

控制与决策

Control and Decision

基于双通道CNN-LSTM-Attention预测模型的晋华炉煤气化过程操作优化

韩永明, 李帅, 耿志强, 汪京培, 王孟志

引用本文:

韩永明, 李帅, 耿志强, 等. 基于双通道CNN-LSTM-Attention预测模型的晋华炉煤气化过程操作优化[J]. 控制与决策, 2026, 41(4): 1110-1121.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0898>

您可能感兴趣的其他文章

Articles you may be interested in

[双重驱动的果蝇优化算法及其在PID控制器中的应用](#)

Double drive fruit fly optimization algorithm and its application in PID controller
控制与决策. 2021, 36(9): 2225-2233 <https://doi.org/10.13195/j.kzyjc.2020.0046>

[基于R2指标和目标空间分解的高维多目标粒子群优化算法](#)

R2 indicator and objective space partition based many-objective particle swarm optimizer
控制与决策. 2021, 36(9): 2085-2094 <https://doi.org/10.13195/j.kzyjc.2020.0113>

[基于局部搜索的反向学习竞争粒子群优化算法](#)

Opposition-based learning competitive particle swarm optimizer with local search
控制与决策. 2021, 36(4): 779-789 <https://doi.org/10.13195/j.kzyjc.2019.1150>

[基于图像随机分布模型的电熔镁炉工况识别](#)

Conditions recognition of fused magnesia furnace based on dynamic characteristics of B-spline network
控制与决策. 2021, 36(11): 2735-2742 <https://doi.org/10.13195/j.kzyjc.2020.0570>

[改进型灰狼算法在热电偶动态补偿中的应用](#)

Application of improved grey wolf algorithm in dynamic compensation of thermocouple
控制与决策. 2021, 36(1): 61-67 <https://doi.org/10.13195/j.kzyjc.2019.0688>

基于双通道 CNN-LSTM-Attention 预测模型的 晋华炉煤气化过程操作优化

韩永明^{1,2}, 李 帅^{1,2}, 耿志强^{1,2}, 汪京培³, 王孟志^{1,2†}

(1. 北京化工大学 信息科学与技术学院, 北京 100029;

2. 智能过程系统工程教育部工程研究中心, 北京 100029;

3. 中国科学院空间应用工程与技术中心, 北京 100094)

摘要: 煤气化过程具有强非线性、强耦合以及多目标冲突等特点, 传统基于机理模型的操作优化方法难以达到高效且稳健的效果. 晋华炉作为我国煤气化工艺中应用广泛的典型炉型, 其运行优化亟需智能化建模和决策支持. 鉴于此, 提出一种基于双通道卷积-长短期记忆网络-注意力机制 (CNN-LSTM-Attention) 预测模型的晋华炉操作优化方法. 预测模型使用双通道结构融合工艺特征和历史序列信息, 并利用层次化注意力机制提升关键特征的表达能. 在氢气、一氧化碳比例预测任务中, 所构建双通道 CNN-LSTM-Attention 模型分别取得 0.9322 和 0.9637 的判定系数, 显示出良好的精度和鲁棒性. 在此基础上, 结合粒子群优化算法, 将预测模型作为代理模型对关键操作变量进行智能寻优. 实验结果表明, 优化方案相较于原始工况氢气比例提高了 1.22%, 一氧化碳比例提高了 1.51%, 总体有效气含量提升了 1.38%. 该研究为晋华炉气化过程的智能建模和工况优化提供了有效支撑, 对煤气化典型炉型的高效运行具有重要参考价值.

关键词: 晋华炉; 操作优化; LSTM; CNN; 注意力机制; 粒子群算法

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0898

引用格式: 韩永明, 李帅, 耿志强, 等. 基于双通道 CNN-LSTM-Attention 预测模型的晋华炉煤气化过程操作优化 [J]. 控制与决策, 2026, 41(4): 1110-1121.

Multi-objective optimization of coal gasification process in Jinhua furnace based on two-channel CNN-LSTM-Attention prediction model

HAN Yong-ming^{1,2}, LI Shuai^{1,2}, GENG Zhi-qiang^{1,2}, WANG Jing-pei³, WANG Meng-zhi^{1,2†}

(1. College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China; 2. Engineering Research Center of Intelligent PSE of Ministry of Education of China, Beijing 100029, China; 3. Technology and Engineering Center for Space Utilization, Chinese Academy of Sciences, Beijing 100094, China)

Abstract: The coal gasification process is characterized by strong nonlinearity, strong coupling, and multiple conflicting objectives, which make it difficult for traditional mechanism-based optimization methods to achieve efficient and robust performance. As a widely applied representative gasifier type in China, the Jinhua gasifier urgently requires intelligent modeling and decision-support techniques for operational optimization. This paper proposes an operation optimization approach for the Jinhua gasifier based on a dual-channel convolutional neural network-long short-term memory-attention (CNN-LSTM-Attention) predictive model. The proposed model employs a dual-channel structure to integrate process features with historical sequence information and leverages a hierarchical attention mechanism to enhance the representation of critical features. In the tasks of predicting hydrogen and carbon monoxide fractions, the constructed dual-channel CNN-LSTM-Attention model achieves coefficients of determination of 0.9322 and 0.9637, respectively, demonstrating high accuracy and robustness. Building upon this, the model is coupled with a particle swarm optimization algorithm and used as a surrogate model to intelligently search for optimal operating

收稿日期: 2025-08-30; 录用日期: 2025-10-14.

基金项目: 国家重点研发计划项目 (2024YFB4105203); 国家自然科学基金优秀青年项目 (62422303); 国家自然科学基金项目 (62373035); 北京市自然科学基金-丰台创新联合基金重点项目 (L241015).

责任编委: 王凌.

†通信作者. E-mail: wangmz@buct.edu.cn.

variables. Experimental results show that, compared with the original operating conditions, the optimized scheme increases the hydrogen fraction by 1.22%, the carbon monoxide fraction by 1.51%, and the overall effective gas content by 1.38%. This study provides effective support for intelligent modeling and operating condition optimization of the Jinhua gasifier and offers valuable insights for the efficient operation of representative coal gasification technologies.

Keywords: Jinhua furnace; operation optimization; LSTM; CNN; attention; particle swarm algorithm

0 引言

我国能源结构呈现“多煤、贫油、少气”的特点,使得煤炭成为支撑国家经济和工业发展的关键资源。同时,煤炭作为化工、电力、钢铁等行业的重要原料,其战略地位日益突出^[1]。为提高煤炭利用效率并减少污染物排放,近几十年来我国洁净煤技术得到了快速发展^[2]。在此背景下,煤气化技术作为现代煤化工和清洁能源生产的核心环节,在煤炭利用效率提升、环境友好性方面具有重要作用^[3]。

目前,我国煤气化技术已形成多种炉型并行发展的格局,如固定床、流化床以及气流床等^[4],其中晋华炉作为近年来我国自主研发并广泛应用的典型水煤浆气化工工艺,凭借其高效适应性和较低的运行成本,已在多个大型煤化工项目中得到大规模推广。然而,在实际运行中,晋华炉的关键工艺参数调节仍然主要依赖操作人员的经验。由于煤气化过程具有强非线性、强耦合和多目标冲突等特征^[5],即使经验丰富的操作人员在复杂工况下也难以实现精准判断,从而影响有效气产率和碳转化率,导致设备性能无法充分发挥。因此,晋华炉的运行优化亟需更加智能化的建模和决策支持方法。

近年来,学者们在煤气化过程的预测建模和操作优化方面开展了大量研究。考虑到煤气化过程高度复杂,传统的计算流体力学和降阶模型在温度、有效气含量等关键变量预测上往往精度不足,深度学习方法逐渐受到重视。已有研究利用长短期记忆网络(LSTM)、循环神经网络(RNN)、卷积神经网络(CNN)、人工神经网络(ANN)和Transformer等模型对不同类型的气化炉进行建模,在温度和气体组分预测方面取得了积极成果^[6-11]。如:Zhao等^[8]采用LSTM构建预测模型,使用粒子群算法(PSO)对模型的超参数进行了优化,以此提高煤气化炉温度预测精度;Wang等^[9]利用CNN卷积神经网络建立了壳牌气化炉的氢气以及一氧化碳的体积流量预测模型。然而,上述工作大多停留在对关键变量的预测层面,缺乏与操作优化的紧密结合。与此同时,针对不同炉型的操作优化研究也不断涌现。已有学者针对SE炉、Shell炉、德古士炉和内流式气化炉提出了多种基于智能建模和智能优化算法的研究^[12-16]。如:王

恺洲等^[12]提出了一种反向传播神经网络-支持向量机-极限学习机融合建模方法,对SE水煤浆气化炉进行预测建模,并在此基础上结合遗传算法对氧气和煤浆流量比进行了优化;孙漾^[13]则基于支持向量机构建了德古士气化炉的预测模型,并采用改进的粒子群协同优化算法开展了优化分析,其优化目标为最大化有效合成气产率。然而,针对晋华炉的系统性操作优化研究仍然鲜见报道,这在一定程度上制约了其性能潜力的充分发挥。

在预测模型方法层面,CNN和LSTM等神经网络在捕捉时间序列数据的局部特征和长期依赖方面展现了优势,但是,传统的单通道结构往往难以同时利用输入特征与历史目标变量的互补信息,从而导致预测精度受限^[8-9]。此外,煤气化过程的非线性和强耦合特征也使得传统模型难以突出关键特征的作用。因此,如何同时融入输入特征和历史目标序列建立高精度预测模型,为操作优化提供可靠支撑是本文关注的主要问题。

鉴于此,本文针对晋华炉气化过程提出一种双通道深度学习预测模型构建方法,并在此基础上构建操作优化模型,结合粒子群方法实现操作参数的智能寻优。本文的主要内容如下:

1) 提出一种融合双通道输入与层次化注意力机制的煤气化运行状态预测模型框架。结合LSTM和CNN,双通道结构将工艺特征变量和历史目标变量同时纳入建模框架,以实现输入与输出特征的有效融合。进一步地,结合特征自注意力、目标自注意力以及跨模态注意力构成的层次化注意力机制,有效捕捉不同输入与输出变量间的复杂关联,为操作优化提供更加精确的预测模型。

2) 基于晋华炉实际运行数据开展实验验证。实验结果表明,预测模型在关键气体组分预测方面具有更高的精度和鲁棒性。进一步结合粒子群优化后,可显著提升气体组分含量和整体有效气产率,验证了所提出方法在预测建模和运行优化中的有效性和先进性。

1 晋华炉工艺介绍

2015年,清华大学山西研究院与北京清创晋华科技有限公司携手攻关,联合研发出晋华炉3.0气化

技术. 该技术创新性地融合水煤浆进料、膜式水冷壁、辐射式蒸汽发生器以及水激冷 4 大核心工艺, 突破了高灰熔点煤和低浓度水煤浆气化过程中的高能耗瓶颈. 同时, 通过高效回收气化装置内高温合成气的热量, 在不增加氧气和煤炭消耗量的前提下, 实现了高压蒸汽的副产, 显著提升了系统的能量利用效率^[17].

晋华炉所采用的水煤浆加压气流床气化工艺, 是其实现高效气化的核心技术路径, 实际工艺流程如图 1 所示. 在工艺的初始阶段水煤浆与助燃剂纯氧通过耐高温烧嘴协同送入气化炉的燃烧室内部. 此烧嘴经特殊结构设计, 能够确保水煤浆与纯氧在进入燃烧室后迅速实现均匀雾化和充分混合, 为后续的气化反应创造良好条件. 在燃烧室内 $1\ 250^{\circ}\text{C} \sim 1\ 550^{\circ}\text{C}$ 的高温 and $6.5\ \text{MPa}$ 高压的条件下, 已充分混合的水煤浆与氧气会发生一系列复杂的氧化还原反应. 煤中的挥发分率先与氧气发生部分氧化反应, 生成 CO 、 CO_2 和 H_2O , 同时放出大量热. 在高温气化区碳与氧气反应生成 CO 和少量 CO_2 , 高温下碳与煤浆蒸发的水蒸气发生反应生成 H_2 和 CO . 最终生成以一氧化碳、氢气为主要有效成分, 同时含有少量二氧化碳的粗煤气^[18]. 完成气化反应后, 离开气化炉燃烧室的粗合成气仍然保持高温高压状态, 且携带大量反应生成的灰渣, 二者向下进入辐射式废热锅炉. 该废热锅炉是工艺中的关键能量回收设备, 其内部的辐射换热元件能够高效吸收粗合成气携带的大部分显热, 并将这些热量转化为高压饱和蒸汽. 经辐射式废热锅炉热处理后, 粗合成气的温度会显著降至 $700^{\circ}\text{C} \sim 800^{\circ}\text{C}$. 出废热锅炉的粗合成气进入激冷

段被激冷水激冷、换热、洗涤, 粗合成气中含有的较大颗粒灰渣冷却后沉入激冷室底部, 经破渣机进入渣锁斗^[19-20]; 其余颗粒较小的灰渣随合成气进入合成气洗涤塔, 进一步进行洗涤冷却.

2 CNN-LSTM-Attention 预测模型

2.1 数据描述与预处理

本研究采用晋华炉气化炉的实际运行数据, 数据集具有 14 个原始变量, 采集周期为 8 min, 共包含 3961 个样本. 在工业过程数据中, 往往存在大量高度相关或冗余的操作变量, 若全部用于建模, 则将会增加模型复杂度, 可能会导致过拟合并降低泛化性能^[21]. 因此, 在建模前需要系统分析输入特征与目标变量的相关性, 以筛选出对预测结果具有显著影响的关键特征.

以气化过程的工业运行数据为研究对象, 采用皮尔逊相关系数 (PCC) 衡量变量间的线性关系强度. 皮尔逊相关系数的取值范围为 $[-1, 1]$, 能够直观地反映变量间的正相关、负相关以及相关强度, 有助于后续筛选重要影响因素和构建建模特征. 因此, 本文利用皮尔逊相关系数对输入变量与目标变量的线性相关性进行评估^[22], 其计算公式如下所示:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}}. \quad (1)$$

其中: x_i 和 y_i 分别为第 i 个样本的输入和输出变量, \bar{x} 和 \bar{y} 分别为其均值. 由于不同输入变量与输出变量间可能存在正相关或负相关关系, 且气化过程的预测输出变量不止一个, 仅依赖特征与单一目标变量的相关性存在一定局限性. 相比之下, 平均绝对相关性能够提供更全面的衡量, 从而有助于特征筛选和建模输入的优化. 本文进一步引入平均绝对相关性作为综合指标, 用于评价变量间整体的相关性^[23].

基于上述方法, 对气化炉运行过程的变量进行相关性分析, 结果如图 2 所示. 热力图直观地展示了不同输入变量与输出气体指标间的相关性强弱. 通过对比不同输入变量与目标变量间的相关性, 进一步基于平均绝对相关性计算结果, 筛选出高相关性的变量, 既能够有效减少输入维度, 又可以提高预测模型的收敛速度和泛化能力^[24].

通过观察图 2 可以发现: 部分温度变量如气化炉辐射废锅内部上下温度与气体组分的相关性较强, 气化炉辐射废锅内部下温度与氢气比例和一氧化碳比例相关性分别达到了 -0.91 和 0.80 , 而氧气总管温

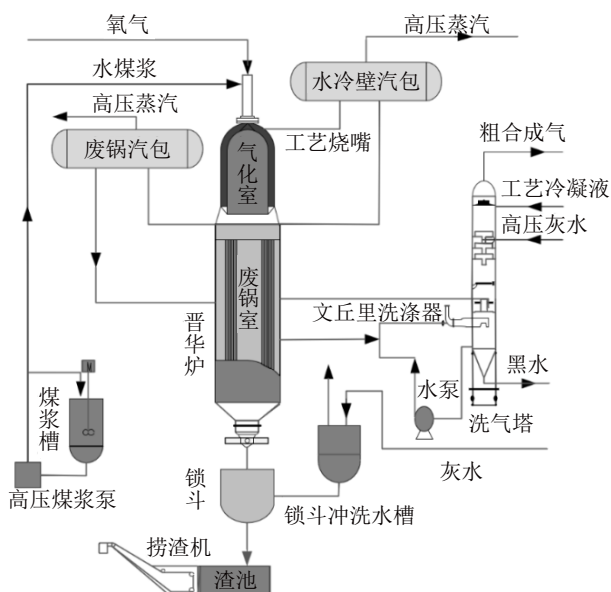


图1 晋华炉工艺流程




图2 输入特征变量与目标变量相关性热力图

度和烧嘴压差等的影响则相对较弱, 氧气总管温度与氢气比例和一氧化碳比例相关性仅为-0.395和0.052. 相关性分析揭示了氢气比例和一氧化碳比例主要受废锅汽包蒸汽流量和气化炉温度的共同作用. 通过计算各操作变量与目标变量的平均绝对相关性, 选取相关系数大于 0.4 的特征作为模型输入, 最终确定了 7 个关键操作特征作为模型输入. 所选取的 7 个输入变量既能够表征输出特征变量, 又不会太过于冗余导致过拟合, 具体变量及其物理意义如表 1 和表 2 所示.

2.2 双通道 CNN-LSTM-Attention 预测模型

CNN-LSTM-Attention 结合了卷积神经网络 (CNN)、长短期记忆网络 (LSTM) 以及注意力机制 (Attention) 的特点, 既能够获取时间特征也能获取空间特征, 强化关键特征的建模能力^[25].

在晋华炉获取的煤气化数据中, CNN 可以提取空间特征以及输入与输出变量间的耦合关系. 池化

表1 输入特征变量

排序	符号	描述	单位
1	X_1	气化炉辐射废锅内部下温度	$^{\circ}\text{C}$
2	X_2	废锅汽包蒸汽流量	m^3/s
3	X_3	气化炉辐射废锅内部上温度	$^{\circ}\text{C}$
4	X_4	气化炉燃烧室环腔温度A	$^{\circ}\text{C}$
5	X_5	气化炉燃烧室环腔温度B	$^{\circ}\text{C}$
6	X_6	气化炉出口合成气温度B	$^{\circ}\text{C}$
7	X_7	气化炉燃烧室水冷壁温度B	$^{\circ}\text{C}$

表2 输出特征变量 (预测目标)

排序	符号	描述	单位
1	Y	气化炉燃烧室压力	MPa
2	Y_1	氢气(比例)	%
3	Y_2	一氧化碳(比例)	%

层通过对卷积结果进行降维和压缩, 提取出重要特征, 以此减少网络参数^[26]. 卷积层与池化层的堆叠, 使得输入数据逐步转化为更加抽象且具有判别力的特征表示. 全连接层将池化层输出的三维张量变为

向量的形式, 传递给下一层. 输出层接收来自全连接层的输出作为输入, 经计算后得到的结果即为整个神经网络的最终输出.

在煤气化炉预测建模中, 卷积神经网络 (CNN) 被用于提取输入工业过程数据中的局部特征和时序相关性. 假设输入的过程数据序列可表示为

$$X = \{x_1, x_2, \dots, x_T\}, x_i \in \mathbb{R}^d. \quad (2)$$

其中: T 为时间步长, d 为输入特征维度.

通过卷积运算得到卷积层的输出特征, 经多组卷积核的堆叠, 可得到综合特征表示, 如下所示:

$$H = [H^{(1)}, H^{(2)}, \dots, H^{(K)}], \quad (3)$$

其中 K 为卷积核的数量. 随后, 卷积特征可通过池化操作进行降维和噪声抑制, 其数学形式为

$$\tilde{h}_j = \text{pool}(\{h_{(j-1)r+1}, \dots, h_{jr}\}). \quad (4)$$

这里: r 为池化窗口大小, $\text{pool}(\cdot)$ 表示平均池化操作.

通过上述卷积和池化操作, 模型能够有效提取煤气化过程中的多尺度特征, 为后续的序列建模提供低维且信息丰富的输入特征表示. 长短期记忆网络 (LSTM) 作为循环神经网络 (RNN) 的改进形式, 能够有效解决 RNN 在处理长时序数据时的梯度消失问题, 进而克服长期依赖难题^[27].

利用卷积神经网络计算后得到的输出序列特征 $H = [H^{(1)}, H^{(2)}, \dots, H^{(K)}]$ 作为 LSTM 输入, 通过遗忘门决定前一时刻的记忆单元状态中有多少信息需要被遗忘, 然后通过输入门决定当前输入信息中有多少被写入记忆单元, 并生成候选记忆, 再进行状

态的更新整合历史和当前信息, 最后通过输出门决定输出多少当前状态得到 LSTM 的隐藏状态序列, 有

$$H = \{h_1, h_2, \dots, h_T\}. \quad (5)$$

对于多输出预测任务, 如气化炉合成气中氢气比例和一氧化碳比例, 将最后时刻的隐藏状态 h_T 输入至全连接层, 如下所示:

$$\hat{y} = W_y h_T + b_y. \quad (6)$$

所提出双通道 CNN-LSTM-Attention 网络模型是由 CNN 网络、LSTM 网络与 Attention 组合而成的复合模型, 具体结构如图 3 所示. 双通道 CNN-LSTM-Attention 模型整合了三者优势, 首先, 通过 CNN 对时间序列数据进行特征提取, 生成压缩的特征; 然后, 将这些压缩的特征输入至 LSTM, 完成时间维度的建模; 最后, 利用层次化注意力机制对 LSTM 输出进行优化, 使得模型能够根据任务需求动态获取关键特征, 实现更准确的预测和分析.

所提出模型由输入特征通道和目标特征通道组成, 两者并行工作, 能够区分外部输入变量与历史目标序列, 从而避免单通道结构中不同信息来源导致的特征稀释问题. 传统的单通道结构是将所有输入包括外部工艺变量和历史目标序列, 杂糅在一起拼接为单一的输入序列再进行特征提取和预测, 对输入特征进行建模, 并未区分不同特征子集间的差异. 其公式可表示为

$$H_t = \text{LSTM}(\text{CNN}(X_{1:T})), \hat{y}_{t+1} = f(H_t). \quad (7)$$

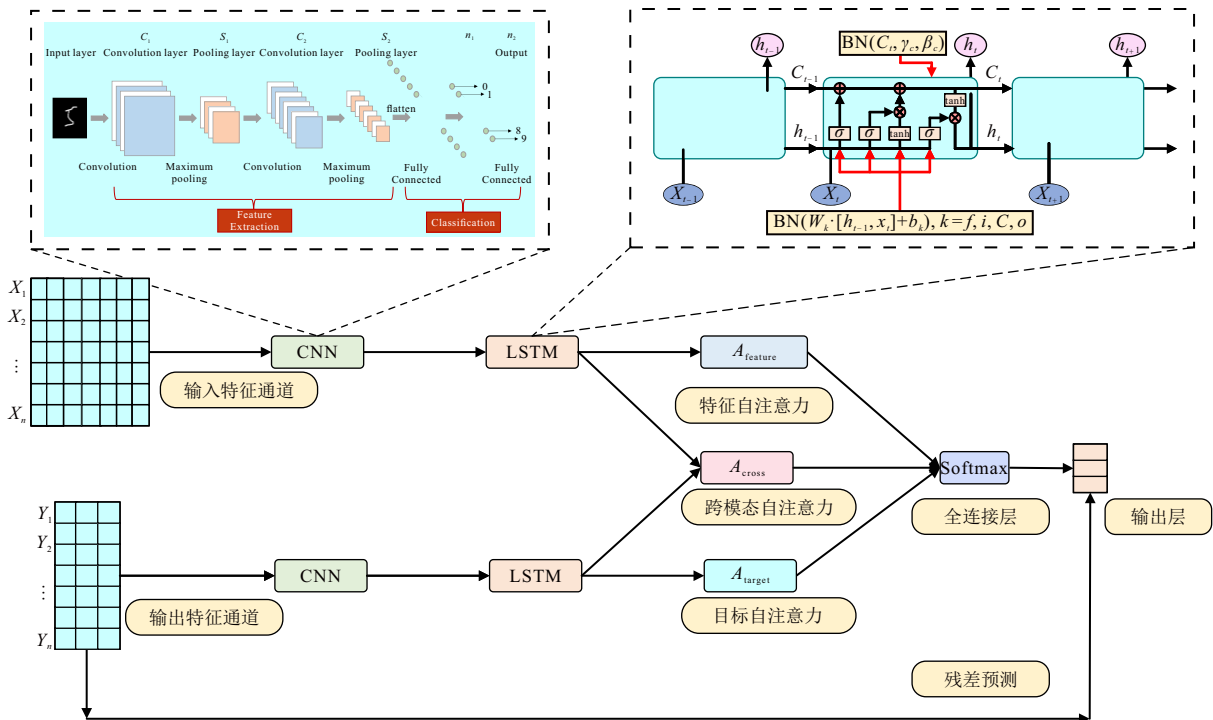


图3 双通道 CNN-LSTM-Attention 模型结构

其中: $X_{1:T} \in \mathbb{R}^{T \times d}$ 表示长度为 T 的多维输入特征, H_t 为隐状态, \hat{y}_{t+1} 为预测结果. 双通道结构则是将输入进行区分, 将输入划分为两个并行通道, 分别建模不同特征子集的时序规律: 一部分为外部的输入特征 $\{X_t\}_{t=1}^T$, 如气化炉辐射废锅内部上下温度等; 另外一部分则是历史目标特征 $\{Y_t\}_{t=1}^T$, 如氢气比例和一氧化碳比例. 两个序列分别通过互不干扰的 CNN-LSTM 子网络提取出时间和空间特征, 最终在融合层实现信息交互. 其公式可表示为

$$H_t^{(x)} = \text{LSTM}_x(\text{CNN}_x(X_{1:T})), \quad (8)$$

$$H_t^{(y)} = \text{LSTM}_y(\text{CNN}_y(Y_{1:T})), \quad (9)$$

$$H_t = \text{Fusion}(H_t^{(x)}, H_t^{(y)}), \quad \hat{y}_{t+1} = f(H_t), \quad (10)$$

这里 $\text{Fusion}(\cdot)$ 则是通过层次注意力机制进行动态融合. 层次化注意力机制由特征自注意力、目标自注意力和跨模态注意力 3 部分组成, 通过多层次的信息融合和权重分配, 有效提取关键特征. 特征自注意力通过为不同输入变量分配权重, 使得模型能够突出对预测目标最敏感的特征, 弱化冗余特征的影响, 实现对输入信息的筛选和优化, 如下所示:

$$A_{\text{feature}}(X) = \text{softmax}\left(\frac{Q_f K_f^T}{\sqrt{d_k}}\right) V_f. \quad (11)$$

其中: Q_f 、 K_f 、 V_f 分别由输入特征序列、 $X \in \mathbb{R}^{T \times d}$ 经线性变换得到, $\sqrt{d_k}$ 为缩放因子. 通过特征注意力机制能够突出对输出变量影响显著的特征变量. 目标自注意力则用于长时间序列建模中. 由于不同目标变量间往往存在耦合关系, 通过在输出层建立目标间的相互关系, 可增强模型对变量间依赖性的捕捉能力, 以此提升预测的针对性, 有

$$A_{\text{target}}(Y) = \text{softmax}\left(\frac{Q_t K_t^T}{\sqrt{d_k}}\right) V_t, \quad (12)$$

这里 $Y \in \mathbb{R}^{T \times m}$ 为历史目标序列, 目标自注意机制则是突出目标特征间的相互关系. 最后, 跨模态注意力机制是在多输出预测场景下, 使得模型能够实现不同模态间的信息融合和交互, 利用输入特征信息与输出特征信息的互补性, 提升预测的准确性, 如下所示:

$$A_{\text{cross}}(X, Y) = \text{softmax}\left(\frac{Q_c K_c^T}{\sqrt{d_k}}\right) V_c. \quad (13)$$

其中: Q_c 为输入特征通道; K_c 和 V_c 则是来自目标特征通道, 通过跨模态注意力机制找到输入特征与输出特征间的相互关系. 对这三者加权融合, 有

$$A(z) = \alpha A_{\text{feature}}(X) + \beta A_{\text{target}}(Y) + \gamma A_{\text{cross}}(X, Y), \quad (14)$$

这里 α 、 β 、 γ 为 3 个权重系数, 在神经网络训练过程自动学习.

所提出预测模型的数据处理流程可概括为 5 个步骤:

- 1) 将输入的时间序列利用双通道转换为神经网络所需要的矩阵形;
- 2) 将该矩阵输入 CNN 网络进行特征提取和降维;
- 3) 将提取的特征序列送入 LSTM 网络进行训练;
- 4) 通过多层次 Attention 机制对 LSTM 网络的输出进行自动加权平均计算;
- 5) 利用全连接层完成预测结果的计算.

3 操作优化模型

在气化炉工况优化问题中, 本文的优化目标为同时最大化氢气比例和一氧化碳比例. 在煤气化过程, 氢气主要通过水煤气反应生成, 而一氧化碳则主要来自部分氧化反应、水煤气反应和二次反应. 由于两者的生成途径存在一定的冲突, 提高氢气比例往往会降低一氧化碳比例, 反之亦然, 因此, 该问题属于典型的多目标优化问题.

考虑到多目标优化在工业场景下通常需要兼顾求解效率与可实现性, 本文将多目标优化转化为单目标优化问题进行求解. 具体而言, 采用加权和法对多个目标进行归一化处理, 并构建综合评价函数, 如下所示:

$$F(x) = \alpha \cdot f_{\text{H}_2}(x) + \beta \cdot f_{\text{CO}}(x). \quad (15)$$

其中: $f_{\text{H}_2}(x)$ 和 $f_{\text{CO}}(x)$ 分别为以氢气和一氧化碳比例作为输出构建的神经网络函数; α 、 β 为权重系数, 根据生产需求设定; x 为 7 个输入特征变量. 通过将多目标问题转化为单目标问题再采用启发式算法进行输入和输出特征参数寻优.

构建含有优化目标以及约束条件的操作优化模型, 如下所示:

$$\begin{aligned} \max_x F(x) &= (\alpha \cdot f_{\text{H}_2}(x) + \beta \cdot f_{\text{CO}}(x)); \\ \text{s.t. } &(f_{\text{H}_2}(x) + f_{\text{CO}}(x))_{\text{lb}} \leq \\ &(f_{\text{H}_2}(x) + f_{\text{CO}}(x)) \leq 100\%, \\ &x \in [x_{\text{lb}}, x_{\text{ub}}], \\ &f_{P,\text{lb}}(x) \leq f_P(x) \leq f_{P,\text{ub}}(x). \end{aligned} \quad (16)$$

其中: $\alpha = \beta = 0.5$, 输入特征的下限值表示为 x_{lb} , 输出特征的上限值表示为 x_{ub} , $f_P(x)$ 为气化炉燃烧室压力, $f_{P,\text{lb}}(x)$ 、 $f_{P,\text{ub}}(x)$ 分别为气化炉燃烧室压力下限和上限值.

粒子群优化 (PSO) 算法具备实现简便、所需参数少、全局搜索能力突出等优势^[28], 因此, 在函数优

化、神经网络训练以及工业过程建模等领域得到了广泛应用. 尤其是在应对非线性、高维优化问题时, PSO 算法通常能够以较快的收敛速度获取近似全局最优解, 展现出较强的实用价值^[29]. 因此, 本文采用 PSO 算法求解优化模型 (16).

4 煤气化运行优化实验分析

4.1 实验设计

本节将对所提出双通道 CNN-LSTM-Attention 深度学习模型进行实验模拟. 首先, 对所提出模型进行消融实验, 以此验证各模块的有效性, 分别对比 CNN-LSTM-Attention、CNN-LSTM、LSTM-Attention、双通道 LSTM 与 CNN 对于不同输出目标的预测结果; 同时, 为验证所提出方法的可行性, 选择常用于煤气化过程建模的深度学习模型进行对比实验, 包括 LSTM 模型、ANN 和 Transform.

本研究的数据来源于某化工企业工业气化炉的 DCS 系统, 涵盖了主要操作参数和产出指标. 为保证数据质量, 在数据处理过程中剔除了明显异常点. 本文采集 2025 年 5 月 1 日 ~ 2025 年 5 月 23 日期间满负荷运行的数据, 采集周期为 8 min, 共获得 3961 个时间样本. 其中: 2773 个 (70%) 用于训练集, 396 个 (10%) 用于验证集, 792 个 (20%) 用于测试集.

4.2 预测性能评价

为了对比不同模型的有效性, 选择测试数据集的平均绝对误差 (MAE)、均方根误差 (RMSE)、判定系数 (R^2) 作为评价指标来评估预测性能. 其定义如下.

平均绝对误差 (MAE) 为

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|; \quad (17)$$

均方根误差 (RMSE) 为

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (18)$$

判定系数 (R^2) 为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (19)$$

其中: y_i 为真实值, \hat{y}_i 为预测值, \bar{y} 为真实值的均值, n 为样本数. MAE 衡量预测值与真实值间的平均绝对偏差, 反映了模型预测的整体偏差水平, 数值越小, 模型预测精度越高; 采用 RMSE 评估一般预测误差, RMSE 越低, 模型预测的精度越高^[30]; R^2 可评估实际

值与预测输出间的相关性^[31], R^2 值越高, 预测效果越好. 所提出双通道 CNN-LSTM-Attention 模型对气化炉燃烧室压力、氢气比例以及一氧化碳比例评价指标如表 3 所示.

表3 CNN-LSTM-Attention 模型评价指标

输出特征	MAE	RMSE	R^2
气化炉燃烧室压力	0.00515	0.00661	0.9344
氢气比例	0.03148	0.05047	0.93205
一氧化碳比例	0.14856	0.36899	0.96346

为验证所提出模型各组成模块的有效性, 本文设计并开展消融实验. 实验以完整的双通道 CNN-LSTM-Attention 结构为基准, 分别移除其中的卷积特征提取模块 (CNN)、时序建模模块 (LSTM) 以及注意力机制模块 (Attention). 通过对比各变体模型在 RMSE、MAE 与 R^2 指标上的表现, 评估不同模块对于模型整体性能的不同作用.

消融实验结果如表 4 和表 5 所示, 分别给出了不同模型在氢气比例和一氧化碳比例预测中的评价指标. 图 4 和图 5 为预测值与实际值的对比情况, 实际值均来自于生产现场 DCS 系统实时采集的工业测量值, 因此, 能够真实反映煤气化炉的运行状态. 模型预测结果与其对比, 能够直观地展示模型对实际工业过程的拟合和预测能力. 实验结果表明, 当移除 CNN 模块后, 模型在时序特征提取方面的能力下降, RMSE 显著增大 (增加 10.9%), 表明卷积层在捕捉局部时序模式中具有重要作用. 进一步比较 CNN-LSTM-Attention 与 CNN-LSTM 模型可以发现, 当移除多层次注意力模块后, 模型在关键特征权重分配方面的能力不足, 导致预测精度下降. 其中: 氢气比例预测准确性降低了 1.5%, 一氧化碳比例预测准确性降低了 2.2%. 这表明多层次注意力机制能够有效增强模型对于关键时序特征的敏感性, 从而显著提升预测性能. 综上所述, 消融实验结果充分验证了卷

表4 气化炉氢气 (比例) 预测消融实验结果

模型结构	CNN-LSTM-Attention	CNN-LSTM	LSTM-Attention	双通道 LSTM	CNN
RMSE	0.07047	0.07742	0.07818	0.07543	0.07264
MAE	0.03148	0.03426	0.03186	0.03178	0.03240
R^2	0.93205	0.91835	0.92685	0.92872	0.92851

表5 气化炉一氧化碳 (比例) 预测消融实验结果

模型结构	CNN-LSTM-Attention	CNN-LSTM	LSTM-Attention	双通道 LSTM	CNN
RMSE	0.36899	0.37290	0.37209	0.37053	0.37327
MAE	0.14856	0.15586	0.15285	0.14791	0.14950
R^2	0.96346	0.94268	0.95364	0.95769	0.94368

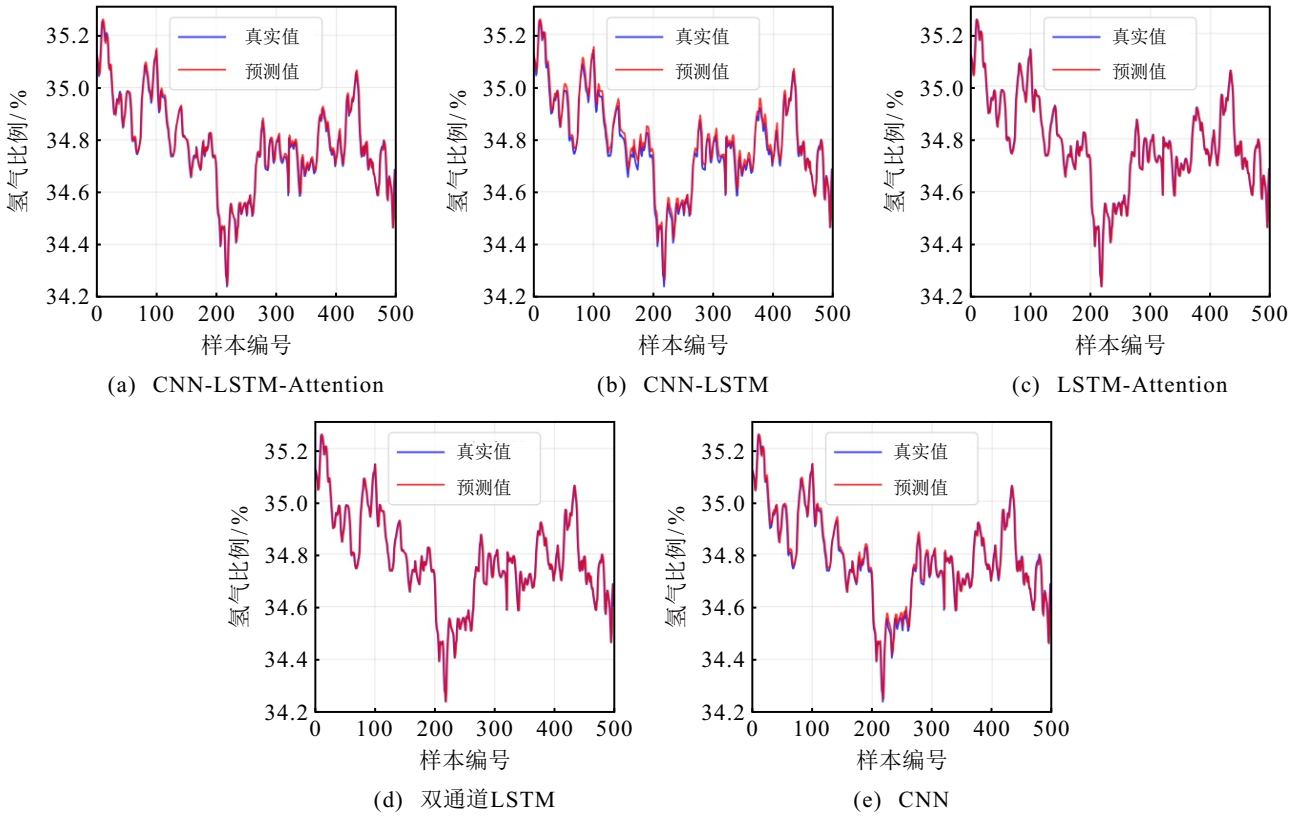


图4 消融实验中不同模型对氢气的预测结果对比

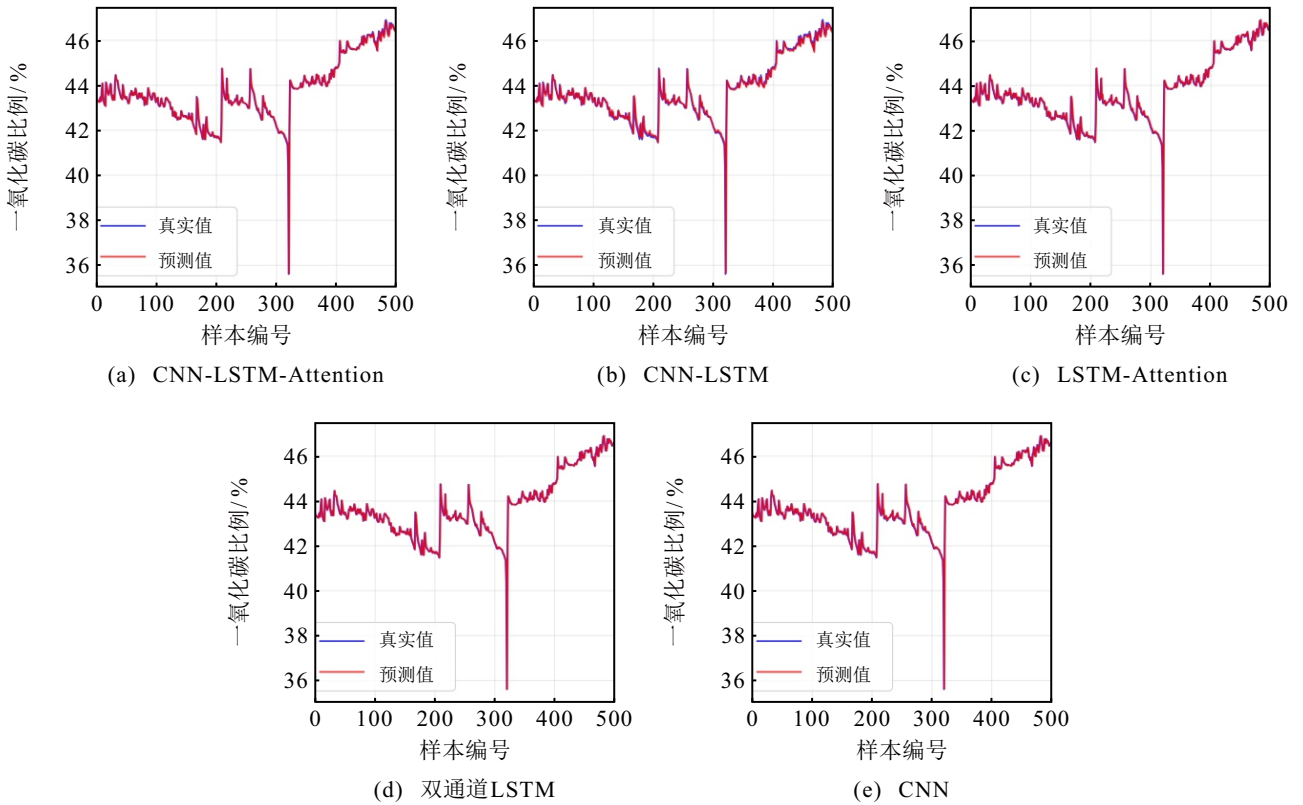


图5 消融实验中不同模型对一氧化碳的预测结果对比

积层和多层次注意力机制在模型预测中的重要作用.

然而,仅验证模型内部模块的有效性无法验证相比于其他模型所提出模型的先进性.为进一步评估所提出模型在实际应用场景中的有效性,需要通


过对比实验全面分析双通道 CNN-LSTM-Attention 模型的整体性能优势.具体而言,本文选取 3 类典型深度学习模型作为对比模型:传统 LSTM、ANN 以及 Transformer.所有对比实验均基于相同数据集与

一致实验设置开展, 同样采用均方根误差 (RMSE)、平均绝对误差 (MAE) 以及判定系数 (R^2) 作为评价指标.


不同模型在氢气比例预测任务中的评价指标如表 6 所示, 其预测值与实际值的对比情况如图 6 所示. 实验结果表明, 所提出 CNN-LSTM-Attention 模型在各项指标上均优于其他对比模型. 具体而言, 在

表6 不同模型在氢气 (比例) 预测上不同表现


模型结构	CNN-LSTM-Attention	LSTM	ANN	Transform
RMSE	0.07047	0.07625	0.08314	0.07353
MAE	0.03148	0.03178	0.03825	0.03511
R^2	0.93205	0.92146	0.91764	0.91846




(a) CNN-LSTM-Attention



(b) LSTM



(c) ANN



(d) Transformer

图6 对比实验中不同模型对氢气的预测结果

均方根误差 (RMSE) 方面, 该模型取得了 0.07047 的最优结果, 优于 Transformer (0.07353), 并显著低于 LSTM (0.07625) 与 ANN (0.08314); 在拟合度方面, 其判定系数 (R^2) 达到了 0.93205, 高于 LSTM (0.93046)、ANN (0.91764) 与 Transformer (0.91846). 这些结果表明, CNN-LSTM-Attention 模型在氢气比例预测中表现出更高的精度和鲁棒性, 相较于传统深度学习模型更具优势, 显示出良好的应用潜力.

不同模型在氢气预测任务中的评价指标如表 7 所示, 各模型在氢气预测中的实际值与预测值对比情况如图 7 所示. 由表 7 的结果可见, 在一氧化碳比例预测任务中, CNN-LSTM-Attention 模型整体表现最优. 具体而言, 在均方根误差 (RMSE) 方面, 该模型相较于表现最佳的传统深度学习模型有 2.7% 的提升; 同时, 其判定系数 (R^2) 达到 0.96346, 显著高于其他对比模型. 上述结果表明, CNN-LSTM-Attention 模型能够有效提取时序数据中的时空特征, 并在拟合精度和泛化能力上均展现出优越性能.

表7 不同模型在一氧化碳 (比例) 预测上不同表现

模型结构	CNN-LSTM-Attention	LSTM	ANN	Transform
RMSE	0.36899	0.38832	0.37877	0.37768
MAE	0.14856	0.15538	0.15480	0.15803
R^2	0.96346	0.93659	0.94768	0.94939

通过对比双通道 LSTM 与传统单通道 LSTM 的实验结果可以发现, 在氢气比例和一氧化碳比例的预测任务中, 双通道 LSTM 的判定系数显著高于传统 LSTM, 而其均方根误差则明显更低. 这进一步验证了双通道结构在提升模型预测精度方面的有效性和优越性.

4.3 优化性能评价

在本文中, 每个粒子对应气化炉运行条件的一组输入参数组合, 如气化炉辐射废锅内部上、下温度等, 其位置向量表示候选操作点, 而适应度函数由预测模型输出的目标性能指标计算得到. PSO 通过群体中粒子间的信息交互不断调整输入变量组合, 逐步逼近最优运行条件.

实验中, 粒子群优化算法 (PSO) 的参数设置如下: 惯性权重 $w = 0.6$, 认知系数 $c_1 = 1.5$, 社会系数 $c_2 = 1.5$, 群体规模设置为 50, 最大迭代次数为 200. 粒子速度^[32] 采用如下公式更新:

$$v_i^{t+1} = wv_i^t + c_1r_1(\text{pbest}_i - x_i^t) + c_2r_2(\text{gbest} - x_i^t). \quad (20)$$

其中: v_i^t 和 x_i^t 分别为第 t 代时第 i 个粒子的速度和位置, pbest_i 为该粒子历史最优位置, gbest 为全局最优

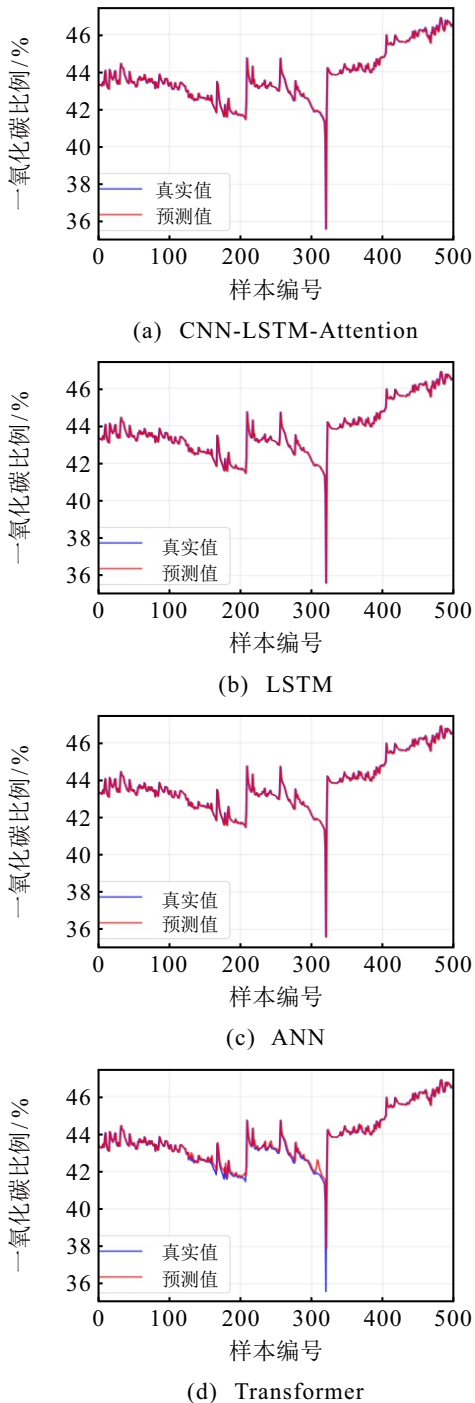


图7 对比实验中不同模型对一氧化碳的预测结果

位置, $r_1, r_2 \sim U(0, 1)$. 为避免粒子过快发散, 将速度设置上限为搜索区间宽度的 20%, 即 $v_{max} = 0.2 \times (x_{max} - x_{min})$. 同时, 粒子位置也要满足在历史数据的变化范围中, 以保证所得到解的结果的合理性和有效性, 具体输入特征的上下限值如表 8 所示.


采用粒子群优化方法对晋华炉气化炉运行工况进行寻优, 得到的优化结果对应的输入-输出变量值如表 9 所示. 粒子群优化过程以及所获取到的最优特征参数如图 8 所示. 在获取到的最优工况下, 合成气中氢气比例达到 35.81%, 一氧化碳比例为 42.39%, 均优于基准工况下的预测水平. 结果表明,

表8 输入特征的上下限


输入特征	符号/单位	上限值	下限值
气化炉辐射废锅内部下温度	$X_1/^\circ\text{C}$	820	1080
废锅汽包蒸汽流量	$X_2/(\text{m}^3/\text{s})$	17000	35000
气化炉辐射废锅内部上温度	$X_3/^\circ\text{C}$	930	1140
气化炉燃烧室环腔温度A	$X_4/^\circ\text{C}$	240	252
气化炉燃烧室环腔温度B	$X_5/^\circ\text{C}$	235	247
气化炉出口合成气温度B	$X_6/^\circ\text{C}$	200	213
气化炉燃烧室水冷壁温度B	$X_7/^\circ\text{C}$	270	275

表9 粒子群优化结果

输入输出变量	优化值/单位
气化炉辐射废锅内部下温度	841.6/ $^\circ\text{C}$
废锅汽包蒸汽流量	28150/ (m^3/s)
气化炉辐射废锅内部上温度	1050/ $^\circ\text{C}$
气化炉燃烧室环腔温度A	251.7/ $^\circ\text{C}$
气化炉燃烧室环腔温度B	244.8/ $^\circ\text{C}$
气化炉出口合成气温度B	211.4/ $^\circ\text{C}$
气化炉燃烧室水冷壁温度B	272.2/ $^\circ\text{C}$
气化炉燃烧室压力	6.4346/MPa
氢气(比例)	35.8109/%
一氧化碳(比例)	42.3903/%



(a) 粒子群优化过程



(b) 最优特征参数

图8 粒子群优化过程以及最优特征参数

PSO 可以在较少迭代次数内实现快速收敛, 并明显提高了氢气和一氧化碳的比例. 该结果验证了粒子群优化方法在气化炉运行参数寻优中的有效性和适用性.

在原始工况下, 合成气中氢气比例为 35.38%, 一氧化碳比例为 41.76%, 总体有效气含量为 77.14%.

经粒子群优化 (PSO) 对运行参数进行寻优后, 氢气比例提升至 35.81%, 一氧化碳比例提升至 42.39%, 总体有效气含量达到 78.20%。相较于原始最低工况, 氢气比例提高了 1.22%, 一氧化碳比例提高了 1.51%, 总体有效气含量提升幅度达到 1.38%。结果表明, PSO 可在较少迭代次数内实现稳定收敛, 且能够有效提高晋华炉当中氢气和一氧化碳的比例。

5 结论

本文提出了基于 CNN-LSTM-Attention 预测模型的晋华炉气化炉操作优化方法。通过引入双通道输入结构和层次化注意力机制, 提升了煤气化过程特征提取能力, 提高了预测模型精度。以氢气和一氧化碳比例最大化为优化目标, 该方法能够有效提高合成气产率。对比实验结果表明, CNN-LSTM-Attention 模型的预测精度优于传统的 ANN、LSTM、Transform 模型, 其 R^2 更高、RMSE 更低, 验证了该方法在关键气体组分预测上的优势。进一步结合粒子群优化算法, 氢气和一氧化碳比例均较原始工况实现了明显提升, 从而为晋华炉的高效运行和经济效益改善提供了有力支撑。

参考文献 (References)

- [1] Chen C J, Hung C I, Chen W H. Numerical investigation on performance of coal gasification under various injection patterns in an entrained flow gasifier[J]. *Applied Energy*, 2012, 100: 218-228.
- [2] Chen X D, Kong L X, Bai J, et al. The key for sodium-rich coal utilization in entrained flow gasifier: The role of sodium on slag viscosity-temperature behavior at high temperatures[J]. *Applied Energy*, 2017, 206: 1241-1249.
- [3] Wagner N J, Coertzen M, Matjie R H, et al. Coal gasification[M]. Amsterdam: Elsevier, 2008.
- [4] Breault R W. Gasification processes old and new: A basic review of the major technologies[J]. *Energies*, 2010, 3(2): 216-240.
- [5] 张志华, 白金锋, 刘洋, 等. 煤炭气化过程数学模型构建的研究进展[J]. *煤炭科学技术*, 2019, 47(11): 196-205.
(Zhang Z H, Bai J F, Liu Y, et al. Progress on mathematical models construction in coal gasification process[J]. *Coal Science and Technology*, 2019, 47(11): 196-205.)
- [6] Faridi I K, Tsotsas E, Heineken W, et al. Spatio-temporal prediction of temperature in fluidized bed biomass gasifier using dynamic recurrent neural network method[J]. *Applied Thermal Engineering*, 2023, 219: 119334.
- [7] Wang H, Ricardez-Sandoval L A. Dynamic optimization of a pilot-scale entrained-flow gasifier using artificial recurrent neural networks[J]. *Fuel*, 2020, 272: 117731.
- [8] Zhao Y B, Ma Z B, Han X F. Research on multi-step mixed prediction model of coal gasifier furnace temperature based on machine learning[C]. *Journal of Physics: Conference Series*. Zhuhai, 2022: 012070.
- [9] Wang K C, Zhang J, Shang C, et al. Operation optimization of Shell coal gasification process based on convolutional neural network models[J]. *Applied Energy*, 2021, 292: 116847.
- [10] Baruah D, Baruah D C, Hazarika M K. Artificial neural network based modeling of biomass gasification in fixed bed downdraft gasifiers[J]. *Biomass and Bioenergy*, 2017, 98: 264-271.
- [11] An T H, Park S, Yoon S M, et al. Prediction of syngas composition in entrained flow gasification systems using a Transformer-based deep learning model[J]. *Journal of Environmental Chemical Engineering*, 2025, 13(5): 117526.
- [12] 王恺洲, 韩洋, 仇鹏, 等. 基于 BPNN-SVM-ELM 融合算法的气化炉预测模型[J]. *华东理工大学学报: 自然科学版*, 2024, 50(2): 161-169.
(Wang K Z, Han Y, Qiu P, et al. A prediction model of gasifier based on BPNN-SVM-ELM fusion algorithm[J]. *Journal of East China University of Science and Technology: Natural Science Edition*, 2024, 50(2): 161-169.)
- [13] 孙漾. 面向水煤浆气化装置的过程建模与操作优化技术[D]. 上海: 华东理工大学, 2012.
(Sun Y. Process modeling and operation optimization technology for coal-water slurry gasification plant[D]. Shanghai: East China University of Science and Technology, 2012.)
- [14] Wang H, Chaffart D, Ricardez-Sandoval L A. Modelling and optimization of a pilot-scale entrained-flow gasifier using artificial neural networks[J]. *Energy*, 2019, 188: 116076.
- [15] An H Q, Liu Z, Tian F C. A machine learning framework for coal gasification process simulation and operation optimization[J]. *Fuel*, 2025, 401: 135934.
- [16] Tornyeviadzi H M, Seidu R. Leakage detection in water distribution networks via 1D CNN deep autoencoder for multivariate SCADA data[J]. *Engineering Applications of Artificial Intelligence*, 2023, 122: 106062.
- [17] 李子正, 李相军, 李朝勇. 晋华炉水煤浆气化技术简介[J]. *化肥工业*, 2019, 46(1): 50-52.
(Li Z Z, Li X J, Li C Y. Brief introduction to coal-water slurry gasification technology of Jinhua gasifier[J]. *Chemical Fertilizer Industry*, 2019, 46(1): 50-52.)
- [18] 徐鹏, 隋志涛, 徐玉花. 晋华炉 3.0 气化装置开车总结[J]. *氮肥与合成气*, 2025, 53(7): 39-41.
(Xu P, Sui Z T, Xu Y H. Summary of the start-up of Jinhua furnace 3.0 gasification plant[J]. *Nitrogen Fertilizer and Syngas*, 2025, 53(7): 39-41.)
- [19] 汪家铭. 水煤浆水冷壁气化技术及其应用[J]. *化学工业*, 2012, 30(10): 30-33.
(Wang J M. Gasification technology and application of coal-water slurry water wall[J]. *Chemical Industry*, 2012, 30(10): 30-33.)

- [20] 刘孝弟, 张勇, 顾学颖. 水煤浆加压气化技术的发展途径探讨[J]. 化工设计通讯, 2013, 39(01): 5-8.
(Liu X D, Zhang Y, Gu X Y. Discussion on the development path of coal water slurry pressurized gasification technology[J]. Chemical Design Newsletter, 2013, 39(01): 5-8.)
- [21] Liu Y Q, Mu Y, Chen K Y, et al. Daily activity feature selection in smart homes based on Pearson correlation coefficient[J]. *Neural Processing Letters*, 2020, 51(2): 1771-1787.
- [22] Weisstein E W. Correlation coefficient[EB/OL]. (2025-10-30)[2025-11-03]. <https://mathworld.wolfram.com/CorrelationCoefficient.html>.
- [23] Okwonu F Z, Chiyeaka O M, Ahad N A, et al. Robust Pearson correlation coefficient for imbalanced sample size and high dimensional data set[J]. *Science World Journal*, 2025, 20(1): 131-136.
- [24] Xu B, Chen Z Y, Wang X, et al. Combined prediction model of concrete arch dam displacement based on cluster analysis considering signal residual correction[J]. *Mechanical Systems and Signal Processing*, 2023, 203: 110721.
- [25] Zhang Y S, Zheng J, Jiang Y R, et al. A text sentiment classification modeling method based on coordinated CNN-LSTM-attention model[J]. *Chinese Journal of Electronics*, 2019, 28(1): 120-126.
- [26] 杜先君, 巩彬, 余萍, 等. 基于 CBAM-CNN 的模拟电路故障诊断[J]. 控制与决策, 2022, 37(10): 2609-2618.
(Du X J, Gong B, Yu P, et al. CBAM-CNN based analog circuit fault diagnosis[J]. Control and Decision, 2022, 37(10): 2609-2618.)
- [27] 赵小强, 脱奔奔, 惠永永, 等. 基于 ISTA-LSTM 模型的间歇过程质量预测[J]. 控制与决策, 2023, 38(11): 3279-3289.
(Zhao X Q, Tuo B B, Hui Y Y, et al. Batch process quality prediction based on ISTA-LSTM model[J]. Control and Decision, 2023, 38(11): 3279-3289.)
- [28] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proceedings of ICNN'95 — International Conference on Neural Networks. Perth, 1995: 1942-1948.
- [29] Yuan Q, Yin G. Analyzing convergence and rates of convergence of particle swarm optimization algorithms using stochastic approximation methods[J]. *IEEE Transactions on Automatic Control*, 2015, 60(7): 1760-1773.
- [30] 王宇超, 赵洵, 杨周琦, 等. 基于 SCI-CA 模型的船舶纵摇多维多步预测方法[J]. 控制与决策, 2025, 40(1): 64-70.
(Wang Y C, Zhao X, Yang Z Q, et al. Multi-dimensional and multi-step prediction method for ship pitching based on SCI-CA model[J]. Control and Decision, 2025, 40(1): 64-70.)
- [31] Prairie Y T. Evaluating the predictive power of regression models[J]. *Canadian Journal of Fisheries and Aquatic Sciences*, 1996, 53(3): 490-492.
- [32] Wang D S, Tan D P, Liu L. Particle swarm optimization algorithm: An overview[J]. *Soft Computing*, 2018, 22(2): 387-408.

作者简介

韩永明 (1987-), 男, 教授, 博士, 博士生导师, 主要研究方向为人工智能、数据挖掘、机器学习、能效分析、智能优化, E-mail: hanym@mail.buct.edu.cn;

李帅 (2000-), 男, 硕士生, 主要研究方向为数据驱动建模、多目标优化, E-mail: 2024200744@buct.edu.cn;

耿志强 (1973-), 男, 教授, 博士, 博士生导师, 主要研究方向为工业大数据与机器学习、智能优化与控制、异常监测与故障诊断, E-mail: gengzhiqiang@mail.buct.edu.cn;

汪京培 (1983-), 男, 副研究员, 博士, 主要研究方向为人工智能、网络空间安全, E-mail: wjp@csu.ac.cn;

王孟志 (1988-), 男, 副教授, 博士, 主要研究方向为数据驱动模型预测控制、先进过程控制、智能优化决策, E-mail: wangmz@buct.edu.cn.