

基于知识与数据融合驱动的转炉炼钢供氧量预测方法

刘 晶^{1,2}, 蒋文杰¹, 冯海领³, 张海滨⁴, 季海鹏^{2,3,5}

(1. 河北工业大学 人工智能与数据科学学院, 天津 300401; 2. 高性能轧辊材料与复合成形全国重点实验室, 天津 300400; 3. 天津开发区精诺瀚海数据科技有限公司, 天津 300400; 4. 河钢数字技术股份有限公司, 河北 石家庄 050000; 5. 河北工业大学 材料科学与工程学院, 天津 300401)

摘 要: 针对在转炉炼钢过程中传统供氧量预测方法存在领域知识与数据驱动模型割裂的问题, 提出一种基于知识与数据融合驱动的转炉炼钢供氧量预测方法。首先, 构建三级知识融合模块, 将冶金机理嵌入深度学习模型; 其次, 设计双分支架构协同挖掘工艺特征与跨炉次时序规律; 最后, 采用某钢厂的实际生产数据进行实验。实验结果表明: 相比 GBRBM-DBN、HyGPR、Stacking 和 BOA-LGBM 等主流方法, 在 SPHC 钢种下供氧量的 MAE 和 RMSE 最高分别降低 7.59% 和 6.80%, 准确率(相对误差 $\pm 5\%$)达到 85.29%; 在 HRB400E 钢种下 MAE 和 RMSE 最高分别降低 15.24% 和 15.13%, 准确率(相对误差 $\pm 5\%$)达到 87.91%, 验证了所提方法的供氧量预测能力。

关键词: 融合驱动; 协同建模; 双分支; 转炉炼钢; 供氧量预测

中图分类号: TP301.6; TF713

文献标志码: A

doi: 10.13705/j.issn.1671-6833.2026.04.013

转炉炼钢通过向铁水吹氧去除杂质并生成气体和炉渣, 是目前应用最广泛的炼钢工艺之一^[1-2]。供氧量直接影响能耗、成本及钢水成分; 过量供氧会造成能源浪费并恶化钢的化学成分^[3]; 供氧不足则导致反应不完全, 降低生产效率和钢的纯净度^[4]。因此, 供氧量的精准预测已成为学术界和工业界的研究热点。传统供氧量预测多基于物质与能量平衡方程^[5], 但现场工况复杂、参数难以获取, 限制了预测精度。为此引入数据驱动方法^[6-9], 通过学习历史数据建立输入与供氧量映射, 虽提高了预测精度, 却难以保证物理合理性。因此如何在数据驱动的预测模型中有效融合冶金知识, 提升预测精度的同时确保结果的物理合理性非常重要。

在数据模型中融入知识主要有 3 类方法: 基于规则约束将知识量化嵌入模型, 但因炼钢工艺复杂, 嵌入点难以准确识别, 应用受限^[10]; 基于多模态融合通过不同模态互补提升表达与鲁棒性^[11]; 基于机理与数据的混合建模以串联或并联方式结合两者输出^[12]。然而炼钢知识多为经验性、非结构化信息,

难以直接建模, 上述后两类方法在炼钢领域应用有限。已有学者尝试在炼钢领域结合机理与数据, 李洋等^[13]推导脱碳效率公式并构建支持向量机模型, 王慧贤等^[14]提出分段式脱碳效率模型并结合案例推理进行预测。尽管如此, 这些方法融合程度仍较浅, 未能发挥机理对数据模型的深度指导作用。

综上所述, 目前基于数据驱动的炼钢供氧量预测方法普遍缺乏工艺知识支持, 难以兼顾准确性与可靠性。由于炼钢知识多为非结构化经验, 难以量化, 现有跨领域融合方法难以直接适用, 同时本领域融合研究仍处于浅层阶段。针对上述问题, 本文提出一种基于知识与数据融合驱动的转炉炼钢供氧量预测方法。首先, 搭建了一个知识驱动的三级融合模块, 在特征级、结构级与目标级多方面中引入了冶金知识, 以增强模型对炼钢工艺机理的认知能力; 其次, 设计了一个数据驱动的双分支特征学习模块, 一方面利用多尺度卷积提取当前炉次的局部工艺特征, 另一方面通过多粒度 Transformer 构建炉次间的时序依赖关系, 实现对历史冶炼影响的深度感知; 最

收稿日期: 2026-03-07; 修订日期: 2026-03-23

基金项目: 国家重点研发计划(2024YFB3311901); 河北省重大科技支撑计划(252G0301D); 天津市制造业高质量发展专项资金(20241047)

作者简介: 刘晶(1979—), 女, 内蒙古包头人, 河北工业大学研究员, 博士, 博士生导师, 主要从事工业人工智能研究, E-mail: liujing@scse.hebut.edu.cn。

后,在某钢厂的真实生产数据上验证了本文转炉炼钢供氧量预测方法的有效性。

1 研究方法

本文提出的基于知识与数据融合驱动的转炉炼钢供氧量预测方法融合了冶金领域知识与数据驱动建模优势,从多层次、多角度提升模型对供氧行为的认知与预测能力。

1.1 基于知识的三级融合模块

为提升模型对转炉工艺的认知,本文设计了基于知识的三级融合模块如图 1 所示,从特征级、结构级、目标级 3 个方面引入领域知识,增强可解释性与稳定性;在特征级以原理、守恒和经验知识辅助特征生成与选择;在结构级用理论区间引导注意力,突出关键历史炉次;在目标级构造知识约束损失函数,提升预测合理性。

1.1.1 特征增强

传统特征工程方法依赖自动提取,缺乏领域知识注入,限制特征表达。为增强工艺感知,本文在输入层引入知识驱动的特征增强机制,结合经验与机理筛选高价值特征,提升关键变量表征能力。

在具体设计中,主要基于以下 3 类炼钢知识完成特征增强。①基于化学反应原理:碳、硅、锰、磷等元素氧化消耗氧气,提取其含量及碳相关变量。②基于热力学与能量守恒:铁水及终点温度影响反应速率与热平衡,纳入热工特征。③工艺经验:供氧效率受转炉与喷枪寿命及物料配比影响^[15],构造“冶炼节奏”和“物料结构”两个派生特征间接表征:一是 T ,表示当前时间到上一次维护时间之间的等效炉次数,该特征综合考虑了炉龄、喷枪寿命以及氧枪更换等因素所带来的氧气利用率变化,反映了设备状态对氧气消耗的间接影响,如式(1)所示;二是 R ,表示废钢与铁水加入比例,该指标可用于衡量物料

热值结构与整体熔炼效率,对供氧策略的制定具有显著参考意义,如式(2)所示。

$$T = \frac{(D - D_0)}{t}; \tag{1}$$

$$R = \frac{w_{\text{scrapsteel}}}{w_{\text{iron}}}. \tag{2}$$

式中: D 为当前炉次冶炼开始时间; D_0 为当前炉次距最近一次转炉检修或氧枪更换的时间,取两者中较近的维护时间作为基准; t 为平均每炉的冶炼时间; $w_{\text{scrapsteel}}$ 为废钢加入的质量; w_{iron} 为铁水加入的质量。

在特征筛选过程中,首先结合冶金机理与经验知识对原始变量进行初筛,对于缺乏机理支撑、与供氧行为无直接关联的特征(如操作班组编号、部分合金加入量等)直接剔除^[16-17]。其余变量构成候选集合后,再通过皮尔逊相关系数分析去除相关性不足的变量。最终保留 14 个特征,它们在机理逻辑与统计分析上均与供氧行为密切相关,作为模型输入。最终输入特征为铁水质量(t)、铁水温度($^{\circ}\text{C}$)、铁水碳含量(质量分数)、铁水锰含量(质量分数)、铁水硅含量(质量分数)、铁水磷含量(质量分数)、铁水硫含量(质量分数)、废钢质量(t)、C 样碳含量(质量分数)、C 样温度($^{\circ}\text{C}$)、终点碳含量(质量分数)、终点温度($^{\circ}\text{C}$)、 T 、 R 。

1.1.2 引导型注意力

传统注意力机制纯依赖数据驱动,缺乏领域感知,易导致关注偏差。为此,本文在结构层引入基于供氧理论区间的注意力引导机制,以嵌入工艺知识,增强模型对规律的建模能力。为构造知识引导信号,基于质量守恒,供氧量主要由 4 部分构成:原料元素氧化、炉渣含铁氧化、炉衬碳氧化及烟尘含铁氧化。炉气自由氧和石灰硫还原原虽也消耗氧,但因量极小一般可忽略。相应计算公式^[14,16,18]见式(3)~




图 1 基于知识的三级融合模块

Figure 1 Three-level fusion module based on knowledge

(6),其中,钢水质量根据铁水与废钢质量估算如式(7)所示。

$$O_E = (w_{\text{iron}} \cdot c_E - w_{\text{steel}} \cdot c_{iE}) \cdot \text{oxides}_{\text{mass}}; \quad (3)$$

$$O_s = w_s \cdot c_{s_{\text{fe}}} \cdot \text{oxides}_{\text{mass}}; \quad (4)$$

$$O_l = w_l \cdot c_{l_{\text{c}}} \cdot \text{oxides}_{\text{mass}}; \quad (5)$$

$$O_d = w_d \cdot c_{d_{\text{fe}}} \cdot \text{oxides}_{\text{mass}}; \quad (6)$$

$$w_{\text{steel}} = 0.95w_{\text{iron}} + 0.93w_{\text{scrapsteel}} \quad (7)$$

式中: O_E 为原料中各元素(包括碳、硅、锰、磷、硫5种元素)从原始浓度(质量分数,下同)氧化到规定目标浓度消耗氧气的体积; c_E 为铁水中各元素对应浓度; w_{steel} 为钢水质量; c_{iE} 为各元素对应的冶炼目标浓度; $\text{oxides}_{\text{mass}}$ 为各元素对应的氧化物的原子质量; O_s 、 O_l 、 O_d 分别为炉渣、炉衬、烟尘部分消耗氧气的体积; w_s 、 w_l 、 w_d 为对应各部分的质量; $c_{s_{\text{fe}}}$ 、 $c_{l_{\text{c}}}$ 、 $c_{d_{\text{fe}}}$ 为对应各部分中氧化元素(fe代表铁,c代表碳)浓度。

由于炉渣含铁、炉衬损耗和烟尘带氧等因素参数复杂且波动较大,总耗氧量难以精确计算,本文采用理论供氧区间估算,更具合理性与可操作性:最小值仅考虑关键元素氧化至目标浓度所需氧量,计算公式见式(8);最大值则假设所有潜在反应均极限发生,计算公式见式(9)。若实际供氧超出该区间,则可能导致资源浪费或炉况异常。

$$O_{\text{Min}} = O_E; \quad (8)$$

$$O_{\text{Max}} = O_E + O_s + O_l + O_d. \quad (9)$$

得到理论供氧区间后,由此得到第*i*个炉次样本的理论供氧区间 $[O_{\text{Min},i}, O_{\text{Max},i}]$ 的区间中值 μ_i ,如式(10)所示。炉渣含铁、炉衬损耗和烟尘带氧等因素虽难以准确建模,但在真实供氧量中客观存在,若完全忽略将导致理论估算偏差。通过区间与中值的方式,可以提升相似度表征的稳健性。接着,构造历史炉次*j*与当前炉次*i*的理论相似度 S_{ij} ,如式(11)所示。该相似度值越大,表示当前炉次与历史炉次在工艺上越接近。进一步构造注意力偏置矩阵 B ,该矩阵是基于当前炉次与历史炉次在理论供氧区间上的相似度动态生成的,并非固定模板,用于引导注意力打分,其元素计算公式如式(12)所示。最终将其注入Transformer的注意力打分计算中,如式(13)所示。

$$\mu_i = \frac{(O_{\text{Min},i} + O_{\text{Max},i})}{2}. \quad (10)$$

$$S_{ij} = \begin{cases} 1, & y_j \in [O_{\text{Min},i}, O_{\text{Max},i}]; \\ 1 - \frac{|y_j - \mu_i|}{O_{\text{Max},i} - O_{\text{Min},i}}, & y_j \notin [O_{\text{Min},i}, O_{\text{Max},i}]. \end{cases} \quad (11)$$

$$B_{ij} = \alpha \cdot S_{ij}; \quad (12)$$

$$\text{Att}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_K}} + \mathbf{B}\right) \mathbf{V}. \quad (13)$$

式中: y_j 为历史炉次*j*的真实供氧量; α 作为一个可训练参数代表缩放因子; $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 分别为查询矩阵、键矩阵、值矩阵,通过输入特征的线性变换获得; d_K 为 $\mathbf{K}$ 的维度,这里为14。

1.1.3 惩罚型损失函数

深度模型在异常样本下易违背工艺常识。为此,本文在输出端引入理论供氧区间构造知识约束损失,以冶金先验规范预测并提升合理性。

具体而言,依据第*i*个炉次样本的理论供氧区间 $[O_{\text{Min},i}, O_{\text{Max},i}]$,设计目标级知识损失 L_{guide} ,用于惩罚预测值 $\hat{y}$ 落在区间之外的情况,其定义如下所示:

$$L_{\text{guide}} = \begin{cases} 0, & \hat{y} \in [O_{\text{Min},i}, O_{\text{Max},i}]; \\ (\hat{y} - O_{\text{Max},i})^2, & \hat{y} > O_{\text{Max},i}; \\ (O_{\text{Min},i} - \hat{y})^2, & \hat{y} < O_{\text{Min},i}. \end{cases} \quad (14)$$

该损失函数在保持区间内部预测结果自由学习的同时,对区间外的异常预测施加显式约束,使模型学习结果更加贴合工艺规律。最终损失由常规回归损失与知识引导损失共同组成:

$$L_{\text{total}} = L_{\text{reg}} + \lambda L_{\text{guide}}. \quad (15)$$

式中: L_{reg} 为常规回归损失; λ 为调节两者权重的超参数,通过验证选取其最优取值。

1.2 基于数据的双分支特征学习模块

转炉炼钢炉次间存在显著时序关联,如炉渣残留、炉衬热态及生产节奏波动等,但传统模型多将其视为独立样本,限制了模型的准确性。为此,本文提出双分支特征学习模块:多尺度卷积分支提取当前炉次局部特征;多粒度Transformer构建时序依赖,最终融合两类特征,实现供氧行为的精细预测。

1.2.1 多尺度卷积特征提取层

当前炉次特征为多维数值变量,存在复杂非线性耦合。全连接难以建模,单尺度卷积又受限,存在感受野受限、信息提取不足的问题,为此设计多尺度卷积分支,并行使用不同尺寸卷积核提取多尺度工艺特征,如图2所示。




图2 多尺度卷积特征提取

Figure 2 Multi-scale convolutional feature extraction

这种多尺度感受野策略能够从不同层级解析工艺变量间的特征关系,增强模型的表征能力。各尺度卷积路径生成的特征图代表了当前炉次在不同模式下的多层级信息^[19],如式(16)所示:

$$f_i = (\text{ReLU}(\text{Conv}_i(x)))_m. \quad (16)$$

每一路卷积之后再接 m 层相同核宽的卷积进行深度特征提取,最终得到 n 组特征图 $f_1, f_2, \dots, f_n$, 分别代表不同感受野下的局部模式表达。为利用其互补性,将各路径输出拼接,形成融合不同感受野的炉次特征金字塔,计算公式如下所示:

$$f_i^{\text{CNN}} = \text{Concat}[f_1, \dots, f_n]. \quad (17)$$

为增强拼接特征的全局感知,引入轻量级自注意力模块。将通道融合后的特征图作为输入,通过 Query-Key 点积生成注意力权重,对 Value 进行加权聚合,实现位置间信息交互,且保持通道独立性^[20-21]。最后将增强后的特征图展平,得到炉次级特征向量作为 CNN 分支输出,计算公式如下所示:

$$h_i^{\text{CNN}} = \text{Flatten}(\text{Attention}(f_i^{\text{CNN}})). \quad (18)$$

式中: h_i^{CNN} 为由多尺度卷积提取得到的当前炉次局部特征,该向量作为当前炉次特征的空间表征,将用于后续的特征融合与预测任务。

1.2.2 多粒度 Transformer 特征提取层

为构建炉次间多尺度时序依赖,本文设计了基于多粒度 Transformer 的特征提取分支如图 3 所示^[22-24]。该分支并行设置不同时间窗口的编码器,分别学习短、中、长期动态,既能刻画相邻炉次的高频波动,又能捕捉跨炉次的低频趋势,从而提升模型的时序理解与稳定性。




图 3 多粒度 Transformer 特征提取

Figure 3 Multi-granularity Transformer feature extraction

每条时间粒度路径以炉次序列为输入,引入位置编码使特征具备时序感知,本文采用固定正余弦方式实现。编码器核心采用标准的多头自注意力结构,并基于第 1.1.2 节所提出的知识引导机制计算注意力。该机制增强了注意力机制对历史炉次的工艺感知能力,实现了结构级知识在时序建模过程中

的自然嵌入。后经过前馈神经网络等得到表征,计算公式如下所示:

$$f_i^{(k)} = \text{TransformerEncoder}^{(k)}(\tilde{X}^{(k)}_i). \quad (19)$$

式中: $f_i^{(k)}$ 为不同时间窗口得到的特征图; k 为时间窗口长度,各粒度编码器输出经特征拼接融合为统一序列特征图,如式(20)所示,为此实现多尺度信息的动态对齐与协同表达。

$$h_i^{\text{Trans}} = \text{Concat}[f_i^{(3)}, \dots, f_i^{(k)}]. \quad (20)$$

式中: h_i^{Trans} 为由多粒度 Transformer 提取得到的时序特征。

1.2.3 特征融合与预测输出层

本文采用特征拼接的方式将两分支输出的高维表示向量进行融合,得到统一的炉次级特征表示,计算公式如下所示:

$$h_i = [\beta h_i^{\text{CNN}}; (1 - \beta) h_i^{\text{Trans}}]. \quad (21)$$

式中: β 为可学习的融合权重参数,融合后的特征表示 h_i 被输入至全连接预测模块,通过多层非线性映射,实现供氧量的最终回归预测。

2 实验及结果分析

2.1 实验细节及评估指标

2.1.1 实验数据

为验证方法有效性与泛化性,实验采用某钢厂两座转炉(A 炉 SPHC 钢种、B 炉 HRB400E 钢种)2023 年 1 月至 2024 年 5 月的真实生产数据,共含 75 个变量,选取有效数据作为原始数据集,数据量分别为 8 467 和 10 991 条。

2.1.2 评估指标

为了评价模型的预测性能,采用平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对相对误差(MAPE)、相对误差范围内准确率(Acc_ε)作为评价标准,定义如下所示:

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n}; \quad (22)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}; \quad (23)$$

$$MAPE = \left(\frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|}{n} \right) \times 100\%; \quad (24)$$

$$Acc_\varepsilon = \left(\frac{\sum_{i=1}^n 1 \cdot \left(\left| \frac{\hat{y}_i - y_i}{y_i} \right| \leq \varepsilon \right)}{n} \right) \times 100\%. \quad (25)$$

式中： y_i 和 $\hat{y}_i$ 分别为目标变量的真实值和预测值； n 为测试集样本个数； $1 \cdot ()$ 为指示函数,如果括号内的表达式为真,则函数的值为 1,否则为 0； ε 为给定的相对误差范围的绝对值,以小数形式表示。

2.1.3 实验环境及设置

实验在 Windows 11 操作系统、Intel Core i5-1035G7 CPU @ 1.20 GHz、NVIDIA GeForce RTX 2080 Ti GPU 环境下完成,开发环境为 Python 3.9.10,深度学习框架采用 PyTorch 2.1.0。除特别说明外,本文实验均在上述环境下实现。实验将原始数据预处理为模型输入并去除机理异常值,训练和测试集划分为 8:2。多粒度时间序列设置 4 种窗口(3,5,7,9 炉次),该选择一方面基于经验,转炉冶炼周期约 30 min,过长窗口的远端炉次对当前炉次影响微弱,信息衰减明显;另一方面通过对不同窗口长度的对比实验验证,该炉次能够较好区分短、中、长程依赖,并在预测性能上表现稳定。多尺度卷积分支并行 4 路卷积(核大小 1,3,5,7,每路 3 层卷

积,通道逐层增加);多粒度 Transformer 分支含 4 层编码器、8 头注意力。训练采用 Adam ($lr=0.001$)、最大 2 000 轮、早停策略,基础损失为 L1。

2.2 供氧量预测对比实验及结果分析

为了验证将时序特征和非时序特征融合建模、引入机理知识辅助模型训练预测的有效性,对本文模型(KG-MCT)进行对比实验。本领域代表性模型介绍如下:改进深度信念网络(GBRBM-DBN)^[8] 结合高斯伯努利受限玻尔兹曼机,提升耗氧量预测精度;混合模型(HyGPR)^[4] 融合多元线性回归(MLR)与高斯过程回归(GPR),提高预测准确性与鲁棒性;集成学习模型(Stacking)^[25] 通过随机森林与 XGBoost 进行初步预测,使用线性回归模型整合结果,最终预测供氧量;贝叶斯优化梯度提升机(BOA-LGBM)^[26] 结合贝叶斯优化参数与轻量梯度提升机,提高预测精度与效率。

实验基于某钢厂 A 炉与 B 炉的实际生产数据。表 1 为对比实验结果。

表 1 对比实验结果
Table 1 Comparative experimental results

模型	A 炉 (SPHC)						B 炉 (HRB400E)					
	MAE	RMSE	MAPE	Acc _{0.01}	Acc _{0.03}	Acc _{0.05}	MAE	RMSE	MAPE	Acc _{0.01}	Acc _{0.03}	Acc _{0.05}
	/m ³	/m ³	/%	/%	/%	/%	/m ³	/m ³	/%	/%	/%	/%
GBRBM-DBN	249.77	320.00	2.93	22.70	58.83	81.93	240.06	306.98	2.93	22.11	59.54	82.20
HyGPR	248.57	313.34	2.93	23.09	56.90	82.19	239.68	296.32	2.96	20.28	58.25	81.98
Stacking	249.30	314.81	2.94	20.90	57.16	82.45	236.80	293.55	2.93	20.71	58.68	82.84
BOA-LGBM	247.13	313.81	2.91	24.38	58.96	80.77	227.09	283.46	2.80	23.19	60.19	83.27
KG-MCT	230.82	298.24	2.71	24.51	62.96	85.29	203.47	260.54	2.50	27.40	66.34	87.91

从表 1 可知,本文提出的 KG-MCT 模型在 A 炉 (SPHC) 和 B 炉 (HRB400E) 两个数据集上均取得了最优的预测性能,表现出良好的通用性与鲁棒性,相比 GBRBM-DBN 模型,KG-MCT 在 MAE 上分别实现了 7.59% 和 15.24% 的降低,在 RMSE 上分别实现了 6.80% 和 15.11% 的降低,在 MAPE 上分别降低了 0.22 个百分点和 0.43 百分点,在 3 个准确率上也都提升。与 HyGPR 相比,KG-MCT 在两个数据集上同样在所有指标上均最优,其中在 B 炉的 RMSE 和 MAPE 分别减少 12.07% 和 0.46 百分点,体现出对复杂数据分布更强的拟合能力。相比 Stacking 和 BOA-LGBM 模型,KG-MCT 依然在 3 个误差指标 (MAE、RMSE、MAPE) 上保持了较为明显的优势。误差降低得益于知识指导缓解了异常值影响,而准确率提升则源于双分支特征学习捕捉更多关键信息。各误差范围散点图如图 4、5 所示。

由图 4 和图 5 可见,GBRBM-DBN 方法大量点




图 4 A 炉误差范围散点图
Figure 4 Scatter plot of error ranges for Furnace A




图 5 B 炉误差范围散点图

Figure 5 Scatter plot of error ranges for Furnace B
分布在 $\pm 5\%$ 之外,点云分散,预测偏差较大;HyGPR

表 2 消融实验结果

模型	A 炉 (SPHC)						B 炉 (HRB400E)					
	MAE	RMSE	MAPE	Acc _{0.01}	Acc _{0.03}	Acc _{0.05}	MAE	RMSE	MAPE	Acc _{0.01}	Acc _{0.03}	Acc _{0.05}
	/m ³	/m ³	/%	/%	/%	/%	/m ³	/m ³	/%	/%	/%	/%
KG-MCT-NoKG	256.81	321.40	3.03	20.90	56.12	80.90	237.51	298.06	2.93	23.19	57.71	81.33
KG-MCT-CNN-Only	269.70	332.89	3.20	19.09	54.19	77.29	245.70	310.49	3.04	21.79	56.95	81.12
KG-MCT-Trans-Only	300.81	374.17	3.55	17.93	48.64	72.64	292.71	365.04	3.62	17.79	48.00	72.92
KG-MCT	230.82	298.24	2.71	24.51	62.96	85.29	203.47	260.54	2.50	27.40	66.34	87.91

由表 2 可知,对于 KG-MCT-NoKG,在去除了知识的三级融合后,各个指标的效果在 A 炉和 B 炉上都有所下降,MAE 分别增大了 11.26% 和 16.73%,RMSE 分别增大了 7.77% 和 14.40%,MAPE 分别增大了 0.32 个百分点和 0.43 百分点,同时各个准确率都有所下降。对于 KG-MCT-CNN-Only,在去除了多粒度 Transformer 特征提取层后,在两个数据集上 MAE 分别增大了 16.84% 和 20.75%,RMSE 分别增大了 11.62% 和 19.17%,MAPE 增大了 0.49 个百分点和 0.54 百分点;在准确率方面有所下降,误差在 $[-3\%, 3\%]$ 的准确率降低了 8.77 个百分点和 9.39 百分点,误差在 $[-5\%, 5\%]$ 内的准确率降低了 8.00 个百分点和 6.79 百分点。对于 KG-MCT-Trans-Only,在去除了多尺度卷积特征提取层后,在误差方面 B 炉效果下降明显,MAE 增大了 43.86%,RMSE 增大了 40.11%,MAPE 增大了 1.12 百分点;在准确率方面,两个数据集预测效果都有明显下降。

方法高偏差样本明显多于本文方法,反映其特征提取与非线性建模不足;Stacking 方法点云离散,未能聚集在理想线附近,说明融合子模型时差异调和不足;BOA-LGBM 方法虽部分表现良好,但在 $\pm 5\%$ 以外仍有一定比例样本,存在局部误差积累。相比之下,本文方法结果集中于理想线两侧,在 $\pm 1\%$ 、 $\pm 3\%$ 、 $\pm 5\%$ 区间的数据密度均更高,尤其在 $\pm 3\%$ 范围内表现最佳,显示出更强的稳定性与鲁棒性。这主要得益于领域知识融合机制,有效构建了关键变量间的非线性关系,提升了泛化性与准确性。

2.3 消融实验及结果分析

为评估 KG-MCT 各模块对模型性能的贡献,本文设计消融实验,逐步移除各模块并观察性能变化,以验证其有效性。实验在 A 炉与 B 炉数据上进行,结果见表 2,其中,KG-MCT-NoKG 表示移除所有知识融合模块;KG-MCT-CNN-Only 表示禁用 Transformer 分支,仅保留 CNN;KG-MCT-Trans-Only 表示禁用 CNN 分支,仅保留 Transformer。

3 结论

针对传统供氧量预测模型单一依赖知识或数据建模所存在的问题,提出知识与数据融合的预测方法。通过构建特征级增强、结构级工艺偏置矩阵与目标级约束损失的三级知识融合模块,将冶金工艺认知注入深度学习模型,实现机理约束与数据规律的有效协同;多尺度 CNN-多粒度 Transformer 双分支架构通过局部卷积核捕捉当前炉次工艺细节,跨炉次时序窗口构建历史冶炼影响,在特征融合层实现工艺动态的全局感知。实验结果表明,供氧量的平均绝对误差和均方根误差相比主流方法最高分别降低了 15.24% 和 15.13%,相对误差在 $\pm 5\%$ 精度下的命中率最优可达到 87.91%,KG-MCT 有效降低了出现异常值的概率,并提高了预测的准确率。

参考文献:

[1] Ma Zhongcun, Zhang Lei, Shi Chunyang, et al. Predic-

- tion of oxygen consumption in steelmaking based on LAOA-TSVR[J]. *Metalurgija*, 2024, 63(2): 165–168.
- [2] Wen Daoyuan, Zhu Yingtao. Research on prediction of oxygen consumption in converter steelmaking based on IGWO-SVM model[J]. *Journal of Physics: Conference Series*, 2021, 2010(1): 012138.
- [3] Wang Dazhi, Bao Yanping, Gao Fang, et al. Hybrid model for predicting oxygen consumption in BOF steel-making process based on cluster analysis[J]. *Steel Research International*, 2023, 94(1): 2200595.
- [4] Jiang Shenglong, Shen Xinyue, Zheng Zhong. Gaussian process-based hybrid model for predicting oxygen consumption in the converter steelmaking process [J]. *Processes*, 2019, 7(6): 352.
- [5] Mei Liuliu. Study on intelligent control method of converter steelmaking based on expert system[D]. Anshan: University of Science and Technology Liaoning, 2023. [梅留留. 基于专家系统的转炉炼钢智慧控制方法研究[D]. 鞍山: 辽宁科技大学, 2023.]
- [6] Yang Qingfeng, Lai Xuzhi, Du Sheng, et al. Converter steelmaking oxygen consumption prediction based on granularity clustering[J]. *Acta Automatica Sinica*, 2024, 50(1): 132–142. [阳青锋, 赖旭芝, 杜胜, 等. 基于粒度聚类的转炉炼钢氧气消耗量预测[J]. *自动化学报*, 2024, 50(1): 132–142.]
- [7] Qin Bo, Wu Qingchao, Zhang Juanjuan, et al. Blowing oxygen volume prediction of BOF steelmaking based on PSO-SVM [J]. *Measurement & Control Technology*, 2014, 33(12): 121–124. [秦波, 吴庆朝, 张娟娟, 等. 基于 PSO 优化 SVM 的转炉炼钢用氧量预测研究[J]. *测控技术*, 2014, 33(12): 121–124.]
- [8] Li Ailian, Zhao Duozhen, Guo Zhibin, et al. Prediction of converter oxygen consumption in improved deep belief network[J]. *China Measurement & Testing Technology*, 2020, 46(6): 1–6. [李爱莲, 赵多祯, 郭志斌, 等. 改进深度信念网络的转炉耗氧量预测[J]. *中国测试*, 2020, 46(6): 1–6.]
- [9] Han Zhongyang, Zhao Jun, Leung H, et al. A review of deep learning models for time series prediction[J]. *IEEE Sensors Journal*, 2021, 21(6): 7833–7848.
- [10] Huang Yixue, Qin Ke, Luo Wei, et al. Ship electrical layout method using piror rules and deep neural networks [J]. *Computer Integrated Manufacturing Systems*, 2024, 30(3): 968–981. [黄一学, 秦克, 罗威, 等. 先验规则和深度学习融合驱动的舰船电气图纸布局方法[J]. *计算机集成制造系统*, 2024, 30(3): 968–981.]
- [11] Wang Min, Hu Zhao, Xu Xiaowei, et al. Constructing a knowledge-driven and data-driven hybrid decision model for etiological diagnosis of ventricular tachycardia [J]. *Medical Journal of Peking Union Medical College Hospital*, 2025, 16(2): 454–461. [王敏, 胡兆, 徐晓巍, 等. 融合知识驱动和数据驱动的混合决策模型构建: 以室性心动过速病因诊断为例[J]. *协和医学杂志*, 2025, 16(2): 454–461.]
- [12] Yang Hao, Wang Jiayi, Yi Wenfei, et al. Hybrid knowledge-data driven adaptive voltage/var optimization control of photovoltaic inverters in distribution networks[J]. *Proceedings of the CSEE*, 2025, 45(22): 8691–8706. [杨浩, 王佳怡, 易文飞, 等. 知识-数据融合驱动的配电网光伏逆变器电压/无功优化自适应控制[J]. *中国电机工程学报*, 2025, 45(22): 8691–8706.]
- [13] Li Yang, Han Min, Jiang Liwen. Blowing oxygen volume calculation model of BOF steelmaking based on oxygen decarburization efficiency prediction [J]. *Journal of Dalian University of Technology*, 2012, 52(5): 725–729. [李洋, 韩敏, 姜力文. 基于氧气脱碳效率预测的转炉炼钢吹氧量计算模型[J]. *大连理工大学学报*, 2012, 52(5): 725–729.]
- [14] Wang Huixian, Xu Anjun, Gu Maoqiang, et al. Oxygen supply prediction model for converters based on segmented oxygen decarburization efficiency[J]. *China Metallurgy*, 2023, 33(7): 91–99. [王慧贤, 徐安军, 谷茂强, 等. 基于分段式氧气脱碳效率的转炉供氧量预测模型[J]. *中国冶金*, 2023, 33(7): 91–99.]
- [15] Shao Xin, Liu Qing, Xin Zicheng, et al. Hybrid model for BOF oxygen blowing time prediction based on oxygen balance mechanism and deep neural network[J]. *International Journal of Minerals, Metallurgy and Materials*, 2024, 31(1): 106–117.
- [16] Li Hua, Lei Hao. Analysis and prediction model of related affecting factors of oxygen consumption in converter steel-making[J]. *Southern Metals*, 2022(3): 37–42. [李桦, 雷豪. 转炉炼钢冶炼氧气消耗相关影响因素分析及预测模型[J]. *南方金属*, 2022(3): 37–42.]
- [17] Peng Qian, Fan Dingdong, Zhou Xiaobin, et al. Optimisation of an oxygen supply prediction model based on the K-nearest neighbours (KNN) algorithm using the Pearson correlation coefficient [J]. *Ironmaking & Steelmaking: Processes, Products and Applications*, 2024: 030192332 41306282.
- [18] Xia Yijie, Wang hongbing, Wei Xing, et al. Data and mechanism joint-driven model for carbon content prediction at the end point of converter[C]//*Proceedings of the 14th CSM Steel Congress*. Beijing: The Chinese Society for Metals, 2023: 43–48. [夏一杰, 汪红兵, 魏星, 等. 数据与机理联合驱动的转炉终点碳含量预测模型[C]//*第十四届中国钢铁年会论文集*. 北京: 中国金属学会, 2023: 43–48.]

- [19] Dong Qianqian, Li Min, Hu Shuaijie, et al. Multi-output prediction model for basic oxygen furnace steelmaking based on the fusion of deep convolution and attention mechanisms[J]. Metals, 2024, 14(7): 773.
- [20] Wu Song, Lan Xin, Shan Jingyang, et al. Improved U-Net algorithm based on attention mechanism and multi-scale fusion[J]. Journal of Computer Applications, 2024, 44(S2): 24–28. [吴淞, 蓝鑫, 单靖杨, 等. 基于注意力机制和多尺度融合的 U-Net 改进算法[J]. 计算机应用, 2024, 44(增刊 2): 24–28.]
- [21] Chen Long, Zhang Hanwang, Xiao Jun, et al. SCA-CNN: spatial and channel-wise attention in convolutional networks for image captioning[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 6298–6306.
- [22] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[PP/OL]. V7. arXiv (2023–08–02) [2025–12–01]. <https://doi.org/10.48550/arXiv.1706.03762>.
- [23] Li Jiayuan, Wang Xiaodong, He Qixue. Application and performance optimization of CNN enhanced Informer model in industrial time series prediction[J]. Journal of Computer Applications, 2024, 44(S2): 79–83. [李嘉源, 王晓东, 何启学. CNN 增强型 Informer 模型在工业时间序列预测中的应用及性能优化[J]. 计算机应用, 2024, 44(增刊 2): 79–83.]
- [24] Han Huijian, Xing Huaiyu, Zhang Yunfeng, et al. Visual detection of steel surface defects based on Transformer and multi-attention[J]. Journal of Zhengzhou University (Engineering Science), 2025, 46(5): 69–76. [韩慧健, 邢怀宇, 张云峰, 等. 基于 Transformer 多元注意力的钢材表面缺陷视觉检测[J]. 郑州大学学报(工学版), 2025, 46(5): 69–76.]
- [25] Ke Kai, Peng Qichun, Peng Xialin, et al. Prediction model of oxygen supply in converter steelmaking based on ensemble learning[J]. Steelmaking, 2023, 39(1): 47–52. [柯凯, 彭其春, 彭霞林, 等. 基于集成学习的转炉炼钢供氧量预测模型[J]. 炼钢, 2023, 39(1): 47–52.]
- [26] Yang Shicun, Wei Zhiqiang, Zhong Liangcai, et al. Study on oxygen consumption model based on data drive in a converter[J]. Steelmaking, 2022, 38(4): 7–13. [杨仕存, 魏志强, 钟良才, 等. 基于数据驱动的转炉耗氧量模型研究[J]. 炼钢, 2022, 38(4): 7–13.]

Oxygen Supply Prediction Method for Converter Steelmaking Based on Knowledge and Data Fusion Driven

LIU Jing^{1,2}, JIANG Wenjie¹, FENG Hailing³, ZHANG Haibin⁴, JI Haipeng^{2,3,5}

(1. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China; 2. State Key Laboratory of High Performance Roll Materials and Composite Forming, Tianjin 300400, China; 3. Tianjin Development Zone Jingnuo Hanhai Data Technology Co., Ltd., Tianjin 300400, China; 4. Hegang Digital Technology Co., Ltd., Shijiazhuang 050000, China; 5. School of Materials Science and Engineering, Hebei University of Technology, Tianjin 300401, China)

Abstract: Aiming at the problem of the disconnection between domain knowledge and data-driven models in traditional oxygen supply prediction methods in converter steelmaking process, a knowledge and data fusion driven oxygen supply prediction method for converter steelmaking was proposed. A three-level knowledge fusion module was constructed, embedding metallurgical mechanisms into deep learning models. Secondly, a dual-branch architecture was designed to collaboratively mine process characteristics and cross furnace temporal patterns. Finally, actual production data from a domestic steel plant was used for the experiment. The experiment results showed that compared with mainstream methods such as GBRBM-DBN, HyGPR, Stacking, and BOA-LGBM, the *MAE* and *RMSE* of oxygen supply under SPHC steel grade decreased by a maximum of 7.59% and 6.80%, respectively, and the accuracy (relative error $\pm 5\%$) reached 85.29%. Under the HRB400E steel grade, the *MAE* and *RMSE* decreased by a maximum of 15.24% and 15.13%, respectively, with an accuracy (relative error $\pm 5\%$) of 87.91%, verifying the oxygen supply prediction ability of the proposed method.

Keywords: fusion driven; collaborative modeling; dual-branch; converter steelmaking; oxygen supply prediction