

DOI:10.3969/j.issn.1003-5060.2023.02.005

基于 KPCA 和 BiLSTM 的分解炉出口温度预测

孟 忍¹, 董学平¹, 甘 敏²

(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:水泥生产过程中,分解炉出口温度是非常重要的工艺参数,为了应对出口温度变量的多样性,文章提出一种核主成分分析(kernel principal component analysis,KPCA)与双向长短期记忆(bidirectional long short-term memory,BiLSTM)神经网络相结合的温度预测组合模型用来预测分解炉的出口温度。通过 KPCA 筛选出影响因素的主成分从而达到数据降维目的,将降维后的主成分作为 BiLSTM 神经网络的输入,分解炉出口温度作为 BiLSTM 神经网络的输出。经 BiLSTM 神经网络训练,得到分解炉出口温度预测模型。通过对比验证表明,使用 KPCA-BiLSTM 相结合的温度预测模型具有较好的预测精度。

关键词:水泥分解炉;出口温度;核主成分分析(KPCA);双向长短期记忆(BiLSTM)神经网络;降维;预测
中图分类号:TP183 **文献标志码:**A **文章编号:**1003-5060(2023)02-0169-06

Prediction of calciner outlet temperature based on KPCA and BiLSTM

MENG Ren¹, DONG Xueping¹, GAN Min²

(1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009, China; 2. School of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108, China)

Abstract:In the cement production process, the outlet temperature of the calciner is a very important process parameter. In order to cope with the diversity of outlet temperature variables, this paper proposes a combined model of temperature prediction using kernel principal component analysis(KPCA) and bidirectional long short-term memory(BiLSTM) neural network to predict the outlet temperature of the calciner. Through the KPCA, the main components that affect the temperature variables at the outlet of the calciner are selected to achieve the data dimensionality reduction. The reduced main components are used as the input of BiLSTM, and the temperature at the outlet of the calciner is used as the output of BiLSTM. After BiLSTM neural network training, the outlet temperature prediction model of the calciner is obtained. The comparison and verification show that the temperature prediction model with KPCA-BiLSTM has better prediction accuracy.

Key words:cement calciner; outlet temperature; kernel principal component analysis(KPCA); bidirectional long short-term memory(BiLSTM) neural network; dimensionality reduction; prediction

0 引 言

水泥工业是我国经济建设的重要基础材料产业。因为分解炉运行状况的关键性能指标是分解炉出口温度,所以对分解炉出口温度的研究

具有重要意义^[1]。近年来,有很多学者对分解炉出口温度的预测方法进行研究。文献[2]提出一种出口温度预测模型基于遗传算法优化 BP 神经网络的方法,进行实验并验证其效果;文献[3]提出一种基于递推最小二乘和 ARMAX 的分解炉

收稿日期:2021-01-11;修回日期:2021-03-10

基金项目:国家自然科学基金资助项目(61673155)

作者简介:孟 忍(1991—),男,安徽淮北人,合肥工业大学硕士生;

董学平(1965—),男,安徽舒城人,博士,合肥工业大学副教授,硕士生导师,通信作者,E-mail:hfdxp@126.com;

甘 敏(1982—),男,湖北武汉人,博士,福州大学教授,博士生导师。

温度预测模型。上述 2 种方法使用传统神经网络的方法对分解炉出口温度进行预测,因为不具备从过去和将来的数据中学习信息的能力,所以影响分解炉出口温度的预测精度。

上述研究都只在其风、料、煤等主要传统经验的基础上进行研究,具有很大的局限性。因此将数据筛选方法与神经网络算法相结合的方法,能够较为准确地把握分解炉出口温度特性。文献[4]将核主成分分析(kernel principal component analysis, KPCA)非线性降维应用于财务危机预警模型的建立,并进行实验验证其效果,表明 KPCA 在处理非线性数据方面具有较好的能力;因此文献[5]应用注意力机制的长短期记忆(long short-term memory, LSTM)神经网络建立 PM_{2.5} 预测模型的方法,并验证其效果;文献[6]应用双向长短期记忆(bidirectional long short-term memory, BiLSTM)神经网络构建刹车片寿命预测模型,通过对比实验验证了模型的优越性。上述方法均体现了神经网络的优越性,但是由于分解炉出口温度具有非线性、多干扰、大时滞等特性,仅把神经网络的方法运用于分解炉出口温度的预测方面,忽略了出口温度变化的非线性特征,影响了预测精度。

本文提出一种基于 KPCA 结合 BiLSTM 的分解炉出口温度预测模型。引入 KPCA 可有效地提取变量的非线性特征,筛选出包含主要信息的主成分,降低影响因素的变量维度;然后将降维所得的主元作为 BiLSTM 神经网络的输入,通过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,并进行实验确定模型精度,从而完成对出口温度的预测。通过仿真实验证明,基于 KPCA-BiLSTM 的分解炉出口温度预测模型具有良好的预测精度。

1 理论分析

1.1 核主成分分析法

模式识别中线性特征的提取和数据表示一般用主成分分析(principal component analysis, PCA),当训练数据集中的样本数量相对少时,较难获得准确的协方差矩阵,并且通常用于非线性数据处理时无法获得最佳的预期效果^[7]。作为减少非线性特征维数的算法,KPCA 使用核的思想以线性方式将非线性样本空间映射到高维特征空间,然后进行线性降维。在解决提取非线性特征的问题方面,KPCA 具有比 PCA 更好的效果,利

用核函数可以有效地保留原始数据的特征,并最大限度地提取数据中包含的非线性信息^[8]。KPCA 具有以下特点:原始数据通过非线性映射函数映射到高维空间,并且空间中的所有样本都可以线性表示空间中的任何向量。

PCA 是一种线性主成分分析方法,对于原始数据构成的矩阵,首先进行标准化处理得到新的样本集 $\mathbf{x}_k (k=1, 2, 3, \dots, m; \mathbf{x}_k \in \mathbf{R}^n)$,再对新的样本集计算其协方差矩阵,即

$$\mathbf{C} = \frac{1}{m} \sum_{j=1}^m \mathbf{x}_j \mathbf{x}_j^T \quad (1)$$

然后求得矩阵 \mathbf{C} 的特征值和特征向量。

KPCA 是 PCA 的非线性间接扩展^[9]。KPCA 首先对样本 \mathbf{x}_k 进行非线性变换 $\phi(\mathbf{x}_k)$,将其映射到高维特征空间 \mathbf{F} ,此时协方差矩阵为:

$$\mathbf{C} = \frac{1}{m} \sum_{j=1}^m \phi(\mathbf{x}_j) \phi(\mathbf{x}_j)^T \quad (2)$$

上述矩阵的特征值 λ 和特征向量 \mathbf{V} 满足以下条件:

$$\lambda \mathbf{V} - \mathbf{C} \mathbf{V} = \mathbf{0} \quad (3)$$

引入非线性函数 $\phi(\mathbf{x}_k)$,可得:

$$\lambda \phi(\mathbf{x}_k) \mathbf{V} - \phi(\mathbf{x}_k) \mathbf{C} \mathbf{V} = \mathbf{0} \quad (4)$$

(4)式中的特征向量 \mathbf{V} 可由 $\phi(\mathbf{x}_i)$ 线性表示,即

$$\mathbf{V} = \sum_{i=1}^m \alpha_i \phi(\mathbf{x}_i) \quad (5)$$

将(2)式、(4)式代入(3)式,并引入核函数 $\mathbf{K}_{ij} = \mathbf{K}(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) \phi(\mathbf{x}_j)$,简化后得:

$$m \lambda \boldsymbol{\alpha} - \mathbf{K} \boldsymbol{\alpha} = \mathbf{0} \quad (6)$$

其中, $\boldsymbol{\alpha}$ 为核矩阵 \mathbf{K} 的特征向量。对于任意样本,在特征空间 \mathbf{F} 中主元 $\phi(\mathbf{x})$ 上的投影为:

$$\mathbf{V} \phi(\mathbf{x}) = \sum_{i=1}^m \alpha_i \phi(\mathbf{x}_i) \phi(\mathbf{x}) = \sum_{i=1}^m \alpha_i \mathbf{K}(\mathbf{x}_i, \mathbf{x}) \quad (7)$$

一般情况下,选择累计贡献率在 90% 以上的主元即满足 $\sum_{k=1}^s \lambda_k / \sum_{k=1}^m \lambda_k$ 大于或等于 90%,其中 s 为满足条件的主元数量。

以上过程是在 $\sum_{i=1}^m \phi(\mathbf{x}_i) = \mathbf{0}$ 的假设条件下进行推导的,若不满足此假设,则(5)式中的 \mathbf{K} 替换为 $\tilde{\mathbf{K}}$,即

$$\tilde{\mathbf{K}} = \mathbf{K} - \mathbf{L} \mathbf{K} - \mathbf{K} \mathbf{L} + \mathbf{L} \mathbf{K} \mathbf{L} \quad (8)$$

其中: \mathbf{L} 为 $m \times m$ 阶单位矩阵,其系数为 $1/m$ 。

1.2 双向长短期记忆神经网络

LSTM 是目前应用比较广泛,并得到高度认可的神经网络,它可以克服循环神经网络(recur-

rent neural network, RNN) 中梯度消失的问题^[10]。因为其具有独特的设计结构,所以 LSTM 适合处理和预测时间间隔长且时间序列延迟的重要事件。LSTM 的单元结构由 4 个部分组成,每个部分之间存在交互,分别为遗忘门、输入门、信息更新和输出门,LSTM 内部结构如图 1 所示。




图 1 LSTM 内部结构

LSTM 内部结构的第 1 部分为遗忘门,如图 1 中①所示,即通过 sigmoid 函数从上一个时刻的输出和本时刻的输入值中丢弃部分信息,其表达式为:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

第 2 部分为输入门,如图 1 中②所示,该部分的功能是确定需要更新哪些信息,并通过 sigmoid 和 tanh 函数进行过滤,需要更新的信息表达式如下。

经过 σ 函数过滤后可得:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (10)$$

经过 tanh 函数过滤后可得:

$$C'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (11)$$

第 3 部分为信息更新,如图 1 中③所示,它将遗忘门和上一时间点的信息更新值相乘并与输出门的 2 个值的乘积相加,细胞状态的更新公式为:

$$C_t = f_t C_{t-1} + i_t C'_t \quad (12)$$

第 4 部分为输出门,如图 1 中④所示,该输出值是基于以上的 3 个步骤。首先利用 sigmoid 函数选择部分输入门的信息;然后利用 tanh 函数功能用于选择和过滤更新后的信息;最后将 2 个选定的信息相乘以获得此时的细胞输出值,其表达式如下。

经过 σ 函数过滤后可得:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (13)$$

$$h_t = o_t \tanh(C_t) \quad (14)$$

其中: σ 为 sigmoid 激活函数; x_t 为时刻 t 的输入值; h_{t-1} 为 $t-1$ 时刻的输出值; C_t 为细胞信息更新值; W_c 、 W_i 、 W_o 、 W_f 分别为细胞状态、输入门、输

出门和遗忘门; b_c 、 b_i 、 b_o 、 b_f 分别为细胞状态、输入门、输出门、遗忘门的偏置值。

本文选取神经网络中常用的 sigmoid 函数作为 σ 函数,其表达式为:

$$s(x) = 1/(1 + e^{-x}) \quad (15)$$

LSTM 具有以非常长的时间间隔和时间序列中的延时来处理 and 预测大型事件的特征,但是它只能根据过去的的数据预测信息,BiLSTM 具有能够从过去和将来的数据中学习信息的能力,BiLSTM 的结构示意图如图 2 所示,图 2 从上到下依次为输入层、前向层、后向层和输出层,BiLSTM 的基本思想是每个学习序列分别作为长短期记忆神经网络的向前和向后的 2 个神经网络,并且这 2 个层分别连接到输入层和输出层。输出值整合了过去(前向)和未来(反向)的信息,分析了不同隐含层和神经元数量对模型的影响,建立了分解炉出口温度预测模型,并进行仿真实验以确定模型的准确性。

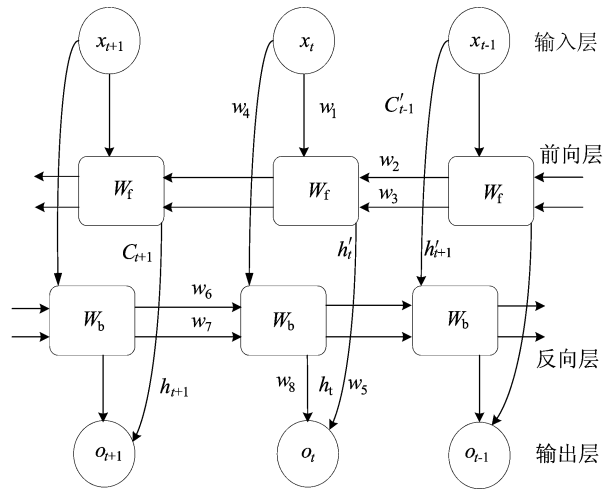


图 2 BiLSTM 神经网络结构

在 BiLSTM 中的每一个时间点都有 8 个唯一的权重值被重复使用,并且每个值对应的 8 个权重值在前隐藏层和后隐藏层中,输入的权重值(w_1, w_4)前向隐藏层到前向隐藏层(w_2, w_3)、后向隐藏层到后向隐藏层(w_6, w_7)、前向隐藏层和后向隐藏层到输出层(w_5, w_8)。尤其要注意的是前向隐藏层和后向隐藏层之间没有进行信息传递,这样可以避免 2 个隐藏层的相邻 2 个时间点之间形成死循环。其计算方式为:在前向层从 1 时刻到 t 时刻正向计算 1 次,得到并保存每个时间点向前隐藏层的输出;在后向层沿着时刻 t 到时刻 1 反向计算 1 次,得到并保存每个时间点后

隐藏层的输出;最后在每个时间点结合前向层和后向层的相应时刻输出的结果得到最终的输出,数学表达式为:

$$h_t' = f(w_1x_t + w_2C_{t-1}' + w_3h_{t-1}') \quad (16)$$

$$h_t = f(w_4x_t + w_5C_{t-1} + w_6h_{t-1}) \quad (17)$$

$$o_t = g(w_7h_t' + w_8h_t) \quad (18)$$

2 基于 KPCA-BiLSTM 温度预测模型

模拟数据取自于实际生产的水泥数据。在变量选择方面,大多数研究者^[11-12]围绕三次风温、分解炉喂料量、分解炉喂煤量这 3 个主要变量对分解炉出口温度进行研究。因为分解炉内部结构复杂且变量众多,所以难以依靠经验法选取变量来全面概括分解炉的内部规律。结合分解炉结构与工况,选取包含分解炉喂料量、分解炉喂煤量、三次风压和出口压力等在内的 22 个变量用来对分解炉出口温度进行分析,并选用 KPCA 数据降维的方法对 22 个变量进行参数估计,用来筛选相关变量。

2.1 KPCA 自变量降维处理

KPCA 进行自变量的降维,使用 Python 编程实现,下面对其关键步骤进行说明。

(1) 数据预处理。首先对数据进行标准化,处理后均值为 0,方差为 1。

(2) 采用高斯径向基核函数,求核矩阵。高斯径向基核函数为:

$$K(\|x - x_c\|) = \exp\left[-\frac{\|x - x_c\|^2}{(2\sigma)^2}\right] \quad (19)$$

其中: x 为空间中任一点; x_c 为核函数中心; σ 为函数的宽度参数,控制函数的径向作用范围。

(3) 对矩阵进行中心化,得到一个新的矩阵。

(4) 特征值分解。找到协方差矩阵的特征向量和特征值,将对角线矩阵与主对角线上的特征值转换为特征值的列向量,并按降序排列特征值。

(5) 对主元的贡献率进行确定。计算每个特征值的贡献率以及累计贡献率,并将主元所在特征值向量中的序号记录下来,同时保存主元序号以及主元的个数。

(6) 计算每个主元向量以及各主元所对应的特征向量,并构建主元矩阵。经过 KPCA 降维处理之后,分解炉出口温度的影响因素由 22 维降至 4 维,累计贡献率达到 90% 以上。KPCA 对前 4 个主成分的单个贡献率及累计贡献率见表 1

所列。

表 1 KPCA 对 22 个影响因素的处理结果 %

主元序号	贡献率	累计贡献率
1	49.869	49.869
2	22.742	72.611
3	14.038	86.649
4	4.420	91.069

为了更好地验证 KPCA 在数据筛选方面的优越性,引入用 PCA 数据筛选方法处理主成分的单个贡献率及累计贡献率,见表 2 所列。

表 2 PCA 对 22 个影响因素的处理结果 %

主元序号	贡献率	累计贡献率
1	41.632	41.632
2	27.813	69.445
3	11.241	80.686
4	3.940	84.626

因为分解炉出口温度具有非线性、强耦合性、多干扰、大时滞等特征,所以 PCA 只能进行线性变化,在非线性数据处理时往往得不到较好的期望效果;而 KPCA 可以进行非线性变化,能将原数据通过引入隐性非线性映射函数映射到高维空间,然后对此空间执行算法进行线性降维,对数据的筛选效果更好。实验结果表明,KPCA 对主成分的累计贡献率要高于 PCA。

2.2 KPCA-BiLSTM 模型整体流程

为了得到精确的预测结果,使用 KPCA 数据降维与 BiLSTM 神经网络相结合的方法,从而给出 KPCA-BiLSTM 的组合模型。KPCA-BiLSTM 组合模型的整体流程如图 3 所示。

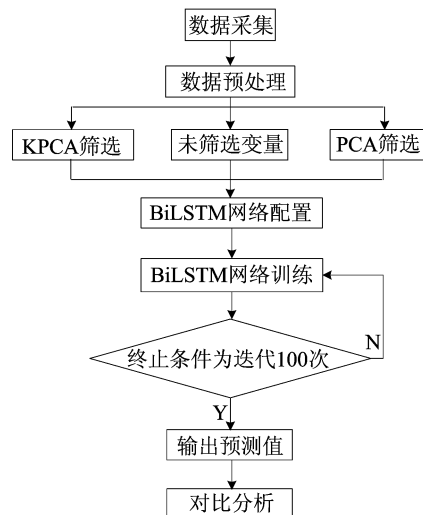


图 3 KPCA-BiLSTM 模型的整体流程

3 算例分析

3.1 实验设计

仿真实验采用某公司 6 000 t/d 水泥生产线的生产数据,利用所测得的 1 100 组数据进行分析预测,其中:900 组作为训练集;200 组作为测试集。由于数据包含温度、压强等不同量纲的变量,需要将输入变量进行归一化处理,计算公式为:

$$\tilde{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

为进一步验证 KPCA-BiLSTM 分解炉出口温度预测模型的准确性,将经过归一化处理和 KPCA 筛选后得到的数据作为 BiLSTM 神经网络的输入,将得到的预测值与真实值进行对比,通过对比不同的神经网络算法在分解炉出口温度预测的精度,来验证 KPCA-BiLSTM 模型的有效性。为进一步验证模型的准确性,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精度进行定量分析。计算公式为:

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{t=1}^n |y_t - y_p| / y_t \quad (21)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - y_p)^2} \quad (22)$$

其中: n 为测试样本数; y_t 为测试样本实际值; y_p 为模型预测值。

3.2 组合预测模型在分解炉温度预测中的实现

选取 1 100 组数据,选取其中 200 组作为测试集,利用前文 2.1 节 KPCA 得到的降维结果作为神经网络的输入,将 BiLSTM 的时间步数设置为 3,优化算法选择随机梯度下降的 Adam 函数,得到预测值与真实值的变化趋势如图 4 所示。从图 4 可以看出,KPCA-BiLSTM 模型在真实温度波动较大的情况下仍可以实现较好的预测,预测结果最接近真实值。同时在 40~60、80~140、125~150 温度波动范围较大的预测点和在 25~50 温度变化较快的预测点范围内,使用 KPCA-BiLSTM 模型也能实现较好的预测效果。

为了更全面地评价模型的有效性与优越性,分别引入不进行数据降维的 BiLSTM 模型,以及用 PCA 和 KPCA 进行数据降维后的 KPCA-LSTM 组合模型,PCA-BiLSTM 组合模型与 KPCA-BiLSTM 组合模型进行对比,最终预测值和真实值的 MAPE 和 RMSE 对比结果见表 3

所列。

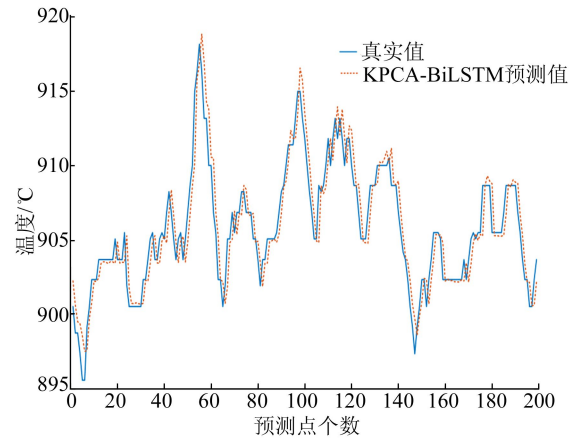


图 4 KPCA-BiLSTM 组合模型拟合曲线

表 3 预测结果误差对比

预测模型	MAPE	RMSE
BiLSTM	0.322	3.044
KPCA-LSTM	0.196	1.906
PCA-BiLSTM	0.139	1.537
KPCA-BiLSTM	0.125	1.469

从表 3 可以看出,KPCA-BiLSTM 组合模型具有最好的预测性能。相较于 PCA-BiLSTM 模型,KPCA-BiLSTM 模型的 MAPE 降低了 0.014, RMSE 降低了 0.068;相较于 KPCA-LSTM 模型,KPCA-BiLSTM 模型的 MAPE 降低了 0.071, RMSE 降低了 0.437;相较于 BiLSTM 模型,KPCA-BiLSTM 模型的 MAPE 降低了 0.197, RMSE 降低了 1.575。因此,本文提出的预测模型是可行的。

使用不同预测模型处理变量的预测结果如图 5 所示。

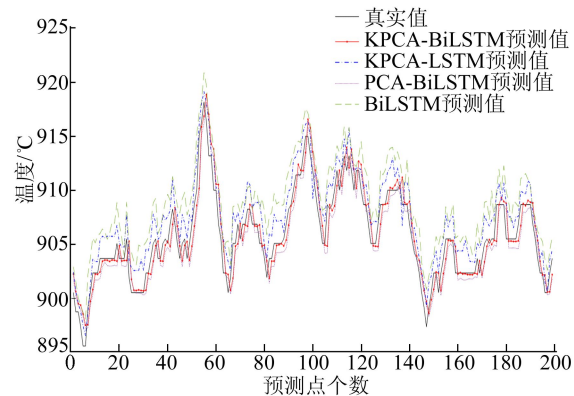


图 5 不同预测模型下的预测值与真实值

从图 5 可以看出,仅使用 BiLSTM 神经网络

预测的结果整体上与实际值偏差较大,尤其是在温度剧烈变化的预测点处,预测结果均大于真实值。使用 KPCA-LSTM 组合预测模型,因为 LSTM 只具备处理和预测时间序列中间隔和延迟比较长的事件,不具备利用过去和未来数据的信息进行学习的能力,所以在经过 KPCA 降维处理后,预测效果会有提前上升和滞后下降的过程。对比 PCA-BiLSTM 模型和 KPCA-BiLSTM 模型,因为 BiLSTM 具有对过去和未来信息学习的能力,所以相比较而言都有较好的预测精度。因为 PCA 只能进行线性变化,在非线性数据处理时往往得不到较好的期望效果,而 KPCA 可以进行非线性变化,所以能将原数据通过引入隐性非线性映射函数映射到高维空间,然后对此空间执行算法进行线性降维,对数据的筛选效果更好。从图 5 还可以看出,KPCA-BiLSTM 模型的拟合效果更优于 PCA-BiLSTM 模型的拟合效果。由此可见,基于 KPCA-BiLSTM 模型的分解炉温度预测不仅在总体上提高了分解炉温度预测的精度,而且在各个预测点的值与真实值的差值相对较小。

4 结 论

由于分解炉出口温度具有非线性、强耦合性、多干扰、大时滞等特征,因此本文提出了使用 KPCA 进行变量筛选从而降低影响分解炉出口温度数据的维度,在此基础上引入 BiLSTM 神经网络,提出一种基于 KPCA-BiLSTM 的组合预测模型。同时与 BiLSTM、KPCA-LSTM、PCA-BiLSTM 等组合模型进行对比分析,得到 KPCA-BiLSTM 组合模型能够精确地预测分解炉的出口温度,有效地提高了预测精度。

[参 考 文 献]

[1] SCHNEIDER M. Process technology for efficient and sus-

tainable cement production[J]. *Cement & Concrete Research*, 2015, 78: 14-23.

- [2] 王红君,孟欣欣,赵辉,等. 基于神经网络的预分解窑系统分解炉出口温度建模[J]. *化工自动化及仪表*, 2016, 43(2): 164-166.
- [3] 褚彪. 基于 ARMAX 模型的分解炉出口温度预测方法研究[J]. *中国水泥*, 2020(10): 94-96.
- [4] 黄虹,徐庆根,张奕倩,等. 基于 KPCA 降维的 Weight-LSSVM 财务危机预警模型[J]. *统计与决策*, 2020(20): 180-184.
- [5] 彭玉青,乔颖,陶慧芳,等. 融入注意力机制的 PM_{2.5} 预测模型[J]. *传感器与微系统*, 2020, 39(7): 44-47.
- [6] 徐萌,王亚锟. 基于双向 LSTM 的 DA40 飞机碳刹车片剩余寿命预测[J]. *计算机应用*, 2021, 39(5): 14-23.
- [7] 聂黎生. 基于 KPCA-粒子群随机森林算法的舆情趋势预测研究[J]. *现代电子技术*, 2019(15): 79-82.
- [8] 者娜,杨剑锋,刘文彬,等. 基于 KPCA 和 SVM 的工艺管道腐蚀速率预测[J]. *腐蚀与防护*, 2019(1): 56-60.
- [9] 许杏花,潘庭龙. 基于 KPCA-RF 的风电场功率预测方法研究[J]. *可再生能源*, 2018, 36(9): 1323-1327.
- [10] 陆文琦,芮一康,冉斌,等. 智能网联环境下基于混合深度学习的交通流预测模型[J]. *交通运输系统工程与信息*, 2020(3): 47-53.
- [11] 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. [S. l.]: IEEE, 2014: 807-812.
- [12] 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. [S. l.]: IEEE, 2013: 86-90.

(责任编辑 张 镅)