

基于 CO 预测模型的垃圾协同处置下分解炉出口温度控制

陈 薇^{1,2}, 赵 军^{1,2}, 刘海军^{1,2}, 解俊哲^{1,2},
康志伟^{1,2}, 诸 庖³, 张宏图³

- (1. 合肥工业大学 电气与自动化工程学院, 合肥 230009;
2. 安徽省工业自动化工程技术研究中心, 合肥 230009;
3. 合肥水泥研究设计院有限公司, 合肥 230051)

摘要: 针对分解炉内的 CO 浓度, 建立了基于 CNN-LSTM-Attention 的 CO 预测模型; 以分解炉出口温度、喂煤量、生料喂料量、氧气浓度、垃圾流量作为预测模型的特征辅助变量, 将这些变量进行预处理与时序匹配, 经过模型处理训练得到 CO 预测浓度; 针对传统的 GPC 分解炉出口温度预测控制, 研究了一种考虑 CO 浓度预测模型的分解炉多工况优化控制策略; 模型的输入为喂煤量, 输出为分解炉出口温度, 分解炉出口温度的预测模型采用 ARMAX 模型来描述, 控制方法采用 GPC 算法, 但在此基础上加入了 CO 浓度工况开关, CO 浓度在正常和异常时采用两种不同的控制方法; 仿真结果表明, CNN-LSTM-Attention 模型预测的效果较好, 而且比 LSTM、CNN-LSTM、LSTM-Attention 这几个模型效果更好, 考虑 CO 浓度的分解炉出口温度模型也有较好的控制效果。

关键词: CNN-LSTM-Attention; GPC; CO 浓度; 多工况; 分解炉出口温度

Temperature Control of Decomposer Outlets with Waste Co-disposal Based on CO Prediction Model

CHEN Wei^{1,2}, ZHAO Jun^{1,2}, LIU Haijun^{1,2}, XIE Junzhe^{1,2},
KANG Zhiwei^{1,2}, CHU Biao³, ZHANG Hongtu³

- (1. School of Electrical and Automation Engineering, Hefei University of Technology, Hefei 230009, China;
2. Anhui Engineering Technology Research Center of Industrial Automation, Hefei 230009, China;
3. Hefei Cement Research & Design Institute Corporation Ltd, Hefei 230051, China;)

Abstract: For the CO concentration in the decomposition furnace, a convolutional neural network-long-short-term memory-attention mechanism (CNN-LSTM-Attention) based a CO prediction model is established. The decomposition furnace outlet temperature, coal feeding amount, raw material feeding amount, oxygen concentration, and waste flow rate are used as the characteristic auxiliary variables of the prediction model, and these variables are preprocessed and matched with time series, thus obtaining the CO prediction concentration through the model processing and training. For the predictive control on the outlet temperature of traditional generalized predictive control (GPC) decomposers, a multi-operating condition optimization control strategy for the decomposer considering the CO concentration prediction model is studied. The model input is the amount of coal fed, and the output is the decomposer outlet temperature. The prediction model of the decomposer outlet temperature is presented by the ARMAX model, and the control method adopts the GPC algorithm. But on the basis, the CO concentration working condition switch is added, with the CO concentration used by two different control methods under normal and abnormal conditions. Simulation results show that the CNN-LSTM-Attention model has the advantages o-

收稿日期:2024-11-11; 修回日期:2024-12-23。

基金项目:安徽省重点研发计划项目(202104a05020054)。

作者简介:陈 薇(1981-),女,博士,副教授。

通讯作者:赵 军(1999-),男,硕士研究生。

引用格式:陈 薇,赵 军,刘海军. 基于 CO 预测模型的垃圾协同处置下分解炉出口温度控制[J]. 计算机测量与控制, 2025, 33(12): 89-95, 136.

ver the LSTM, CNN-LSTM and LSTM-Attention models in prediction, and the temperature model of the decomposer outlet also has a better control effect on the CO concentration.

Keywords: CNN-LSTM-Attention; GPC; CO concentration; multi-working conditions; decomposition furnace outlet temperature

0 引言

在当前全球范围内, 碳排放和环境污染成为制约经济可持续发展的关键挑战之一。垃圾协同处置作为一种有效的废弃物处理方式, 具有资源综合利用、减少土地占用以及减少环境污染等优势。其中, 分解炉作为垃圾协同处置的核心设备之一, 其运行优化控制对于提高处理效率、降低能耗以及减少环境污染具有重要意义。

许多学者对 CO 浓度的预测模型和分解炉出口温度的控制方法都进行了大量研究。

在 CO 浓度的预测模型方向上, 文献 [1] 采用灰色系统理论中的原始差分灰色模型对遗煤自燃释放的 CO 量进行预测, 如文献 [2] 采用反向传播神经网络 (BP, back propagation) 神经网络预测淮安市 CO 浓度, 文献 [3] 采用多因素逐步回归分析, 建立采空区 CO 涌出量预测模型, 文献 [4] 使用机器学习中的多种方法对 CO 进行预测研究, 文献 [5] 采用灰色系统理论知识分析 CO 的浓度值, 并对 CO 浓度进行预测。

在分解炉出口温度的控制方法方面, 文献 [6] 在 CO 浓度正常的情况下将模糊规则与预测控制算法相结合, 通过与比例—积分—微分 (PID, proportional-integral-derivative) 方法进行对比实验, 结果表明, 所设计的系统适应性强, 对大滞后系统有良好的控制效果。在文献 [7] 中, 未考虑 CO 在分解炉中的作用, 仅从理论上对风、煤及料 3 种因素进行了定量研究, 并以此为依据, 利用最小二乘法及回归分析等方法, 构建了水泥分解炉温度控制模型。

在分解炉在实际运行过程中 CO 是许多化学反应的中间产物, 尤其是在高温和复杂反应环境中, CO 的浓度变化会直接影响分解过程的速率。CO 的存在会影响热量的传递和反应的放热过程, 从而影响炉内温度的稳定性, 最重要的是 CO 浓度会影响分解炉出口温度和喂煤量之间的正相关关系, 因此控制温度时需要考虑 CO 浓度。

综上所述, 对于 CO 的预测研究多集中在煤矿等需要安全检测的区域, 针对分解炉内 CO 的预测则少之又少; 分解炉出口温度的控制方法多为在 CO 浓度正常情况下的预测控制, 而当 CO 浓度异常时则可能会影响分解炉出口温度的预测控制。

1 垃圾协同处置下分解炉工艺分析

1.1 工艺分析

在现代新型干法水泥生产技术中, 分解炉是干法水

泥生产线的一个重要组成部分, 分解炉在高温条件下可以有效地热解原料中的有机物质, 将有机物质转化为气体和液体产物。其工艺流程如图 1 所示。

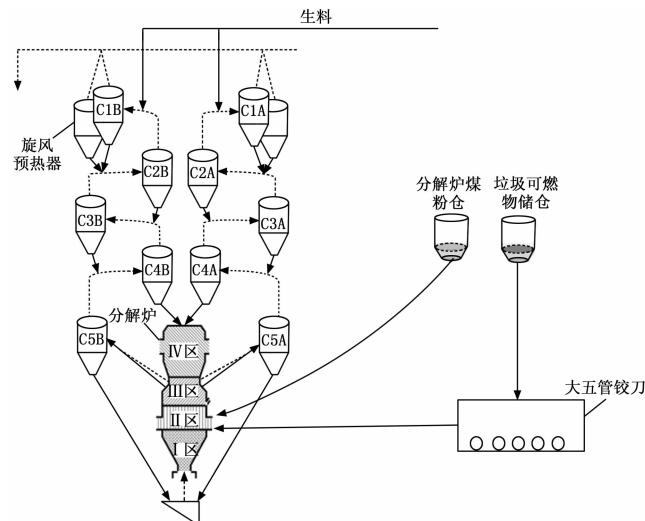


图 1 分解炉工艺流程图

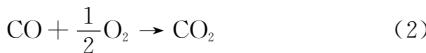
原料通过给料装置进入分解炉。在进入分解炉之前, 原料通常被预热器进行预热, 以达到更好的热解效果。通常情况下, 分解炉内的温度可达 800~1 000 ℃以上。在这种高温条件下, 原料中的有机物质开始分解并挥发出来, 同时一些化学反应也会发生, 使原料逐渐转变成煤气、液体产物和固体残渣。分解炉的产物主要包括煤气和液体产物。煤气可以被回收利用作为燃料供给其他设备, 液体产物则可以进行妥善处理或继续被利用, 而固体残渣则成为水泥生产中的原料之一。通过以上工作过程, 分解炉能够有效地将原料中的有机物质和挥发性成分分解和挥发出来, 并为水泥生产线后续煅烧工艺提供更加适宜的原料, 从而保证水泥产品的质量和生产效率。

对分解炉工艺分析可知, CO 浓度在分解炉内主要受温度、可燃物、氧气浓度影响, 因此将分解炉内分解炉出口温度、喂煤量、生料喂料量、氧气浓度、垃圾流量作为特征变量。

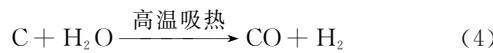
1.2 产生 CO 的机理分析

垃圾协同分解炉以垃圾为燃料, 燃烧反应可分为两个阶段, 即垃圾中的挥发分释放、燃烧及固体碳的燃烧, 而 CO 则是通过这两个阶段的反应进行的。垃圾中的挥发性物质 (包括各种高分子) 主要通过裂解生成的小分子气体有机物 (CO、CO₂ 和 H₂O 等) 进入气体环境中^[8]; 焚烧是指生活垃圾在高温条件下, 产生的小分

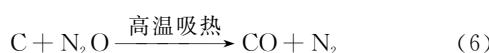
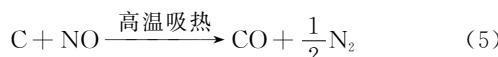
子有机物与 CO 在高温下发生的化学反应, 会产生大量的小分子有机物 (C_xH_y 、CO), 这些物质在高温环境下无法充分燃烧, 就会产生或残留 CO^[9]; 热解后的废弃物中仍有一定量的活性炭, 如果在燃烧过程中出现氧气不足或缺乏氧气, 则会造成燃烧不完全, 有很多中间产物没有完全反应, 则 CO 就会直接排放。固定碳在高温条件下的热化学反应主要分为 3 种情形^[10]:



在垃圾焚烧过程中, 在高温蒸汽条件下, 固体碳与水蒸汽发生气化反应^[11], 生成大量 CO, 如下式:



在热解过程中, 除了燃料的不完全燃烧、气化反应之外, 还存在着固体碳与其它无机氧化物发生化学反应所产生的 CO。如焚烧炉内存在着大量的氮的氧化物 (NO_x), 可能会与固定碳发生反应生成 N₂ 与 CO^[12]:



因此, CO 浓度在分解炉内主要受温度、可燃物、氧气浓度影响, 因此将分解炉内分解炉出口温度、喂煤量、生料喂料量、氧气浓度、垃圾流量作为预测模型的特征辅助变量。

1.3 存在问题

正常情况下, 煤粉作为燃料, 投入分解炉的煤粉越多, 分解炉温度越高。但在实际过程中, 当投入垃圾和煤粉过量或者分解炉内部的氧气含量很少时, 会产生过多的 CO, 进而抑制炉内燃烧, 出现增加喂煤量反而使分解炉温度降低的情况, 如图 2 所示, 采取的数据为安徽省某水泥厂的 2023 年 1 月 1 日的一部分生产线数据, 每个数据采样点间隔为 5 s。

在图 2 中, 当 CO 浓度正常时, 分解炉的出口温度与喂煤量成正相关; CO 浓度异常时, 分解炉出口温度与喂煤量成负相关。可见, CO 浓度对分解炉出口温度的控制有着不小的影响。

因此, 在分解炉出口温度预测控制中, 应该对 CO 浓度进行关注。然而传统的广义预测控制 (GPC, generalized predictive control) 分解炉出口温度预测控制却只考虑了 CO 浓度在正常情况下的预测控制, 这样可能会导致对出口温度的控制效果不够准确。

2 基于 CNN-LSTM-Attention 的 CO 预测模型

针对分解炉内复杂反应及数据的时间序列^[13]特点,

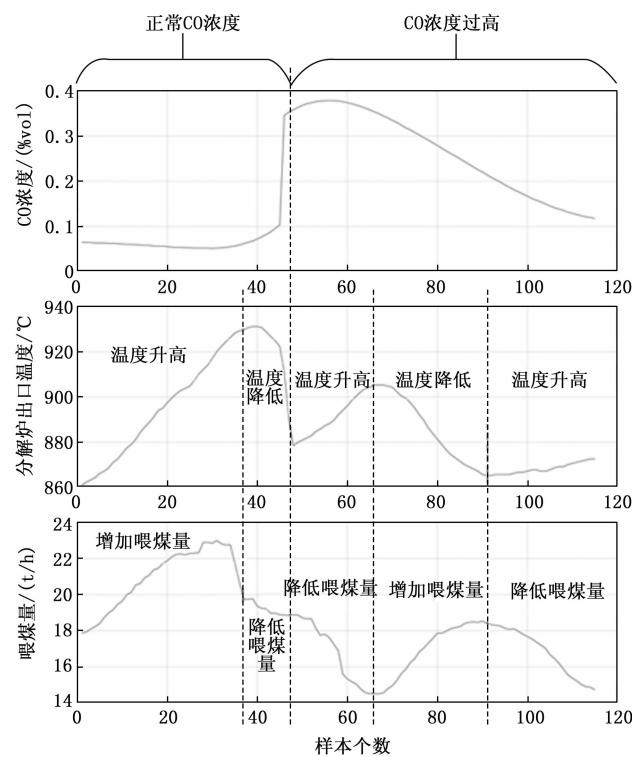


图 2 CO 含量、分解炉出口温度与喂煤量三者变化的趋势

本文设计基于卷积神经网络—长短期记忆网络—注意力机制 (CNN-LSTM-Attention, convolutional neural network-long-short-term memory-attention mechanism) 融合模型的 CO 浓度预测模型, 网络结构如图 3 所示。CNN-LSTM-Attention 融合模型主要包括 5 层: 输入层、卷积神经网络 (CNN, convolutional neural network) 层、长短期记忆网络 (LSTM, long-short-term memory) 层、注意力机制 (Attention Mechanism) 层、输出层。对于分解炉历史各参数数据, 首先选择特征向量并判断特征向量与目标向量之间的滞后时间, 再将输入数据进行数据预处理, 减少噪音对模型的影响, 并将处理后的数据作为 CNN 层的输入数据并经过 CNN-LSTM-Attention 网络结构的处理。最后在输出层中, 对预测结果进行误差评估分析。通过这种 CNN-LSTM-

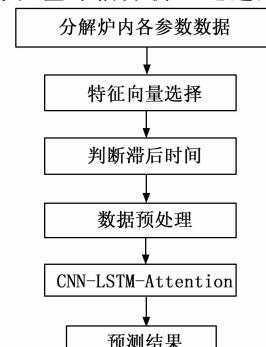


图 3 CNN-LSTM-Attention 模型架构

Attention 融合模型的结构，可以更好地利用分解炉历史各参数数据的时序特征，并提高模型在预测方面的性能。

2.1 辅助变量数据预处理

由于采集的数据会有少量异常数据，可能包含错误、遗漏值或异常值，这些都可能影响模型的学习效果和预测准确性。对于缺失值的处理，使用平均值来填充，公式如下：

$$x_{\text{miss}}^k = \frac{1}{N} \sum_{i=1}^N x_i^k \quad (7)$$

其中： x_{miss}^k 表示第 k 个特征辅助变量的平均值， N 为第 k 个特征辅助变量的总个数， x_i^k 表示第 k 个特征辅助变量的第 i 个数据。

对于异常值的处理，使用 Z 分数^[14] 的方法检测异常值，Z 分数的公式如下：

$$z_i^k = \frac{(x_i^k - \mu^k)}{\sigma^k} \quad (8)$$

其中： x_i^k 表示第 k 个特征辅助变量的第 i 个数据， μ^k 表示第 k 个特征辅助变量的数据集均值， σ^k 表示第 k 个特征辅助变量的数据集标准差。在计算了每个数据点的 Z 分数之后，可以通过设置阈值来判定异常值。通常，如果数据点的 Z 分数的绝对值超过了这个阈值，该数据点就被视为异常值，则将这个异常数据点使用均值代替。

在对垃圾流量这个辅助变量进行预处理时，由于垃圾流量变化频率很快，因此除了要对它进行数据的异常勘误外，还要对它进行窗口均值滑动，以 24 个垃圾流量数据点为一个滑动窗口，计算每个滑动窗口的平均值作为新的每个时刻的垃圾流量值。

2.2 多时间序列辅助变量的时序匹配

水泥分解炉是一个复杂的热化学反应系统，涉及多个变量之间的相互作用。CO 浓度的变化受到炉内温度、氧气浓度等多个因素的影响。这些因素的变化通常会有一定的滞后效应，即影响 CO 浓度的变化在时间上可能会有一定的延迟。通过计算滞后时间，可以更准确地反映不同因素之间的时序关系，能够更好地反应动态特性、时序关系和变量之间的延迟效应，提高预测的准确性和可解释性。

相关系数^[15] 可以有效地量化两个时间序列之间在不同时间滞后下的关联程度。通过计算不同滞后条件下的相关系数，可以发现哪些时间滞后能够最大化这种相关性，从而揭示潜在的因果关系或影响路径。特别是斯皮尔曼秩相关系数这类非参数方法，不假定数据遵循正态分布，适用于各种分布的数据。这意味着即便数据的分布未知或非常偏斜，仍然可以有效使用相关系数来分析数据，使其应用范围更广。因此本文使用斯皮尔曼秩相关系数^[16] 来进行时序匹配。公式如下：

$$\rho = 1 - \frac{6 \sum d_{(k,i)}^2}{n^3 - n} \quad (9)$$

其中： $d_{(k,i)}$ 表示第 k 个特征辅助变量与 CO 浓度这两个变量对的秩次之差， n 是这两个变量的观测值的数量。

对于第 k 个特征辅助变量考虑的滞后 t ，将它的时序序列向后移动 t 时间单位，计算其与 CO 浓度的斯皮尔曼秩相关系数 ρ_t^k ，选择使得斯皮尔曼秩相关系数最大的滞后，作为第 k 个特征辅助变量与 CO 浓度之间的最佳匹配滞后。由此得到全部特征辅助变量与 CO 浓度之间的最佳匹配滞后。

2.3 基于 CNN-LSTM-Attention 的 CO 预测模型

CNN 输入层接收到预处理后的变量数据 $X(t) = [X_1(t), X_2(t), \dots, X_5(t)]$ $X_1(t), X_2(t), \dots, X_5(t)$ 依次表示分解炉出口温度、喂煤量、生料喂料量、氧气浓度、垃圾流量这 5 个特征变量的时间序列，CNN 层进行一维卷积操作从特征向量中提取局部特征，并使用 Dropout 层，避免过拟合，最后使用批量规范化层进行标准化处理，以加速模型收敛并提高模型的泛化能力。LSTM^[17] 层接收 CNN 层的输出作为输入，并用于捕捉序列信息和建模时间依赖关系。Self-Attention 层引入了自注意力机制，使模型能够自适应地关注输入序列中的重要部分。通过计算注意力权重，Self-Attention 层可以对序列中的不同位置进行加权处理，从而更好地捕捉上下文信息并提高模型性能。CNN-LSTM-Attention^[18] 网络结构如图 4 所示。

3 考虑 CO 预测模型的分解炉多工况优化控制策略 (CO-GPC)

分解炉出口温度是分解炉操作中需要密切关注和控

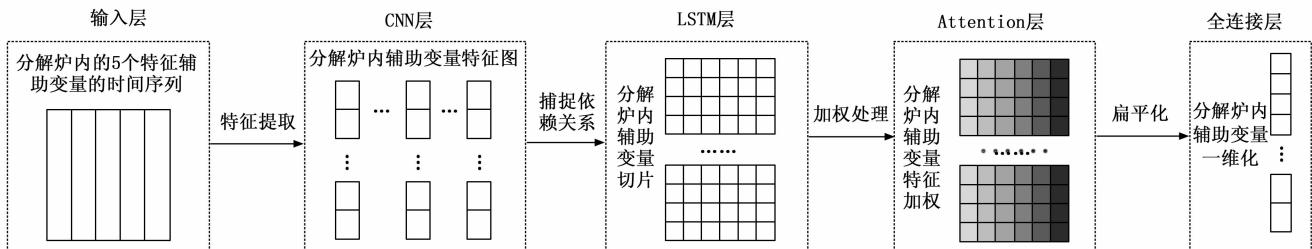


图 4 CNN-LSTM-Attention 网络结构

制的参数之一。它直接影响裂解反应的进行程度、产品选择性、产品质量以及设备安全。通过合理调节和控制分解炉出口温度, 可以优化生产过程, 提高产品质量, 确保设备的安全稳定运行。因此, 在分解炉的操作和监控中, 对分解炉出口温度进行实时监测和调控是至关重要的。只有在合适的温度下, 分解炉才能实现最佳的效率和产品质量, 同时确保设备的安全运行。

传统的 GPC^[19]出口温度预测控制无法满足 CO 浓度对出口温度的影响, 因此对传统的 GPC 出口温度预测控制进行改进, 引入 CO 浓度条件, 根据经验将 CO 浓度高于 0.3 (即 CO 浓度异常) 和 CO 浓度低于 0.3 两种情况分为两个预测模型和控制模型, 以此提高对分解炉出口温度的控制效果, 其原理如图 5 所示。

3.1 参考轨迹

“参考轨迹”是指系统被期望或要求跟随的理想输出轨迹或目标轨迹。在控制系统中, 通常存在一个期望的输出值, 控制器的任务就是使系统的实际输出尽可能接近这个期望值。在实际生产中, 若输出的设定值与实际值偏差过大, 可能导致过度的控制活动, 甚至产生安全隐患, 因此要对设定值进行柔化。设定值柔化通常通过一个低通滤波器实现, 该滤波器能够平滑过渡设定值, 使其变化更为渐进。一个简单而常见的柔化方法是一阶滤波器, 公式如下:

$$y_s(k+j) = \alpha y(k) + (1 - \alpha) y_s \quad (10)$$

其中: $y_s(k+j)$ 是 $(k+j)$ 时刻柔化后的设定值, $y(k)$ 为分解炉出口温度设定值, α 为滤波器参数, $0 < \alpha \leqslant 1$, α 越小, 滤波效果越强, 设定值越平滑。当 $j = n_1, \dots, n_2$ 时, 由式 (10) 可得柔化值序列 $Y_s = [y_s(k+N_1), \dots, y_s(k+N_n)]^T$ 。

3.2 预测模型

本文在广义预测控制中加入受控自回归滑动平均模

型 (ARMAX, auto regression moving average with extra input) 模型^[20], 主要是因为 ARMAX 模型能够提供一种有效的方式来描述和预测控制对象的动态行为。ARMAX 模型的数学表达式如下:

$$A(z^{-1})y(t) = B(z^{-1})u(t-n_k) + C(z^{-1})e(t) \quad (11)$$

其中: $y(t)$ 是在时间 t 的系统输出, $u(t)$ 是在时间 t 的系统输入, $e(t)$ 是在时间 t 的随机干扰项, $A(z^{-1})$, $B(z^{-1})$, $C(z^{-1})$ 是多项式, 分别对应于系统的自回归部分、输入的影响部分以及随机干扰的移动平均部分。 n_k 是输入输出之间的时延。具体来说:

$$A(z^{-1}) = 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_p z^{-p} \quad (12)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_q z^{-q} \quad (13)$$

$$C(z^{-1}) = 1 + c_1 z^{-1} + c_2 z^{-2} + \dots + c_r z^{-r} \quad (14)$$

这些表达式中, p 是自回归部分的阶数, q 是输入影响部分的阶数, a_i, b_i, c_i 都是模型参数, 需要通过数据拟合得到。

3.3 求解控制量

GPC 的目标是最小化一个目标函数, 该函数通常是预测输出与期望输出(参考轨迹)之间差的加权平方和, 加上控制增量的加权平方和。具体来说, 目标函数可以表示为:

$$J = \sum_{k=1}^N w_k [\hat{y}(t+k/t) - r(t+k)]^2 + \sum_{k=1}^{N_u} \lambda_k [\Delta u(t+k-1)]^2 \quad (15)$$

其中: N 为预测的时间范围; N_u 为控制优化的时间范围, 小于或等于 N ; $\hat{y}(t+k/t)$ 为给定当前信息时, 对时刻 $(t+k)$ 的系统输出的预测; $r(t+k)$ 是在时刻 $(t+k)$ 的参考值; $\Delta u(t+k-1)$ 为控制增量; w_k 和 λ_k 为权重系数, 分别衡量预测误差和控制增量的相对重要性。

最终, 通过优化目标函数来求解控制量 u 。这通常需要使用数值优化技术, 如二次规划。优化的结果是得

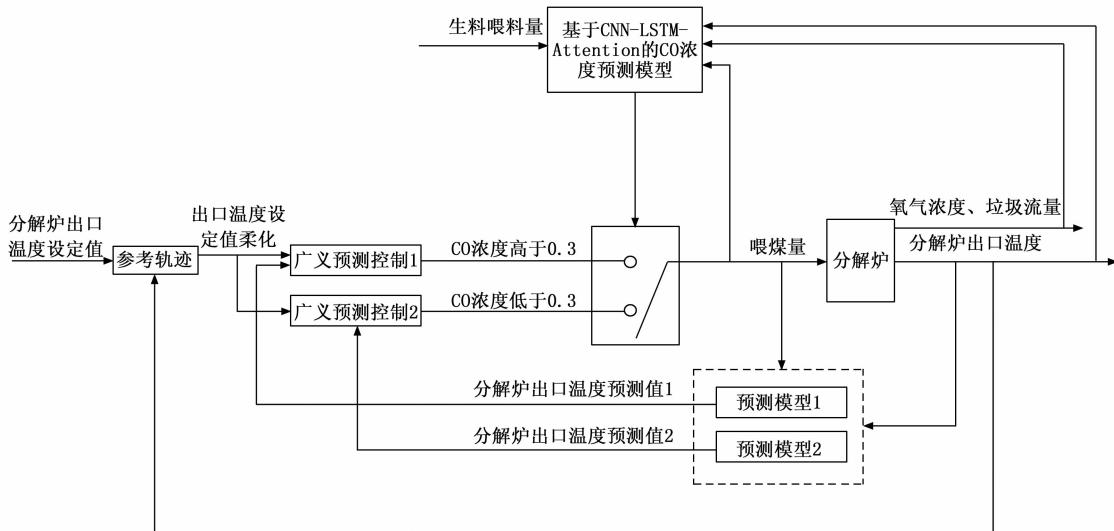


图 5 CO-GPC 出口温度预测控制原理图

到一系列控制增量 Δu ，而 GPC 仅使用序列中的第一个增量来更新控制信号。

综上，本文在考虑分解炉内 CO 浓度的情况下对分解炉出口温度进行预测控制，具体步骤如下：

- 1) 求解分解炉出口温度设定值柔化序列 $Y_s = [y_s(k+N_1), \dots, y_s(k+N_n)]^T$ ；
- 2) 将分解炉内各辅助变量作为 CNN-LSTM-Attention 预测模型的输入来预测 CO 浓度 $S = [s(k+N_1), \dots, s(k+N_n)]$ ；
- 3) 如果预测出的 CO 浓度大于 0.3，则选择广义预测控制 1；否则选择广义预测控制 2；
- 4) 通过广义预测控制求解喂煤量 $u(k)$ ；
- 5) 根据广义预测控制对应的预测模型求解分解炉出口温度预测序列 $Y = [y(k+N_1), \dots, y(k+N_n)]$ ；
- 6) 记录下喂煤量 $u(k)$ 并返回 1) 开始下一轮预测控制。

4 实验与讨论

4.1 CO 浓度预测模型仿真

4.1.1 特征变量与目标变量之间的滞后时间

本文采取的数据为安徽省某水泥厂的生产线数据，采样点间隔为 5 s，并选取一天的数据为一个总样本。通过特征变量和目标变量之间不同滞后时间的相关系数（斯皮尔曼秩相关系数）来判断特征变量与目标变量之间的滞后时间，如图 6 所示。

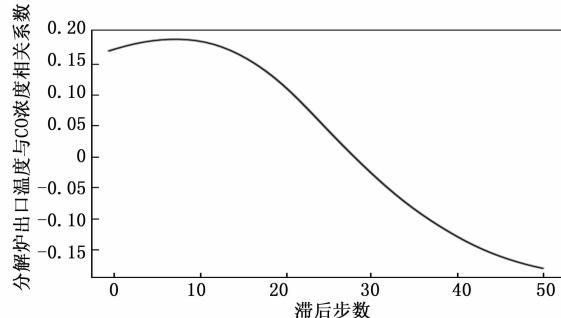


图 6 分解炉出口温度与 CO 浓度相关系数

由图 6 可知，分解炉出口温度滞后步数为 8（即 40 s），喂煤量滞后步数为 40（即 200 s），同理可知生料喂料量滞后步数为 70（即 350 s），氧气浓度滞后步数为 0，垃圾流量步数为 128（需要以垃圾流量实际值 120 s 为一个滑动窗口，计算每个滑动窗口的平均值作为此处的垃圾流量，128 步即 640 s），如表 1 所示。

表 1 各个特征变量与目标变量 CO 浓度之间的滞后时间

	分解炉出口温度	喂煤量	生料喂料量	氧气浓度	垃圾流量
滞后步数	8	40	70	0	128
滞后时间/s	40	200	350	0	640

4.1.2 实验仿真结果

CNN-LSTM-Attention 融合模型的超参数如下：卷积层 1 的卷积核大小为 1×1 ，卷积核数量为 100；卷积层 2 的卷积核大小为 2×2 ，卷积核数量为 100；LSTM 层具有 100 个隐藏单元；Dropout 层设置为 0.15，表示在训练过程中会以 15% 的概率丢弃部分隐藏神经元。将所有数据的 75% 设置为训练集，25% 为测试集，分别对模型的时间步数 t 和训练次数 n 进行检测实验，实验结果如表 2 所示。

表 2 不同参数下模型的预测效果

误差参数	$t=2, n=50$	$t=2, n=80$	$t=20, n=50$	$t=20, n=80$	$t=60, n=50$	$t=80, n=50$
RMSE	0.0013	0.0013	0.0012	0.0014	0.0004	0.0012
MAE	0.0232	0.0226	0.0209	0.0228	0.014	0.0189

由表 2 可知，当时间步数 $t=60$ 和训练次数 $n=50$ 的时候，均方根误差 (RMSE, root mean squared error) 和平均绝对误差 (MAE, mean absolute error) 的值最小，此时的实验结果如图 7 所示。

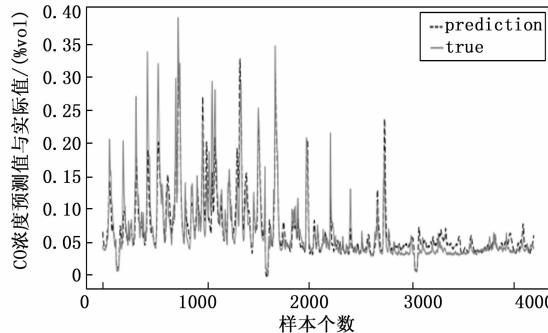


图 7 $t=60, n=50$ 时的预测曲线

由图 7 可知，预测模型以及模型设置的参数对于预测 CO 浓度有着良好的效果。

4.1.3 模型对比试验

为了验证本文 CNN-LSTM-Attention 模型的准确性和有效性，开展了该模型和 CNN-LSTM 模型、LSTM-Attention 模型以及 LSTM 模型的对比实验。本文对这 4 个模型使用同一参数进行预测曲线分析，如图 8 所示。

从这些模型预测曲线可以看出，CNN-LSTM 模型和 LSTM-Attention 模型对谷值的预测比较精准，但是对于一些峰值的预测精准性较差，对于 LSTM 模型，一些峰值和谷值的预测精准度都比较差，而 CNN-LSTM-Attention 模型对于峰值和谷值的预测都比较精准，对实际数据的拟合度最好。

对于 4 种模型的误差指标如表 3 所示。由结果可知，本文提出的 CNN-LSTM-Attention 模型具有最小的误差，相对于其他 3 种模型，它的 RMSE 和 MAE 大大减少。由于 CNN-LSTM 模型和 LSTM-Attention 模型

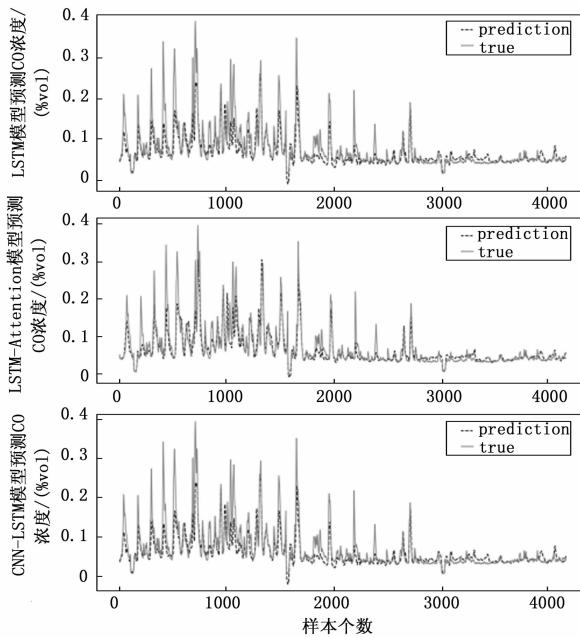


图 8 不同模型对 CO 浓度的预测效果

在单一 LSTM 模型的基础上加上了 CNN 和注意力机制, CNN 可以自动提取并学习数据中的空间和时间特征, 从而更好地捕捉峰值和谷值的变化模式, 注意力机制能够根据输入数据的重要性动态调整信息的权重分配, 从而更加准确地关注峰值和谷值所在的位置。因此 CNN-LSTM 模型和 LSTM-Attention 模型的预测效果也优于单一 LSTM 模型。

表 3 不同模型在同一参数下的预测效果

	LSTM	LSTM-Attention	CNN-LSTM	CNN-LSTM-Attention
RMSE	0.001 6	0.001 5	0.001 5	0.000 4
MAE	0.024 3	0.022 9	0.023	0.014

4.2 CO-GPC 分解炉出口温度预测控制仿真

4.2.1 预测模型验证

本文使用最小二乘法对预测模型 ARMAX 进行参数辨识, 结合实际工程经验以及模型拟合度, 得到模型的参数为:

CO 浓度正常情况下的模型参数:

$$a = [1 - 0.99293]; b = [0.35779]。$$

CO 浓度异常情况下的模型参数:

$$a = [1 - 1.5728 0.57596];$$

$$b = [-0.72402 0.87]。$$

4.2.2 控制仿真

传统的 GPC 温度预测控制与 CO-GPC 温度预测控制在 CO 浓度正常情况下是一样的控制效果, 如图 9 (a) 所示, 图中的设定值为分解炉出口温度设定值, 输出值为分解炉出口温度的预测值, 图中的控制律为喂煤

量; 当 CO 浓度异常时, 由于分解炉出口温度与喂煤量的关系变化, 传统的 GPC 控制的预测模型已经不适用于 CO 浓度异常的情况, 因此在 CO-GPC 控制中切换控制器预测模型, 效果如图 9 (b) 所示。

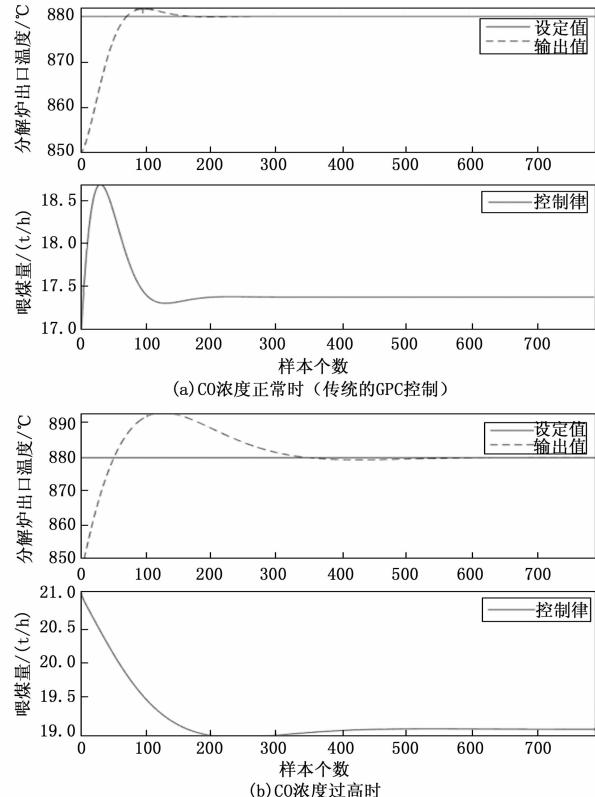


图 9 CO-GPC 控制下不同 CO 浓度下的分解炉出口温度预测控制

在图 9 中, 当 CO 浓度正常时传统的 GPC 控制器可以正常进行调节, 然而当 CO 浓度异常时, 分解炉出口温度与喂煤量呈负相关关系, 由于传统的 GPC 控制器预测模型仅适用于 CO 浓度正常时分解炉出口温度与喂煤量的正相关关系, 因此传统的 GPC 控制不适用于 CO 浓度异常的情况; 但是在 CO-GPC 控制器下, 当 CO 浓度正常和异常时控制器都可以正常进行调节。对比传统的 GPC 控制器, CO-GPC 控制器在 CO 浓度正常和异常时分别使用了相对应的预测模型, 使得分解炉出口温度与喂煤量始终保持对应关系, 以此弥补了传统 GPC 温度预测控制在 CO 浓度异常时的缺点, 最终取得良好的控制效果。

5 结束语

本文首先从垃圾协同处置下分解炉的工艺机理和产生 CO 的机理分析角度出发, 确定了分解炉内 CO 浓度预测模型的辅助特征变量, 然后对这些变量进行预处理以及时序匹配, 建立了基于 CNN-LSTM-Attention 的 CO

(下转第 136 页)