

6-9-2021

## Decomposition Furnace Outlet Temperature Prediction Based on ElasticNet and LSTM

Guangyu Yu

1. *School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China; ;*

Xueping Dong

1. *School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China; ;*

Xiangmin Wang

1. *School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China; ;*

Gan Min

2. *School of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Decomposition Furnace Outlet Temperature Prediction Based on ElasticNet and LSTM

## Abstract

**Abstract:** The outlet temperature of the decomposition furnace is a key indicator in the cement production process. *Aiming at the problem that traditional prediction methods only consider the influence of wind, coal, and materials, a temperature prediction model of ElasticNet combined with Long Short-Term Memory (LSTM) neural network is proposed. The ElasticNet-LSTM export temperature prediction model is constructed by using the ElasticNet method to estimate the parameters of different variables, fully considering the influencing factors and realizing the variable screening, and analyzing the influence of the number of hidden layers and nodes on the accuracy of the neural network.* Simulation results show that the proposed method is superior to LSTM, Least Absolute Shrinkage and Selection Operator-LSTM, BP neural network, and RBF neural network, and has higher prediction accuracy.

## Keywords

decomposition furnace outlet temperature, ElasticNet, long short-term memory neural network, feature selection

## Recommended Citation

Yu Guangyu, Dong Xueping, Wang Xiangmin, Gan Min. Decomposition Furnace Outlet Temperature Prediction Based on ElasticNet and LSTM[J]. Journal of System Simulation, 2021, 33(5): 1078-1085.

## 弹性网下基于 LSTM 的分解炉出口温度预测

于广宇<sup>1</sup>, 董学平<sup>1</sup>, 王祥民<sup>1</sup>, 甘敏<sup>2</sup>

(1. 合肥工业大学 电气与自动化工程学院, 安徽 合肥 230009; 2. 福州大学 数学与计算机科学学院, 福建 福州 350108)

**摘要:** 分解炉出口温度是水泥生产过程中的关键指标。针对传统预测方法只考虑风、煤、料影响的问题, 提出一种弹性网(ElasticNet)结合长短时记忆(Long Short-Term Memory, LSTM)神经网络的温度预测模型。利用弹性网方法对不同变量进行参数估计, 充分考虑影响因素并实现变量筛选, 同时分析隐含层和节点数对神经网络精确度的影响, 构建 ElasticNet-LSTM 出口温度预测模型。仿真结果表明: 所提出的方法优于 LSTM, LASSO(Least Absolute Shrinkage and Selection Operator)-LSTM, BP 神经网络和 RBF 神经网络方法, 具有较高的预测精度。

**关键词:** 分解炉出口温度; 弹性网; 长短时记忆神经网络; 变量筛选

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X (2021) 05-1078-08

DOI: 10.16182/j.issn1004731x.joss.20-0012

## Decomposition Furnace Outlet Temperature Prediction Based on ElasticNet and LSTM

Yu Guangyu<sup>1</sup>, Dong Xueping<sup>1</sup>, Wang Xiangmin<sup>1</sup>, Gan Min<sup>2</sup>

(1. School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China;

2. School of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108, China)

**Abstract:** The outlet temperature of the decomposition furnace is a key indicator in the cement production process. Aiming at the problem that traditional prediction methods only consider the influence of wind, coal, and materials, a temperature prediction model of ElasticNet combined with Long Short-Term Memory (LSTM) neural network is proposed. The ElasticNet-LSTM export temperature prediction model is constructed by using the ElasticNet method to estimate the parameters of different variables, fully considering the influencing factors and realizing the variable screening, and analyzing the influence of the number of hidden layers and nodes on the accuracy of the neural network. Simulation results show that the proposed method is superior to LSTM, Least Absolute Shrinkage and Selection Operator-LSTM, BP neural network, and RBF neural network, and has higher prediction accuracy.

**Keywords:** decomposition furnace outlet temperature; ElasticNet; long short-term memory neural network; feature selection

## 引言

新型干法水泥生产技术已成为当代水泥工业发展的主流, 预分解技术是其核心技术之一。分解炉承担煤粉燃烧、气固换热和碳酸盐分解任务, 使生料入窑时分解率达到 90%以上<sup>[1]</sup>。由于分解炉的非线性、强耦合性、多干扰、大时滞等特征使得预

分解环节的优化控制难度加大, 准确建立其出口温度预测模型有利于解决阻碍水泥生产的技术问题。面对水泥实际生产过程中的大量数据, 如何从变量众多的数据中提取有用数据是首要目标, 传统的变量选择方法遇到自变量过多的情况, 往往会导致共线性问题, 因此进行变量选择的时候可能会丢失重要因子, 从而大大降低模型的解释力度<sup>[2]</sup>。针对上

收稿日期: 2020-01-06 修回日期: 2020-02-01

基金项目: 国家自然科学基金(61673155)

第一作者: 于广宇(1995-), 男, 硕士, 研究方向为系统建模分析与控制。E-mail: whrcygy@163.com

述问题, LASSO (Least Absolute Shrinkage and Selection Operator)和 ElasticNet 方法先后被提出并被加以应用<sup>[3-4]</sup>, 二者通过在损失函数上增加不同的惩罚因子使得部分回归系数压缩为 0, 实现变量筛选。文献[5]利用 LASSO 方法在影响电力价格的众多变量中挑选出关键变量, 实现数据降维, 获得对变量选择合理见解并在此基础上建立电力价格预测模型; 文献[6]使用 ElasticNet 方法实现特征筛选, 应用于电力系统暂态稳定裕度评估。

随着深度学习算法的发展, 一些深度学习模型渐渐应用到预测模型的建立上。长短时记忆(Long Short-Term Memory, LSTM)神经网络源于循环神经网络(Recurrent Neural Network, RNN), 解决了循环神经网络在反向传播过程中存在的梯度消失和梯度爆炸问题, 解决长期依赖性。由于前馈神经网络处理时序信息的能力一般, 影响所构建模型的精度, LSTM 能对输入进行选择记忆, 在处理时序数据时表现出优异性能<sup>[7]</sup>, 被广泛用于预测模型的建立。文献[8]通过主成分分析(Principal Component Analysis, PCA)降低数据维度并输入 LSTM 建立了风电机网相互作用预测模型; 文献[9]分析了 LSTM 在时序数据分析中的优点, 将其应用在股票价格预测上。

LSTM 包含许多非线性隐含层, 相对于传统模型对特征的表达更加细致, 可应对复杂环境建模, 关于其应用在分解炉出口温度预测的研究还尚未出现。结合众多学者对分解炉出口温度预测的研究及其不足之处, 本文提出一种 ElasticNet 结合 LSTM 的分解炉出口温度预测模型。首先对水泥生产现场采集到的数据进行数据分析, 利用 ElasticNet 方法筛选相关变量, 得到不同变量的压缩系数并且论述 ElasticNet 如何实现参数寻优; 其次为建立精确的 LSTM 神经网络, 分析不同隐含层和神经元个数对模型的影响, 建立分解炉出口温度预测模型, 并进行试验仿真确定模型精度, 结果表明其精度高于未进行变量筛选和 LASSO 变量筛选的情况; 为进一

步验证该方法的有效性, 与 BP 神经网络、RBF 神经网络传统方法进行对比, 说明模型的精度要优于传统方法, 可以实现更加精确的温度预测。

## 1 方法论述

### 1.1 LASSO 与 ElasticNet

LASSO 方法由 Robert Tibshirani<sup>[10]</sup>首次提出, 该方法是一种压缩估计, 通过构造模型系数的  $L_1$  范数作为惩罚因子, 将最小二乘估计得到的较小的系数压缩为 0, 从而获得稀疏解, 实现对显著性变量进行选择 and 参数估计。

对于已有样本  $(X_i, Y_i), i=1, 2, \dots, n$ , 其中  $X_i \in R^p$  为样本的  $p$  个特征变量,  $Y_i$  为一维响应变量, 定义多元线性回归模型:

$$Y = X\beta + \varepsilon \quad (1)$$

式中:  $\beta$  为回归系数;  $\varepsilon$  为随机扰动,  $\varepsilon \sim N(0, \sigma^2)$ 。

线性回归的优化目标函数:

$$\hat{\beta} = \arg \min_{\beta} \frac{1}{2} \|Y - X\beta\|_2^2 \quad (2)$$

LASSO 方法通过在(2)中增加  $L_1$  范数, 得到:

$$\hat{\beta} = \arg \min_{\beta} \frac{1}{2} \|Y - X\beta\|_2^2 + \frac{\lambda}{2} \|\beta\|_1 \quad (3)$$

式中:  $\lambda$  为惩罚参数,  $\lambda$  的取值决定了对回归系数压缩的强弱, 能够使无关特征的系数尽可能地减小, 从而达到特征选择的目的。

LASSO 方法继承了传统方法的优点, 但是对于回归系数的选择可能会出现过度压缩的情况, 因为在很多特征相互关联的情况下, LASSO 可能只随机考虑这些特征中的一个。Zou 等<sup>[11]</sup>针对上述问题, 在 LASSO 方法的基础上引入  $L_2$  范数, 提出 ElasticNet 方法, 如式(4)所示:

$$\hat{\beta} = \arg \min_{\beta} \frac{1}{2} \|Y - X\beta\|_2^2 + \lambda \left( \alpha \|\beta\|_1 + \frac{(1-\alpha)}{2} \|\beta\|_2 \right) \quad (4)$$

通过结合  $L_1, L_2$  范数使得 ElasticNet 既保留了 LASSO 容易产生稀疏解的特性, 也结合了  $L_2$  正

则化岭回归的性质,同时解决了 LASSO 方法在多变量相关性大时产生多个解的问题,在变量选择时可以有效剔除无关变量,保留相关性大的有关变量。

## 1.2 长短时记忆神经网络(LSTM)

RNN 是一种反馈神经网络,相比于 BP, RBF 等前馈神经网络具有自反馈机制,能够将先前输入产生的影响向下传递。但是原始循环神经网络由于参数共享,在误差反向传播时,用于更新神经网络权重值的梯度存在消失或者爆炸的问题,使得模型难以学习更早的信息。LSTM 模型在 RNN 的内部增加一个长期记忆状态和多个门控单元来解决 RNN 在反向传播期间产生的梯度消失和梯度爆炸问题,使得 LSTM 可以学习长期依赖信息。LSTM 的核心概念在于细胞状态以及“门”结构,内部结构如图 1 所示。 $C_{t-1}$  和  $C_t$  分别代表细胞的旧态和新态,细胞状态相当于信息的传输路径,让信息能在序列中一直传递下去。内部包含遗忘门、输入门、输出门 3 种门结构,门的输出值都在  $[0, 1]$  之间,用于控制不同信息的通过。同一时刻,一个 LSTM 元组包含了 3 种输入,当前时刻输入  $x_t$ , 上一时刻的输出  $h_{t-1}$ , 以及上一时刻的细胞旧态  $C_{t-1}$ 。

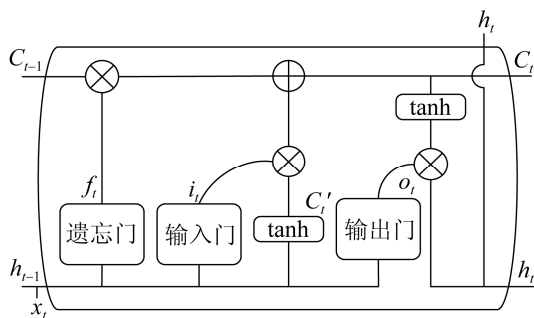


图 1 LSTM 元组内部结构  
Fig. 1 LSTM network structure

遗忘门决定细胞旧态  $C_{t-1}$  能否保存到当前的细胞新态  $C_t$  中。对于系统读取到的上一时刻输出  $h_{t-1}$  和当前时刻输入  $x_t$ , 遗忘门输出  $f_t$  为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

输入门决定当前时刻网络输入  $x_t$  能否保存到细胞新态  $C_t$ 。  $i_t$  与邻近 tanh 层的输出  $C'_t$  产生候选信息更新并且存储细胞信息,之后与细胞旧态  $C_{t-1}$  和遗忘门的输出产生新的细胞状态  $C_t$ 。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$C'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = i_t \cdot C'_t + f_t \cdot C_{t-1} \quad (8)$$

输出门决定细胞新态  $C_t$  对此时元组输出  $h_t$  的影响。输出门的输出  $o_t$  如公式(9)所示, LSTM 元组在  $t$  时刻的输出  $h_t$  如公式(10)所示。

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (10)$$

式(5)~(10)中:  $\sigma$  为 sigmoid 激活函数,  $W_f$ ,  $W_i$ ,  $W_c$ ,  $W_o$  分别表示遗忘门、输入门、细胞状态、输出门的权重矩阵,  $b_f$ ,  $b_i$ ,  $b_c$ ,  $b_o$  分别表示遗忘门、输入门、细胞状态、输出门的偏置向量。

LSTM 结构中的  $h$  相当于 RNN 结构中对短时输入敏感的部分,而  $C$  则实现长时记忆功能,各种门控单元将短时记忆与长时记忆相结合,这种机制使得 LSTM 实现信息的长期筛选与保留,有效地解决长期依赖问题。

## 2 ElasticNet-LSTM 温度预测模型

### 2.1 数据分析

仿真数据来自于水泥实际生产数据。在变量选择方面,大多数学者<sup>[12-13]</sup>围绕风(3次风)、料(生料量)、煤(喂煤量)这3个主要变量对分解炉温度展开研究。这些变量的选取方法大多来自于操作人员的人为经验,由于分解炉内部结构复杂、变量众多,单单依靠人为经验法选取变量难以全面概括分解炉系统的内部规律,本文结合分解炉结构与工况,选取了包含生料喂料量、分解炉喂煤量、高温风机转速和阀门开度在内的21个变量用以对分解炉出口温度进行分析,并选用 ElasticNet 方法对21个变量进行参数估计,用以筛选相关变量。

## 2.2 ElasticNet 参数确定与变量选择

ElasticNet 方法筛选变量的关键在于如何选取  $\alpha$  和  $\lambda$ , 对于式(4), 当  $\alpha$  取值为 1 时, 此时就变为 LASSO 方法。

采用  $K$  折交叉验证误差最小来确定模型参数。在数据预处理时, 通常将数据分为训练集和测试集,  $K$  折交叉验证在样本数据数量有限的情况下可以充分利用训练集, 将训练集随机划分为  $K$  个集合, 每次交叉验证时, 选择 1 个集合作为验证集测试模型误差, 其余  $K-1$  个集合作为训练集训练模型。

在取值[0.01~0.99]范围内, 步长越小, 计算精度越高, 计算时间越长<sup>[14]</sup>。以 0.01 为步长, 采用 10 折交叉验证平均误差最小进行参数寻优。取  $\alpha=0.99$  时的验证过程作为介绍。首先将训练集随机划分为 10 个子集, 每次选择 1 个子集作为测试集, 其余的 9 个子集作为训练集, 交叉 10 次, 使得每个子集都做 1 次测试集, 计算不同  $\lambda$  取值下交叉验证的平均误差, 取误差最小时的  $\lambda$  作为此时  $\alpha$  的匹配值。图 2 为  $\alpha=0.99$  时交叉验证误差随  $\lambda$  变化的关系曲线。当  $\lambda=0.037 64$  时交叉验证误差最小, 最小误差为 15.573。




图 2 交叉验证误差随  $\lambda$  变化关系曲线  
Fig. 2 Cross-validation error curve

按照上述方法计算所有  $(\alpha, \lambda)$ , 以交叉验证误差最小原则得到最优的  $\alpha=0.84$ , 此时对应的  $\lambda=$

0.041 32, 最小误差为 15.570。用确定参数的 Elastic Net 方法对 21 个变量进行筛选和参数估计, 得到各个变量的压缩系数见表 1 所列。

表 1 各个变量的压缩系数

Tab. 1 Compression coefficients of various variables			
参数变量	压缩系数	参数变量	压缩系数
窑头温度	1.131	风机转速	0
窑头压力	1.074	窑速	0
炉出口压力	0.312	风机开度	-0.131
烟室压力	0.246	三次风压	-0.173
混合室温度	0.231	三次风温	-0.214
出口气体 O <sub>2</sub> 含量	0.231	出口气体 CO 含量	0
废气温度	0.168	炉喂煤量	-1.008
窑喂煤量	0.052	混合室压力	-1.342
二次风温	0	窑进料量	-1.567
出口气体	0	旋涡分解室	-4.327
NO 含量	0	温度	
烟室温度	-0.421		

## 2.3 模型整体流程

ElasticNet-LSTM 模型的整体流程如图 3 所示。

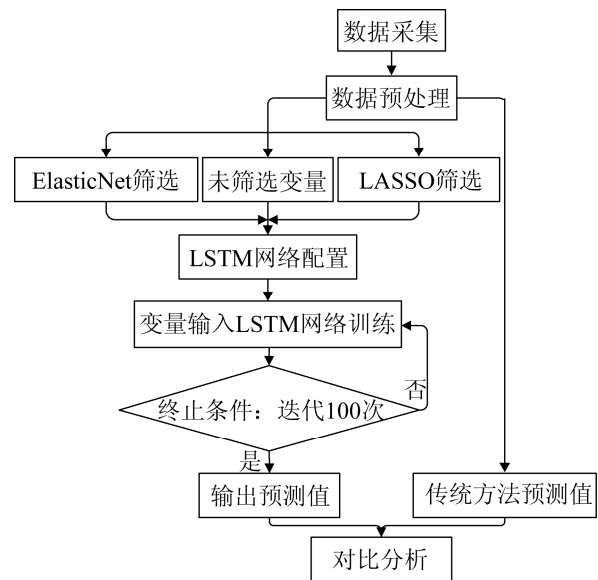


图 3 ElasticNet-LSTM 模型的整体流程图  
Fig. 3 Overall flowchart of the ElasticNet-LSTM model

## 3 算例分析

### 3.1 实验设计

仿真实验采用安徽某公司 6 000 t/d 水泥生产

线 2014 年 6 月的生产数据, 利用所测得的 1 278 组数据进行分析预测, 其中 1 100 组作为训练集, 178 组作为测试集。由于数据包含温度、压强等不同量纲的变量, 需要将输入变量做归一化处理, 如式(11)所示。

$$\tilde{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

为验证 ElasticNet-LSTM 分解炉出口温度预测模型的准确性, 将经过归一化和 ElasticNet 变量筛选得到的数据作为 LSTM 网络的输入量, 得到预测结果与真实值进行对比, 同时引入 BP 神经网络、RBF 神经网络传统方法的预测结果, 通过对比不同的算法在分解炉出口温度预测的精度, 来验证 ElasticNet-LSTM 模型的有效性。选取平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)和均方根误差(Root Mean Square Error, RMSE)作为评价指标对模型的预测效果进行定量分析。如式(12), (13)所示。

$$MAPE = \frac{1}{n} \sum_{t=1}^n |(y_a(t) - y_p(t)) / y_a(t)| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_a(t) - y_p(t))^2} \quad (13)$$

式中:  $n$  为测试样本数;  $y_a(t)$ 、 $y_p(t)$  分别为  $t$  时刻测试样本实际值和模型预测值。

### 3.2 LSTM 网络分析

建立预测分解炉出口温度的 LSTM 模型需要确定输入单元数、输入数据时间步数、隐含层层数、隐含层神经元个数以及输出单元数 5 个参数。输入、输出单元数根据筛选变量以及预测目标分别确定为 16 维和 1 维。隐含层以及神经元的数目决定了神经网络训练时间以及预测精度, 实际使用时, 其数量并非越多越好, 过多的隐含层和神经元个数会加大模型复杂度, 增加训练时间, 预测精度也不会提高。为选择最佳隐含层和神经元数目, 设计 1, 2, 3, 4 层隐含层, 内部包含 50, 100, 150, 200 个神经元的 LSTM 网络, 不同隐含层及

神经元数目对模型的影响见表 2 所列。

表 2 不同隐含层和神经元数目的预测结果误差  
Tab. 2 Errors in prediction results of different hidden layers and the number of neurons

隐含层	神经元数目			
	50	100	150	200
1	1.889	1.885	1.861	2.087
2	1.761	1.842	1.906	2.133
3	1.721	1.708	1.944	1.929
4	2.018	2.099	2.115	2.047

由表 2 可以看出, LSTM 网络包含 3 层隐含层, 每层内含 100 个神经元时的预测结果误差最小, 增加或减小隐含层层数和神经元个数都会使模型的预测结果误差增大, 因此选择 3 层隐含层, 每层内含 100 个神经元的 LSTM 网络。

### 3.3 实验结果分析

利用 3.2 节 ElasticNet 得到的变量筛选结果, 时间步数设置为 4, 神经网络的优化算法选择随机梯度下降的 Adam 函数, 得到不同方法处理变量的预测值与真实值的变化趋势如图 4 所示, 部分预测结果见表 3 所列。

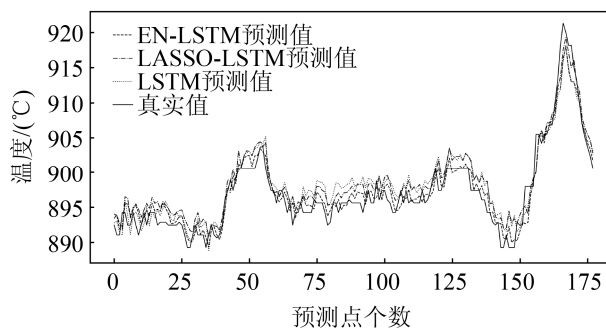


图 4 不同方法处理变量预测结果  
Fig. 4 Variable prediction results of different methods

由图 4 可以看出, 3 种模型在真实温度波动较大的情况下都可以实现较好的预测, 其中 ElasticNet-LSTM 模型的预测结果最接近真实值, 而未进行变量筛选和 LASSO 方法的预测结果则相对较差, 尤其在预测曲线前部和中部均有较大的差值。统计得到 ElasticNet-LSTM 模型的预测差值有



83.1%在 2 °C 区间以内, 有 3.4%高于 4 °C 区间, 最大差值为-6.13 °C, LSTM 和 LASSO-LSTM 模型则分别为 55.4%, 7.9%, -5.52 °C 和 58.4%, 5.1%, -6.25 °C。表 3 列出不同模型在数据中部(85~94 点)的预测情况, 从预测误差上看, ElasticNet-LSTM 模型的 MAPE 和 RMSE 最小, 虽然最大温差略高

于 LASSO 方法, 但总体上结果最优。为充分验证 ElasticNet-LSTM 分解炉出口温度预测模型的准确性, 引入 BP 神经网络、RBF 神经网络传统方法进行对比。模型的平均绝对百分比误差 MAPE 和均方根误差 RMSE 对比见表 4 所列。温度预测曲线如图 5 所示。

表 3 不同预测方法部分结果比较

Tab. 3 Comparison of some results of different prediction methods

预测点	真实值	LSTM		LASSO-LSTM		ElasticNet-LSTM	
		预测值	差值	预测值	差值	预测值	差值
85	895.601	897.709	2.108	896.299	0.698	894.630	-0.971
86	895.601	897.710	2.108	897.031	1.430	895.266	-0.335
87	895.601	898.224	2.623	897.064	1.463	895.209	-0.392
88	896.022	898.357	2.335	897.446	1.424	896.457	0.435
89	895.601	899.195	3.594	897.954	2.353	896.986	1.385
90	895.601	897.913	2.312	897.186	1.585	896.232	0.631
91	895.601	898.302	2.701	898.292	2.691	897.146	1.545
92	895.601	898.173	2.572	898.187	2.586	896.993	1.392
93	894.228	899.324	5.096	898.237	4.009	896.924	2.696
94	896.022	897.759	1.737	896.455	0.433	895.414	-0.608
MAPE		0.216		0.206		0.146	
RMSE		2.348		2.190		1.708	

表 4 预测结果误差对比

Tab. 4 Error comparison of prediction results

预测方法	MAPE	RMSE
BP	0.311	3.733
RBF	0.407	4.463
ElasticNet-LSTM	0.146	1.708

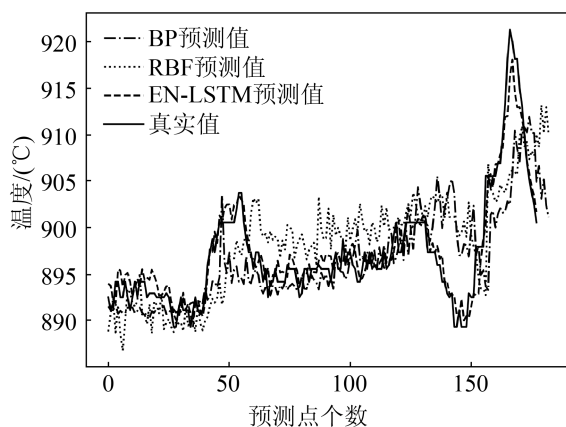


图 5 对比方法温度差值曲线

Fig. 5 Temperature difference curve of comparison method

图 5 所示的传统方法预测值都没有很好地拟合实际曲线, BP 神经网络在数据中部预测良好, 但是在第 1 温峰(35~65 点)和温谷(125~150 点)分别出现了预测温度提前上升和滞后下降的情况, 最大预测差值达到 13.0 °C, 而 RBF 神经网络在第 1 温峰表现良好, 但在数据中部和温谷预测温度均偏高, 最大预测差值为 13.4 °C, 而 2 种方法在第 2 温峰(160~175 点)预测值均远小于实际温度。由表 4 可以看出预测误差最小的是 ElasticNet-LSTM 模型, 其次是 BP 神经网络, RBF 神经网络预测误差最大。相比于 BP, RBF 神经网络, LSTM 神经网络内部的门控单元和长期记忆状态使得模型能够长时间学习和保留历史数据中有效信息, 有利于解决分解炉大时滞等特性所带来的影响, 所提出的方法可以更精确地预测水泥分解炉出口温度。



## 4 结论

(1) 基于 ElasticNet-LSTM 的水泥分解炉出口温度预测模型, 在传统风、煤、料的基础上充分考虑影响出口温度的指标, 利用 ElasticNet 进行变量筛选, 保留相关变量同时降低数据维度, 并且分析论述 ElasticNet 如何进行参数寻优以达到筛选最佳变量的目的。

(2) 为建立精确的 LSTM 神经网络, 针对实验算例数据, 分析说明 LSTM 神经网络不同隐含层数和神经元个数对预测的影响。筛选变量分析预测结果, 得到 ElasticNet-LSTM 预测效果最好, LASSO 其次, 未进行变量筛选最差。

(3) 与 BP 神经网络、RBF 神经网络方法进行对比, ElasticNet-LSTM 模型得到的预测值更加接近真实值, 预测结果可以准确跟随真实温度变化趋势, 拥有更小的预测误差, 充分说明所提出的方法可以更精确地预测分解炉出口温度。

### 参考文献:

[1] 赵彦涛, 陈宇, 陈英豪, 等. 基于 BFCM-iWM 模糊规则自提取的水泥分解炉温度控制[J]. 控制与决策, 2019, 34(2): 383-389.  
Zhao Yantao, Chen Yu, Chen Yinghao, et al. Temperature Control of Cement Decomposing Furnace Based on BFCM-iWM Fuzzy Rules Extraction[J]. Control and Decision, 2019, 34(2): 383-389.

[2] 何耀耀, 秦杨, 杨善林. 基于 LASSO 分位数回归的中期电力负荷概率密度预测方法[J]. 系统工程理论与实践, 2019, 39(7): 1845-1854.  
He Yaoyao, Qin Yang, Yang Shanlin. Medium-Term Power Load Probability Density Forecasting Method based on LASSO Quantile Regression[J]. Systems Engineering- Theory & Practice, 2019, 39(7): 1845-1854.

[3] 王宏伟, 黄元生, 姜雨晴, 等. 基于套索算法和高斯过程回归的中长期居民用电量概率预测[J]. 华北电力大学学报, 2019, 46(6): 27-35.  
Wang Hongwei, Huang Yuansheng, Jiang Yuqing, et al. Residential Probabilistic Load Forecasting based on LASSO-Gaussian Process Regression[J]. Journal of North China Electric Power University, 2019, 46(6):

27-35.

[4] 王沛立, 李恩平. 我国居民医疗负担及其影响因素分析-基于弹性网方法的实证研究[J]. 数学的实践与认识, 2019, 49(14): 97-107.  
Wang Peili, Li Enping. Analysis of Medical Burden Influencing Factors-An of Chinese Residents and Its Empirical Study Based on Elastic Network Method[J]. Mathematics in Practice and Theory, 2019, 49(14): 97-107.

[5] Bartosz U, Grzegorz M. Understanding Intraday Electricity Markets: Variable Selection and Very Short-term Price Forecasting Using LASSO[J]. International Journal of Forecasting (S0169-2070), 2019, 35(4): 1533-1547.

[6] 宓登凯, 王彤, 相禹维, 等. 基于 ElasticNet 的暂态稳定裕度在线评估[J]. 电网技术, 2019, 44(1): 19-26.  
Mi Dengkai, Wang Tong, Xiang Yuwei, et al. Elastic Net based Online Assessment of Power System Transient Stability Margin[J]. Power System Technology, 2019, 44(1): 19-26.

[7] 唐振浩, 赵赓楠, 曹生现, 等. 基于 SWLSTM 算法的超短期风向预测[J]. 中国电机工程学报, 2019, 39(15): 4459-4467.  
Tang Zhenhao, Zhao Gengnan, Cao Shengxian, et al. Very Short-Term Wind Direction Prediction Via Self-tuning Wavelet Long-Short Term Memory Neural Network[J]. Proceedings of the CESS, 2019, 39(15): 4459-4467.

[8] 王伊宁, 解大, 王西田, 等. 基于 PCA-LSTM 模型的风电机网相互作用预测[J]. 中国电机工程学报, 2019, 39(14): 4070-4080.  
Wang Yining, Xie Da, Wang Xitian, et al. Prediction of Interaction Between Grid and Wind Farms Based on PCA-LSTM Model[J]. Proceedings of the CESS, 2019, 39(14): 4070-4080.

[9] 宋刚, 张云峰, 包芳勋, 等. 基于粒子群优化 LSTM 的股票预测模型[J]. 北京航空航天大学学报, 2019, 45(12): 2533-2542.  
Song Gang, Zhang Yunfeng, Bao Fangxun, et al. Stock Prediction Model based on Particle Swarm Optimization LSTM[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(12): 2533-2542.

[10] Tibshirani R. Regression Shrinkage and Selection via the Lasso[J]. Journal of the Royal Statistical Society Series B-Statistical Methodology (S1467-9868), 1996, 58(1): 267-288.

[11] Zou H, Hastie T. Regularization and Variable Selection

- Via the Elastic Net[J]. Journal of the Royal Statistical Society Series B-Statistical Methodology (S1467-9868), 2005, 67(2): 301-320.
- [12] Song Q Y, Yuan Z G. Working Condition Recognition of Cement Decomposition Furnace Based on ART-2 Neural Network[C]// Sixth International Conference on Measuring Technology and Mechatronics Automation. Zhangjiajie, China: IEEE, 2014: 807-812.
- [13] Li S W, Li B, Li C R. The Study of Temperature Control of Cement Decomposition Furnace on the Basis of Fuzzy Immune Self-Adaptive PID Control Method[C]// Third International Conference on Information Science and Technology. Yangzhou, China: IEEE, 2013: 86-90.
- [14] Liu W, Dou Z H, Wang W G. Short-Term Load Forecasting Based on Elastic Net Improved GMDH and Difference Degree Weighting Optimization[J]. Applied Sciences (S2076-3417), 2018, 8(9): 1603.