
最大迭代次数	500
交叉超参数	7.5

4.4 仿真结果及分析

由于神经网络训练的随机性, 每次运行结果会略

有不同, 为进一步验证算法稳定性, 本文采用相同数据集与运行环境对各算法进行10次仿真, 采用统计结果的平均值作为模型性能评价标准, 结果如表4所示.

表 3 各对比模型基本结构及参数设定

Table 3 Basic structure and parameter setting of each comparison model

参数名称	MLP	RNN	LSTM	MI-LSTM
输入维度	30	30	30	30
网络隐含层数	1	1	1	1
隐含层节点数	10	10	128	128
输出维度	1	1	1	1
学习率	0.001	0.001	0.005	0.005
最大迭代次数	1000	1000	500	500

表 4 不同算法仿真结果

Table 4 Simulation results of different algorithms

Model	M.S	A.R ²	MSE	MAPE
MLP	30	0.4847	28.1003	0.5818
RNN	30	0.5261	14.5409	0.4205
LSTM	30	0.6184	7.9323	0.2200
MI-LSTM	16.8	0.7837	5.8200	0.2062
NNG-LSTM	9.6	0.8590	3.3360	0.1455

RNN与LSTM算法所建模型的误差评价指标MAPE与MSE均明显低于MLP, 且A.R²有显著提高, 说明对动态、时滞过程建模时, 动态神经网络能更好地捕捉输入变量与目标变量间的时序依赖关系. 另外, 在对具有高度动态性与长时依赖性的过程建模时, LSTM比RNN更加有效.

与上述3种算法对应相比, 基于输入变量选择的MI-LSTM与NNG-LSTM算法所建模型的各项性能指标均有明显提升, 充分证明了通过有效地输入变量选择可降低模型复杂度, 提高预测精度. 其中, NNG-LSTM算法所建立的模型平均输入变量数目最少, 误差评价指标MSE与MAPE最低, 校正决定系数A.R²也明显高于其它几种算法, 验证了所研究算法的优越性.

同时, 为更直观地体现不同算法对SO₂烟气排放浓度的预测性能, 本文绘制了不同算法的预测拟合曲线与带正态拟合的预测误差频率分布直方图, 如图7–8所示. 由图7可以看出, 相比于其他算法, NNG-LSTM算法的数据拟合效果最好, 能够更好地预测SO₂浓度的动态变化; 由图8可知, 该算法预测误差分布的标准差 $\sigma = 1.7715$, 远小于其它算法, 表明算法预测误差波动更小, 预测精度更高, 可为该电厂脱硫工艺过程的SO₂浓度监测提供有力参考.

此外, 为进一步验证NNG-LSTM算法变量选择结果与过程机理的相符性, 本文给出了所有候选输入变

量所对应的收缩算子 θ 的数值统计(保留4位有效数字),如图9所示。


θ 值大于0.5的变量共有8个,如表5所示,其中变量2,3,12,16,17对应的 θ 值均大于0.95,对目标变量影响较大,这一结果与文献[26–27]中对脱硫系统中影响脱硫效率的关键因素分析相符合。

表5 $\theta > 0.5$ 的候选输入变量


Table 5 Candidate input variables with $\theta > 0.5$

序号	变量名称	单位	θ 值
2	炉原烟气SO ₂ 浓度	mg/m ³	0.9507
3	一级吸收塔出口烟气SO ₂ 浓度	mg/m ³	1.0000
4	一级吸收塔石膏浆液pH值		0.7711
5	石灰石浆液吸收塔流量	m ³ /h	0.6968
6	二级吸收塔石膏浆液pH值		0.5435
12	总煤量	t	1.0000
16	炉烟囱入口净烟气流量	Nm ³ /h	0.9980
17	炉烟囱入口净烟气压力	Pa	1.0000


变量2,3分别为原烟气SO₂浓度与一级吸收塔出口烟气SO₂浓度,由安装在管道内相应位置的SO₂传感器模组测量获得。显然,这两个变量与脱硫效率直接相关,对最终排放烟气中的SO₂浓度有直接影响。变量12为消耗的总煤量,其变化率也会直接影响烟气SO₂浓度。变量16,17分别为炉烟囱入口净烟气流量与压力,当入口烟气流量越高时,炉烟囱入口净烟气压力越大,被吸收的SO₂也就越多。变量4,5,6所对应的 θ 值均在0.5以上,其中变量5为吸收塔内石灰石浆液流量,会影响烟气中SO₂的吸收速率。变量4,6分别为一、二级吸收塔浆液pH值,其大小表征了浆液对SO₂的吸收程度。




(a) MLP预测拟合曲线




(b) RNN预测拟合曲线



(c) LSTM预测拟合曲线



(d) MI-LSTM预测拟合曲线



(e) NNG-LSTM预测拟合曲线



图7 不同算法SO₂浓度预测曲线

Fig. 7 The prediction curve of SO₂ concentration with different algorithms

综上可知,该算法输入变量选择的结果与该过程机理及专家经验基本一致,充分验证了NNG-LSTM算法所建模型的可解释性。

5 结论

本文提出一种基于NNG与LSTM的动态软测量算法,以解决复杂工业过程中的非线性动态建模问题。所提算法充分利用LSTM神经网络的长时历史信息记忆能力,捕捉输入变量与目标变量之间复杂的时序依赖关系,提高了模型的动态信息处理能力。另一方面,利用NNG算法优化LSTM输入权重矩阵,并剔除冗余输入变量,降低模型复杂度与训练难度,提高了模型的预测性能。最后,将所研究算法应用于某火电厂脱硫过程排放烟气SO₂浓度软测量,并与其它先进算法进行比较,结果表明该算法所建立的软测量模型具有更高的精度,输入变量选择的结果与脱硫过程机理和专家经验一致,充分验证了所提算法的有效性。

图8 不同算法SO₂浓度预测误差分布Fig. 8 The error distribution of SO₂ concentration prediction with different algorithms图9 各候选输入变量的 θ 数值统计Fig. 9 Numerical statistics of θ for different input variables

后续研究包括高维非线性特征选择、无标签数据信息挖掘、以及如何对模型参数进一步优化, 以更好地提高软测量模型在线监测的准确性和可靠性, 从而为相应过程控制系统的优化设计提供技术支撑。

参考文献:

- [1] YUAN X, WANG Y, YANG C, et al. Weighted linear dynamic system for feature representation and soft sensor application in nonlinear dynamic industrial processes. *IEEE Transactions on Industrial Electronics*, 2017, 65(2): 1508 – 1517.
- [2] TANG Jian, QIAO Junfei, XU Zhe, et al. Soft measuring approach of dioxin emission concentration in municipal solid waste incineration process based on feature reduction and selective ensemble algorithm. *Control Theory & Applications*, 2021, 38(1): 110 – 120.
(汤健, 乔俊飞, 徐喆, 等. 基于特征约简与选择性集成算法的城市固废焚烧过程二噁英排放浓度软测量. 控制理论与应用, 2021, 38(1): 110 – 120.)
- [3] LIU Y, CHEN T, CHEN J. Auto-switch Gaussian process regression-based probabilistic soft sensors for industrial multigrade processes with transitions. *Industrial & Engineering Chemistry Research*, 2015, 54(18): 5037 – 5047.
- [4] GENG Zhiqiang, XU Meng, ZHU Qunxiong, et al. Research and application of soft measurement model for complex chemical processes based on deep learning. *CIESC Journal*, 2019, 70(2): 564 – 571.
(耿志强, 徐猛, 朱群雄, 等. 基于深度学习的复杂化工过程软测量模型研究与应用. 化工学报, 2019, 70(2): 564 – 571.)
- [5] SUN K, HUANG S H, WONG D S H, et al. Design and application of a variable selection method for multilayer perceptron neural network with LASSO. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28(6): 1386 – 1396.
- [6] WU Weining, LIU Xiaoyan, XU Xuekui, et al. Time series analysis method for the soft measurement of cement clinker quality. *Control Theory & Applications*, 2018, 35(7): 1029 – 1036.
(武伟宁, 刘小燕, 徐学奎, 等. 水泥熟料质量软测量模型中的时序分析方法. 控制理论与应用, 2018, 35(7): 1029 – 1036.)
- [7] JI Yuehui, ZHOU Hailiang, CHE Shihang, et al. Recurrent neural network-based optimal attitude control of reentry vehicle. *Control Theory & Applications*, 2021, 38(3): 329 – 338.
(吉月辉, 周海亮, 车适行, 等. 基于递归神经网络的再入飞行器最优姿态控制. 控制理论与应用, 2021, 38(3): 329 – 338.)
- [8] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 1994, 5(2): 157 – 166.
- [9] HOCHREITER S, SCHMIDHUBER J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735 – 1780.
- [10] LIU J, WANG G, DUAN L Y, et al. Skeleton-based human action recognition with global context-aware attention LSTM networks. *IEEE Transactions on Image Processing*, 2017, 27(4): 1586 – 1599.
- [11] TANAKA T, MORIYA T, SHINOZAKI T, et al. Evolutionary optimization of long short-term memory neural network language model. *The Journal of the Acoustical Society of America*, 2016, 140(4): 3062 – 3062.
- [12] LI Xu, YAO Chunlong, FAN Fenglong, et al. Recurrent neural networks based paraphrase identification model combined with attention mechanism. *Control and Decision*, 2021, 36(1): 152 – 158.
(李旭, 姚春龙, 范丰龙, 等. 结合注意力机制的循环神经网络复述识别模型. 控制与决策, 2021, 36(1): 152 – 158.)
- [13] YUAN X, LI L, WANG Y. Nonlinear dynamic soft sensor modeling with supervised long short-term memory network. *IEEE Transactions on Industrial Informatics*, 2020, 16(5): 3168 – 3176.
- [14] WANG Yaxin, XU Baochang, XU Chaonong, et al. Attention LSTM network identification method based on factory data. *CIESC Journal*, 2020, 71(12): 5664 – 5671.
(王雅欣, 徐宝昌, 徐朝农, 等. 基于工厂数据的注意力LSTM网络辨识方法. 化工学报, 2020, 71(12): 5664 – 5671.)
- [15] LIU X, ZHANG H, KONG X, et al. Wind speed forecasting using deep neural network with feature selection. *Neurocomputing*, 2020, 397: 393 – 403.
- [16] YUANG X, LI L, SHARDT Y, et al. Deep learning with spatiotemporal attention-based LSTM for industrial soft sensor model development. *IEEE Transactions on Industrial Electronics*, 2020, 68(5): 4404 – 4414.
- [17] YUAN M, LIN Y. On the non-negative garrotte estimator. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2007, 69(2): 143 – 161.
- [18] SUN K, LIU J, KANG J L, et al. Development of a variable selection method for soft sensor using artificial neural network and nonnegative garrote. *Journal of Process Control*, 2014, 24(7): 1068 – 1075.
- [19] COLEMAN T F, LI Y. On the convergence of interior-reflective Newton methods for nonlinear minimization subject to bounds. *Mathematical Programming*, 1994, 67(1): 189 – 224.
- [20] COLEMAN T F, LI Y. An interior trust region approach for nonlinear minimization subject to bounds. *SIAM Journal on Optimization*, 1996, 6(2): 418 – 445.
- [21] LAVALLE S M, BRANICKY M S, LINDEMANN S R. On the relationship between classical grid search and probabilistic roadmaps. *The International Journal of Robotics Research*, 2004, 23(7/8): 673 – 692.
- [22] RACINE J. Consistent cross-validated model-selection for dependent data: HV-block cross-validation. *Journal of Econometrics*, 2000, 99(1): 39 – 61.
- [23] BERGMER C, BENITEZ J M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 2012, 191: 192 – 213.
- [24] KINGMA D, BA J. Adam: A method for stochastic optimization. *Computer Science*, 2014: 273 – 297.
- [25] SUN K, WU X, XUE J, et al. Development of a new multi-layer perceptron based soft sensor for SO₂ emissions in power plant. *Journal of Process Control*, 2019, 84: 182 – 191.
- [26] CUI L, LU J, SONG X, et al. Energy conservation and efficiency improvement by coupling wet flue gas desulfurization with condensation desulfurization—science direct. *Fuel*, 2021, 285(10): 119209.
- [27] ZHANG Sanhu, BAO Junjiang. Key parameters affecting desulfurization efficiency in wet flue gas desulfurization system. *Environmental Engineering*, 2009, 27(2): 22 – 30.
(张三虎, 包俊江. 湿法烟气脱硫系统中影响脱硫效率的关键参数. 环境工程, 2009, 27(2): 22 – 30.)

作者简介:

孙 凯 教授, 硕士生导师, 目前研究方向为神经网络与机器学习、复杂系统建模与优化控制的研究, E-mail: sunkai79@qlu.edu.cn;

隋 璘 硕士研究生, 目前研究方向为机器学习、软传感器建模的研究, E-mail: suilin359@163.com;

张芳芳 副教授, 硕士生导师, 目前研究方向为混沌控制与混沌保密通信、非线性控制、混沌神经网络的研究, E-mail: zhff4u@qlu.edu.cn;

杨根科 教授, 博士生导师, 目前研究方向为复杂系统建模与优化控制、制造系统调度与供应链管理、能源优化与调度的研究, E-mail: gkyang@sjtu.edu.cn.