基于 LSTM 的湿法烟气脱硫浆液 pH 值建模

金秀章，景　昊

（华北电力大学 控制与计算机工程学院，河北 保定 071003）

摘　要： 针对燃煤电厂湿式石灰石－石膏湿法烟气脱硫(WFGD)过程中浆液 pH 值测量时间长，不利于 WFGD 作业的问题，建立高精度的浆液 pH 值模型。基于深度学习的框架，利用长短期记忆神经网络(LSTM)算法对时间序列处理上的优越性进行建模，该模型具有良好的精确度和泛化能力。将燃煤机组实际运行数据中与浆液 pH值变化相关的变量作为模型的辅助变量，建立基于 LSTM 神经网络的浆液 pH 值预测模型。对模型进行仿真验证，并分别与 BP 神经网络模型和最小二乘支持向量机(LSSVM)模型比较，结果表明 LSTM 神经网络模型的预测精度最高，验证了 LSTM 神经网络在工业建模中的优良性能。

关键词： 浆液 pH 值预测；长短期记忆网络(LSTM)；湿式石灰石－石膏湿法烟气脱硫(WFGD)；时间序列

中图分类号： TK39；TP183　　**文献标识码：** A　　**DOI：** 10.19358/j.issn.2096－5133.2020.08.012

引用格式： 金秀章，景昊. 基于 LSTM 的湿法烟气脱硫浆液 pH 值建模 [J]. 信息技术与网络安全，2020，39(8)：62－66.

Modeling of pH value of wet flue gas desulfurization slurry based on LSTM

Jin Xiuzhang, Jing Hao

(School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: Aiming at the problem that the measurement time of slurry pH in wet limestone－gypsum wet flue gas desulfurization(WFGD) process in coal－fired power plants is long, which is not conducive to WFGD operation, a high－precision slurry pH model was established. Therefore, based on the framework of deep learning, the long－term and short－term memory neural network(LSTM) algorithm was used to model the superiority of time series processing. The model has good accuracy and generalization ability. The slurry pH prediction model based on LSTM neural network was established by using variables related to slurry pH changes in actual operating data of coal－fired units as the auxiliary variables of the model. The model was simulated and verified, and compared with the BP neural network model and the least square support vector machine(LSSVM) model. The results show that the LSTM neural network model has the highest prediction accuracy, which verifies the excellent performance of the LSTM neural network in industrial modeling.

Key words: slurry pH prediction; long and short－term memory network(LSTM); wet limestone－gypsum wet flue gas desulfurization(WFGD); time series

0 引言

目前燃煤电厂的 SO_2 排放量已经超过了 SO_2 排放总量的一半，并且呈现逐年递增的趋势。我国先后颁布的《火电厂大气污染物排放标准》和《煤电节能减排升级与改造行动计划（2014—2020 年）》等一系列政策法规，明确指出火电厂的 SO_2 排放浓度必须控制在 35 mg/m^3 以下[1]。石灰石－石膏湿法烟气脱硫技术(WFGD)是目前最有效的燃煤机组 SO_2 控制技术之一[2]。WFGD 工艺中浆液 pH 值是决定烟气脱硫效率的关键参数，因此 pH 值的测量需要迅速、准确。

在 WFGD 现场测量时由于环境恶劣，且 pH 值变化具有较大的惯性，导致测量时长较大，无法及时得到浆液 pH 值的准确值，对于脱硫作业十分不利。因此需要对浆液 pH 值进行预测。

pH 值测量作为非线性系统一直是研究热点[3]。利用燃煤机组的运行数据，再结合机理分析，采用实验建模的方法可以辨识出精确合理的系统模型[4]。

www.pcachina.com

文献[5]和文献[6]把神经网络等自适应模糊系统用于 pH 中和过程。BP 神经网络、RBF 神经网络、Elman 神经网络等方法是 pH 值建模的典型方法,但上述算法本身在时间序列的处理上并没有突出的优势。

随着技术的进步,深度学习、递归神经网络、卷积神经网络等也在 pH 值建模得到应用[7-10]。LSTM 神经网络,注重数据间的时间特性,在大迟延时间序列预测中具有突出优势[11]。LSTM 神经网络的特点在于发现当前时刻数据与之前数据间的联系,利用本身具有的记忆能力,将之前数据的状态进行保存[12],同时根据保存的信息影响后续的预测值及变化趋势。

因此,本文提出一种基于 LSTM 神经网络的 pH 值预测模型。以某 600 MW 机组为研究对象,使用机组实际运行数据,经过机理和相关性分析,确定 pH 值模型的辅助变量,建立高精度的 pH 值预测模型。

1 LSTM 网络

作为循环神经网络(Recurrent Neural Network,RNN)中的一个特殊情况,LSTM 与前馈神经网络不同,属于反馈神经网络的一种。RNN 中神经元的输出可以在下一个时刻作用于自身,且共享从样本序列中不同位置学习到的特征,以此减少模型中的参数数量,这一点在数据规模庞大时具有重要意义。与传统 RNN 网络的区别在于,LSTM 网络结构加入了控制门的机制,结构包括记忆细胞、输入门、输出门、遗忘门四部分。LSTM 原理图如图 1 所示。

图 1 中,三个框分别为不同时序下的细胞状态,δ 表示激活函数为 sig-moid 的前馈网络层,tanh 表示激活函数为 tanh 的前馈网络层。X_t 表示 t 时刻的输入,$S(t)$表示 t 时刻细胞的状态值,前馈网络层中的隐藏神经元个数经多次调试后,确定一个最佳值。

输入门 i_t 的值和在 t 时刻输入细胞的候选状态值 $\widetilde{C}_t$,计算如下:

$$i_t=\delta(\boldsymbol{W}_i*(X_t,h_{t-1})+\boldsymbol{b}_i) \tag{1}$$

$$\widetilde{C}_t=\tanh(\boldsymbol{W}_c*(X_t,h_{t-1})+\boldsymbol{b}_c) \tag{2}$$

其中,$\boldsymbol{W}_i$ 为输入门的权重矩阵,$\boldsymbol{b}_i$ 为输入门的偏置项;$\boldsymbol{W}_c$ 为细胞当前状态的权重矩阵;$\boldsymbol{b}_c$ 为细胞当前状态的偏置项。

其次,计算在 t 时刻遗忘门的激活值 f_t,公式如下:

$$f_t=\delta(\boldsymbol{W}_f*(X_t,h_{t-1})+\boldsymbol{b}_f) \tag{3}$$

式中,$\boldsymbol{W}_f$ 为遗忘门的权重矩阵,$\boldsymbol{b}_f$ 为遗忘门的偏置项。

由以上公式可计算出 t 时刻的细胞状态更新值 $S(t)$,公式如下:

$$S(t)=i_t*\widetilde{C}_t+f_t*S(t-1) \tag{4}$$

计算出细胞状态更新值后,可计算输出门的值 h_t,公式如下:

$$O_t=\delta(\boldsymbol{W}_o*(X_t,h_{t-1})+\boldsymbol{b}_o) \tag{5}$$

$$h(t)=O_t*\tanh(S(t)) \tag{6}$$

式中,$\boldsymbol{W}_o$ 为输出门的权重矩阵,$\boldsymbol{b}_o$ 为输出门的偏置项。

通过以上计算,LSTM 可以有效利用输入数据使 LSTM 神经网络具有长时期记忆功能。

2 模型的建立

2.1 辅助变量的选择

根据 WFGD 的生产机理,pH 值的影响因素来源于两个方面,分别是燃烧侧产生的 SO_2 总量和新鲜石灰石浆液的供应量。如果 SO_2 总量不变,新鲜石灰石浆液供应量增加可以增大 pH 值;如果新鲜

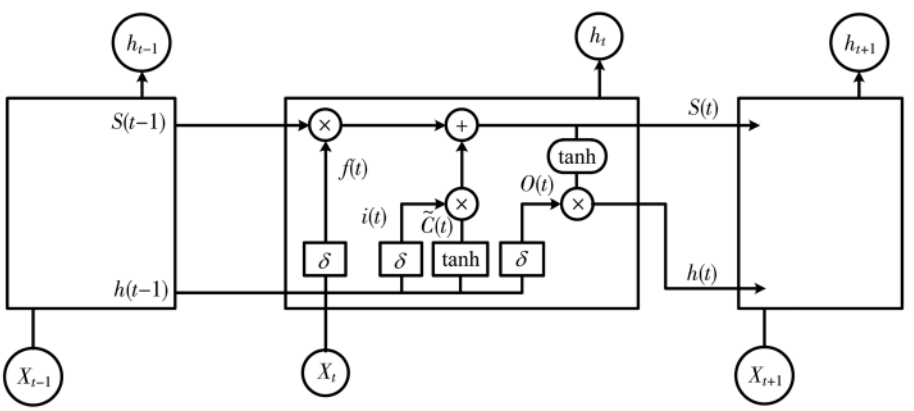

图 1 LSTM 结构图

www.pcachina.com

石灰石浆液供应量不变，SO_2 总量增大可以降低 pH 值。因此模型辅助变量应选取与 SO_2 总量和新鲜石灰石浆液变化有关的物理量。之后使用互信息计算浆液 pH 值与生产中所涉及的物理量的相关性。选取与浆液 pH 值相关性大的变量为辅助变量。因为浆液 pH 值变化惯性大，所以当前时刻浆液 pH 值受前时刻浆液 pH 值的影响。最后确定总风量、总煤量、净烟气 SO_2 浓度、原烟气 SO_2 浓度、原烟气流量、空预器入口烟气氧量、空预器出口烟气氧量、炉浆液密度、新鲜石灰石浆液流量、吸收塔液位、两台氧化风机电流及 5 s 前的浆液 pH 值为辅助变量。

2.2 数据预处理

本文所用数据源于某燃煤电厂的历史数据。预处理包括剔除粗大值、数据中值滤波两部分。

2.2.1 粗大值处理

数据规模足够，且趋于正态分布，因此使用 3σ 准则对数据进行粗大值处理。步骤如下：

(1)计算标准差 σ

$$\sigma=\sqrt{\frac{(x_1-\bar{x})^2+\cdots+(x_n-\bar{x})^2}{n-1}} \tag{7}$$

式中，x_n 为数据值；n 为数据个数；$\bar{x}$ 为数据平均值。

(2)比较数据是否满足下式要求，如果不满足则将数据剔除。

$$\left|x_i-\bar{x}\right|<3\sigma \tag{8}$$

(3)重复步骤(2)，直到数据全部满足式(8)的要求。

2.2.2 数据滤波

对数据曲线中带有“毛刺”的数据滤波，可以消除噪声的影响，使数据变化更加平滑，更加接近真实数据。其中辅助变量总风量的滤波图如图 2 所示。

2.2.3 时序调整

pH 值变化是一个复杂的过程，存在多变量、多耦合及迟延的问题。因此采用互信息法求辅助变量与主导变量间的时间迟延，对变量进行时序调整，进一步提高模型预测精度。

2.3 构建 LSTM 模型

模型以浆液 pH 值作为输出，采用三层 LSTM 神经网络建立，每层 21 个神经元，优化算法为 Adam，最大迭代次数为 280，初始学习率为 0.005，在 125 轮训练后乘以 0.1 来降低学习率。选用 8 700 组预处理后的数据进行仿真实验，其中 6 700 组用于模型训练，2 000 组用于模型测试，数据采样时间间隔为 1 s。

基于 LSTM 神经网络的 pH 值预测模型 LSTM 模型结构如图 3 所示。

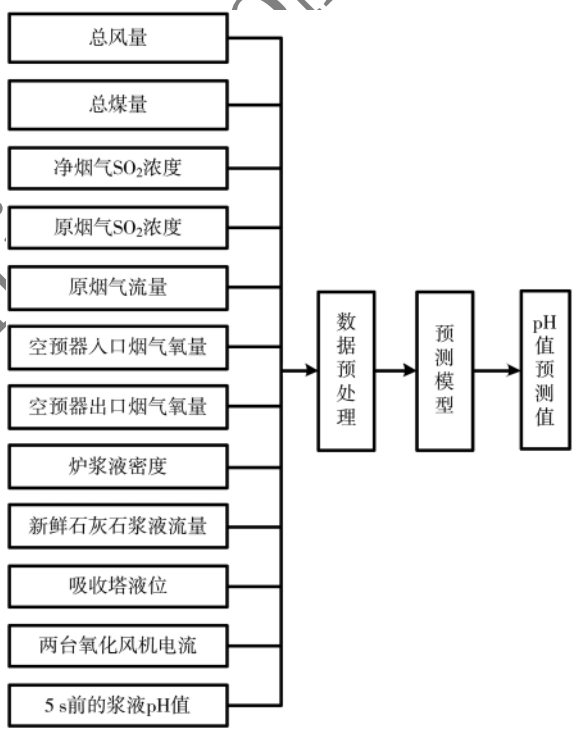

图 3 LSTM 模型结构

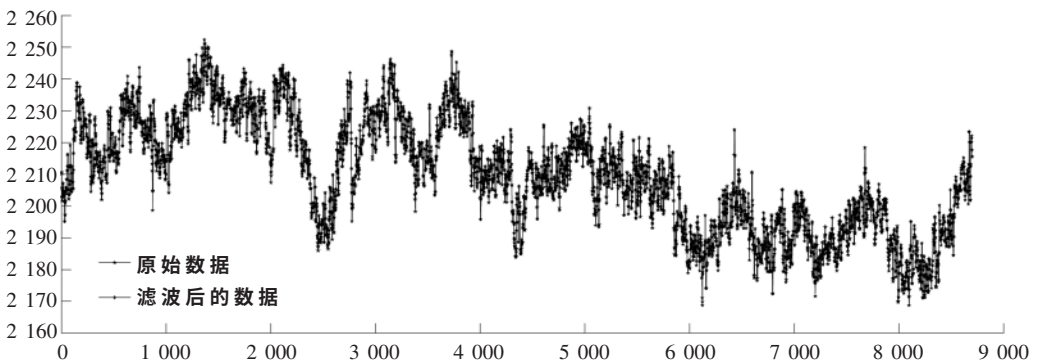

图 2 数据滤波

www.pcach...com

3 结果分析

为了便于验证模型的性能，使用 LSTM 模型与 BP 神经网络模型和 LSSVM 模型进行对比。模型预测值与实际值如图 4 所示。LSTM 模型与 LSSVM 模型和 BP 神经网络模型相比在预测趋势、预测精度方面更加具有优势。LSSVM 模型测试结果显示，在浆液 pH 值增大时，预测值下降；pH 值不变时，预测趋势反复波动。BP 神经网络模型测试结果显示，浆液 pH 值不变时，预测值反复波动；pH 值增大时，预测值没有明显的趋势变化。同时 LSSVM 模型和 BP 神经网络模型的预测值一直在频繁、剧烈波动，使预测精度更低。而 LSTM 网络模型测试结果显示，浆液 pH 值稳定时，预测值也比较稳定；在浆液 pH 值急剧增加时，预测值也在急剧增加，预测值与实际值紧密跟随，且增加后迅速保持稳定。对比三个不同模型测试结果，LSTM 模型在预测精度、趋势跟随上均优于 LSSVM 模型和 BP 神经网络模型，验证了 LSTM 模型在数据挖掘和时间序列处理上的优势。

模型的预测误差如图 5 所示。LSSVM 模型、BP 神经网络模型误差较大，多次出现误差比较严重的值，且误差曲线一直存在频繁、剧烈的波动，因此 LSSVM 模型、BP 神经网络模型预测不理想。LSTM 模型误差最小，误差稳定在 0 刻度左右，没有出现较大误差。因此 LSTM 模型测试结果最好。

为了进一步分析模型的性能，采用平均绝对误差(MAE)和均方根误差(RMSE)两个指标对各个模型进行分析，如式(9)、式(10)所示：

$$\mathrm{MAE}=\frac{1}{N}\sum_{i=1}^{N}\left|(y_{pi}-y_{ai})\right| \tag{9}$$

$$\mathrm{RMSE}=\sqrt{\frac{\sum_{i=1}^{n}(y_{pi}-y_{ai})^2}{n}} \tag{10}$$

式中，y_{pi} 为预测值，y_{ai} 为实际值。

如表 1 所示，LSTM 模型与 BP 神经网络模型、LSSVM 模型相比测试结果最好。LSTM 模型与 LSSVM 模型相比平均绝对误差降低了 0.014 0，均方根误差降低 0.016 6。本文建立的 LSTM 神经网络模型与 BP 神经网络模

表 1 模型测试结果

模型	MAE	RMSE
LSTM	0.002 4	0.003 0
LSSVM	0.016 4	0.019 6
BP	0.009 6	0.012 3

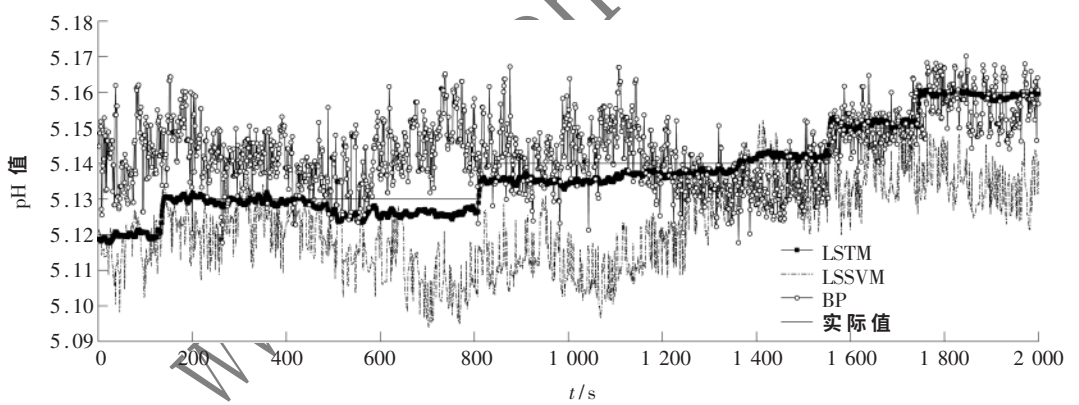

图 4 模型预测值与实际值

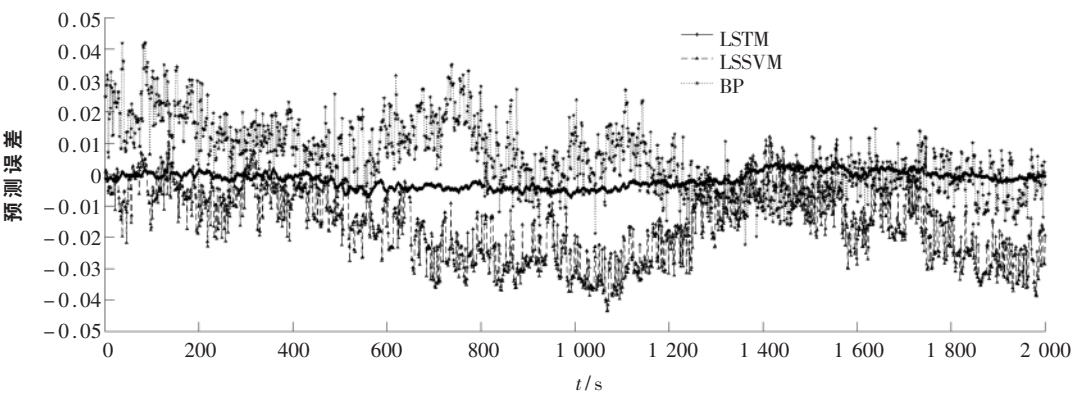

图 5 模型预测误差

型、LSSVM 模型相比在趋势、精度、平均绝对误差及均方根误差方面均有非常大的提升，验证了 LSTM 神经网络在时间序列处理上的优越性，也验证了 LSTM 模型在浆液 pH 值预测的有效性及通用性。

4 结论

针对燃煤电厂 WFGD 过程中石灰石浆液 pH 值的变化受多个变量的影响，且变量之间具有相关性和现场数据具有时序特性，本文提出了一种基于长短期记忆网络的 pH 值预测模型。首先，通过机理分析初步筛选辅助变量后进一步使用互信息确定辅助变量；然后，建立 LSTM 神经网络模型；最后，使用燃煤电厂数据对模型进行测试。模型测试结果表明本文所提出的 LSTM 模型相对 BP 神经网络模型、LSSVM 模型预测精度高、泛化能力强。

需要说明的是，由于数据量有限，本研究只能归纳出高负荷状态下的浆液 pH 值预测模型。然而随着燃煤电厂智能化水平的提高，电厂数据海量化和高维化已经成为必然趋势。合理使用这些数据可以进一步建立全工况的浆液 pH 值预测模型，这也是后续的研究重点。本文结果对 LSTM 算法在燃煤电厂的实际应用具有一定借鉴意义。

参考文献

[1] 康英伟，孙智滨，常俊.基于改进差分进化算法的湿法烟气脱硫系统模型辨识[J].动力工程学报，2019，39(10)：834－839.

[2] 李存杰，张军，张涌新，等.基于 pH 值分区控制的湿法烟气脱硫增效研究[J].环境科学学报，2015，35(12)：4081－4087.

[3] 张嘉，黄景涛，茅建波.基于 LSTM 的电站锅炉 NO_x 排放浓度建模研究[J].计算机与应用化学，2018，35(11)：903－909.

[4] 王志甄，邹志云.基于神经网络的 pH 中和过程非线性预测控制[J].化工学报，2019，70(2)：678－686.

[5] MOTA A S，MENEZES M R，SCHMITZ J E，et al. Identification and online validation of a pH neutralization process using an adaptive network－based fuzzy inference system[J].Chemical Engineering Communications，2016，203(4)：516－526.

[6] CHEN X，XUE A K，PENG D L，et al.Modeling of pH neutralization process using fuzzy recurrent neural network and DNA based NSGA－II[J].Journal of the Franklin Institute，2014，351(7)：3847－3864.

[7] 李泽龙，杨春节，刘文辉，等.基于 LSTM－RNN 模型的铁水硅含量预测[J].化工学报，2018，69(3)：992－997.

[8] 焦李成，杨淑媛，刘芳，等.神经网络七十年：回顾与展望[J].计算机学报，2016，39(8)：1697－1716.

[9] 王康成，尚超，柯文思，等.化工过程深度神经网络软测量的结构与参数自动调整方法[J].化工学报，2018，69(3)：900－906，1253.

[10] 王文广，赵文杰.基于 GRU 神经网络的燃煤电站 NO_x 排放预测模型[J].华北电力大学学报(自然科学版)，2020，47(1)：96－103.

[11] 彭燕，刘宇红，张荣芬.基于 LSTM 的股票价格预测建模与分析[J].计算机工程与应用，2019，55(11)：209－212.

[12] 陈卫华，徐国祥.基于深度学习和股票论坛数据的股市波动率预测精度研究[J].管理世界，2018，34(1)：180－181.

(收稿日期：2020－05－09)

作者简介：

金秀章(1969－)，男，博士，副教授，主要研究方向：先进控制策略在大型电力机组的控制研究、信息融合技术。

景昊(1994－)，男，硕士，主要研究方向：机器学习算法研究、火电厂控制策略优化。

(上接第 61 页)

stronger[C].2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR)，2016.

[15] 李庆忠，李宜兵，牛炯.基于改进 YOLO 和迁移学习的水下鱼类目标实时检测[J].模式识别与人工智能，2019，32(3)：193－203.

[16] 孙琪翔，何宁，张则宇.基于深度学习方法的人体行为识别综述[C].中国计算机用户协会网络应用分会 2019 年第二十三届网络新技术与应用年会论文集，F，2019.

[17] LIU W，RABINOVICH A，BERG A C.ParseNet：looking wider to see better[J].Computer Science，2015.

(收稿日期：2020－05－26)

作者简介：

王文成(1995－)，男，硕士，主要研究方向：农业工程与信息技术。

蒋慧(1996－)，女，硕士，主要研究方向：声学仪器设备。

www.pachira.com

版权声明

经作者授权，本论文版权和信息网络传播权归属于《信息技术与网络安全》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《信息技术与网络安全》编辑部

中国电子信息产业集团有限公司第六研究所