

doi:10.12068/j.issn.1005-3026.2026.20240127

基于混合特征选择的BiGRU-Att烧结矿转鼓指数预测模型

栗潇通, 宋小龙, 范金鑫, 吴朝霞
(东北大学秦皇岛分校 控制工程学院, 河北 秦皇岛 066004)

摘要: 由于烧结过程具有复杂且高维的过程变量及诸多不确定性因素,单一特征选择方法难以有效地选出最佳特征集,从而影响模型的预测准确性.为此,提出一种基于混合特征选择的BiGRU-Att烧结矿转鼓指数预测模型.首先,利用最大信息系数(MIC)从原始特征集中筛选出候选特征.然后,运用基于同时扰动随机逼近的特征选择方法(PSA-FS)对候选特征集进一步优选.最终,将最佳特征集作为基于注意力机制的双向门控循环单元模型(BiGRU-Att)的输入进行烧结矿转鼓指数预测.与多种模型和单一特征选择方法的比较分析结果表明,本文提出的混合特征选择方法能够选出最佳的特征集,所建模型具有较高的预测精度,为烧结过程提供了可靠的决策支持.

关键词: 烧结矿转鼓指数;混合特征选择方法;BiGRU;预测模型;注意力机制

中图分类号: TP 181 文献标志码: A 文章编号: 1005-3026(2026)01-0107-08

Prediction Model of BiGRU-Att Sinter Drum Index Based on Hybrid Feature Selection

LI Xiao-tong, SONG Xiao-long, FAN Jin-xin, WU Zhao-xia

(School of Control Engineering, Northeastern University at Qinhuangdao, Qinhuangdao 066004, China. Corresponding author: WU Zhao-xia, E-mail: ysuwzx@126.com)

Abstract: Because the sintering process has complex and high-dimensional process variables and many uncertain factors, it is difficult for a single feature selection method to effectively select the best feature set, which affects the prediction accuracy of the model. Therefore, a prediction model of attention mechanism-based bidirectional gated recurrent unit model (BiGRU-Att) sinter drum index based on hybrid feature selection was proposed. Firstly, the maximum information coefficient (MIC) was used to select candidate features from the original feature set. Then, the feature selection method based on simultaneous perturbation stochastic approximation (PSA-FS) was used to further optimize the candidate feature set. Finally, the best feature set was used as the input of BiGRU-Att to predict the sinter drum index. The results of comparative analysis with multiple models and single feature selection methods show that the hybrid feature selection method proposed in this paper can select the best feature set, and the established model has higher prediction accuracy, providing reliable decision-making support for the sintering process.

Key words: sinter drum index; hybrid feature selection method; BiGRU; prediction model; attention mechanism

钢铁工业是现代工业的基础和支柱,而铁矿烧结是现代钢铁冶炼的第一道工序,是实现优质、高产、低耗钢铁生产的基础^[1].烧结矿转鼓指

数作为评估烧结矿性能的关键指标,直接影响着高炉的稳定性、冶炼效率和产品质量.较低的转鼓指数意味着烧结矿在高温条件下的机械强度较差,

收稿日期: 2024-05-29

基金项目: 河北省教育厅科学技术研究项目(BJ2021099).

作者简介: 栗潇通(2001—),男,河南开封人,东北大学硕士研究生.

通信作者: 吴朝霞, E-mail: ysuwzx@126.com.

容易碎裂和崩解.这导致高炉料柱不稳定,增加冶炼过程中料柱坍塌或阻塞的风险,从而影响高炉的正常运行.在实际烧结生产中,传统的烧结矿转鼓指数测定通常是定期对成品矿进行取样测定,并根据测定结果调整烧结工艺参数.然而,这种方法存在着无法实时检测的问题,并且测定的转鼓指数难以及时反映当前烧结过程的质量.因此,为了解决烧结矿转鼓指数检测长时间滞后的问题,探索烧结矿转鼓指数预测模型变得至关重要^[2-3].

随着人工智能技术的迅速发展,针对烧结矿转鼓指数检测存在长时间滞后的问题,众多学者开始探索建立烧结矿转鼓指数预测模型.在当前相关研究中,张振等^[4]通过与实际烧结终点状态相关联,提出一种基于多类别生产状态的烧结矿转鼓指数预测模型,当误差范围在 0.25% 以内时,该模型的预测命中率能够达到 95% 以上. Ren 等^[5]采用不同的数据预处理方法和 10 种回归预测算法对烧结矿转鼓强度进行预测,得出了适合烧结矿转鼓强度预测的模型预测算法和数据预处理算法.郝良元等^[6]提出了一种以烧结机实际生产数据为基础,应用深度森林算法建立了转鼓指数实时预测模型. Xia 等^[7]为解决烧结矿转鼓指数点预测结果可靠性较低的问题,提出了一种基于 LightGBM 和核密度估计的转鼓指数预测区间估计方法.上述研究表明,当前烧结矿转鼓指数预测模型的研究已相当成熟.然而,为了实现烧结矿转鼓指数的稳定控制,模型的预测精度有待进一步提高.由于烧结过程具有多变量、非线性、强耦合等特性,单一特征选择方法难以有效地剔除预测信息很少或无信息的特征以及强相关的冗余特征,并且目前大多数研究仅采用单一特征选择方法,这在很大程度上限制了模型的预测精度.

针对以上问题,本文提出了基于混合特征选择的 BiGRU-Att 烧结矿转鼓指数预测模型.首先对采集的烧结数据进行预处理,以得到可以直接建模的有效数据.然后使用最大信息系数(maximum information coefficient, MIC)选出与转鼓指数强相关的候选特征,再运用基于同时扰动随机逼近的特征选择方法(feature selection method based on simultaneous perturbation stochastic approximation, SPSA-FS)对候选特征进一步优化,得出最佳的特征集^[8-9].在获得最佳的特征集之后,考虑到烧结过程是一个连续复杂的工业过程,为了更准确地预测转鼓指数,构建

了基于注意力机制的双向门控循环单元模型(bidirectional gated recurrent unit model based on attention mechanism, BiGRU-Att),以捕捉烧结过程变量的长期依赖关系,并在每个时间步上动态地分配注意力,更好地关注对转鼓指数重要的时间点或特征^[10].通过与其他几种模型和单一特征选择方法进行比较分析,表明本文提出的混合特征选择方法能够筛选出更优的特征集,并且所建模型表现出较高的预测精度.

1 数据描述及预处理

1.1 数据描述

本研究以某烧结厂 3 号烧结机为研究对象,收集了 13 000 组实际生产数据,对烧结过程中的关键参数进行了详细分析和预处理.这些参数分为原料参数、操作参数、混合料参数和状态参数四大类,涵盖了烧结过程的各个关键方面.具体而言,本文在表 1 中总结了 49 个主要参数,这些参数与烧结矿转鼓指数密切相关.为了使读者能够更清晰地理解相关数据,表 2 提供了烧结过程原始数据的基础信息,图 1 展示了烧结矿转鼓指数的数据分布.

原料参数描述了在配料工序中各种原料的下料量,这些原料按照一定的比例混合形成了烧结混合料.操作参数是在烧结过程中可以人工调节的变量,对于保证烧结生产过程的稳定性至关重要.混合料参数即烧结混合料中各种化学成分的占比,直接影响到最终烧结矿的质量.状态参数描述了烧结过程中所表现出的状态变量,通过对这些参数的观察和分析,可以对操作参数进行相应的调整,确保烧结矿的质量达到预期目标.在研究过程中,特别关注了这些参数与烧结矿转鼓指数之间的关系,因为烧结矿转鼓指数是评价烧结过程效果的重要指标之一.通过对这些参数的深入分析,可以更好地理解烧结过程中的关键影响因素,并为提高烧结矿质量提供科学依据.

1.2 数据预处理

数据预处理的主要目的是识别和处理异常值和缺失值,因为异常值和缺失值会对模型的预测性能产生负面影响.在烧结过程中,由于设备故障、传感器异常或存储介质故障等因素,部分数据可能会缺失或异常.因此,在建立模型之前,需要对原始数据进行预处理.

表 1 烧结过程的主要参数
Table 1 Main parameters of sintering process

参数类型	参数序号	参数	参数序号	参数
原料参数	1	石灰粉下料量/(t·h ⁻¹)	2	除尘灰下料量/(t·h ⁻¹)
	3	燃料下料量/(t·h ⁻¹)	4	铁粉下料量/(t·h ⁻¹)
	5	烧结返矿下料量/(t·h ⁻¹)	6	高炉返矿下料量/(t·h ⁻¹)
混合料参数	7	w(混合料总铁)/%	8	w(混合料五氧化二钒)/%
	9	w(混合料氧化钙)/%	10	w(混合料二氧化硅)/%
	11	w(混合料水分)/%		
操作参数	12	圆辊转速/(r·h ⁻¹)	13	九辊转速/(r·h ⁻¹)
	14	烧结机速度/(m·min ⁻¹)	15	点火温度/°C
	16	煤气流量/(m ³ ·h ⁻¹)	17	风机风量/(m ³ ·h ⁻¹)
状态参数	18	南烟道温度/°C	19	南烟道负压/kPa
	20	北烟道温度/°C	21	北烟道负压/kPa
	22~35	14个风箱废气温度/°C	36~49	14个风箱负压/kPa
输出参数	50	烧结矿转鼓指数/%		

表 2 烧结原始数据基础信息
Table 2 Basic information of raw sintering data

变量	下料量/(t·h ⁻¹)				...	烧结矿转鼓指数/%
	石灰粉	除尘灰	铁粉	烧结返矿		
均值	30.184	9.768	87.730	96.827	...	77.167
最小值	11.913	0.000	0.000	50.144	...	74.600
25%	27.499	7.632	62.800	90.742	...	76.900
50%	30.038	9.875	79.648	97.459	...	77.200
75%	32.780	12.677	124.238	103.985	...	77.400
最大值	48.753	24.248	305.117	144.376	...	79.400




图 1 烧结矿转鼓指数频数直方图

Fig. 1 Frequency histogram of sinter drum index

本文采用箱形图方法来识别异常值,这种方法基于四分位数,并不对数据进行任何先验限制,能够直观地展示异常值,并具有较客观的结果.原理如图 2 所示,下四分位数(Q1)、中位数(median, MD)和上四分位数(Q3)分别代表所有样本从小到大排序后的 25%,50%和 75%位置的值.四分位距(interquartile range, IQR)定义为 Q3-Q1,上限为 Q3+1.5IQR,下限为 Q1-1.5IQR.在箱形图中,如果数据点位于上、下限之外,则被视为异常点.对于筛选出的缺失值和异常值,本文使用该数据

点前后 5 个正常数据点的平均值进行替换.




图 2 箱形图

Fig. 2 Box plot

2 特征选择

在建立机器学习模型的过程中,特征选择扮演着至关重要的角色.其目的在于排除不相关和

冗余的特征,从而选择数据集中与目标变量相关性较强的有效特征子集.特征变量选择的优劣直接影响着模型的预测精度和泛化性能.针对具有复杂且高维过程变量的烧结过程,本文提出了一种混合特征选择方法,通过充分结合 MIC 与 SPSA-FS 两种特征选择方法的优势,以选择出最优特征子集.

2.1 最大信息系数

MIC 是一种用于特征选择的非参数方法,它旨在捕捉变量间包括但不限于线性、非线性、单调和复杂的依赖关系.MIC 通过量化 2 个变量间的信息共享程度来评估它们的相关性,尤其擅长发现非线性关系.针对高度非线性的烧结数据,本文首先利用 MIC 进行初步特征筛选,以得到后续使用的候选特征.MIC 的定义为

$$\text{MIC} = \max_{|x|, |y| \leq B} \frac{\sum_{x,y} P(x,y) \text{lb} \frac{P(x,y)}{P(x)P(y)}}{\text{lb}(\min(|x|, |y|))}. \quad (1)$$

式中: $|x|$ 和 $|y|$ 分别为 x 方向(横轴)和 y 方向(纵轴)划分的区间数量; $P(x)$ 为样本点落在 x 方向上的概率; $P(y)$ 为样本点落在 y 方向上的概率; $P(x,y)$ 为 x 与 y 之间的联合概率密度; B 为划分的最大网格数量,为样本量的 0.6 次方.MIC 值范围为 0 到 1, 值越接近 1 表示 2 个变量之间的关系越强.

2.2 SPSA-FS

SPSA-FS 是一种包装式的特征选择方法,将特征选择任务视为数学优化问题,以给定模型的错误率为目标函数,使用改进的二元同时扰动随机逼近(BSPSA)算法同时近似每个特征的梯度,通过连续迭代来寻找能使模型性能最优的特征集^[11].SPSA-FS 具有相对较快的收敛速度,并且能考虑特征之间的相互作用和组合效应,往往能够获得比过滤器方法更高的预测精度^[12].因此本文使用 SPSA-FS 对候选特征集进一步优化,以获得最终用于模型训练及测试的特征集.SPSA-FS 的具体步骤如下:

- 1) 初始化 SPSA-FS 所需的参数;
- 2) 选择一组特征作为初始特征集;
- 3) 指定评估模型及评估指标,用于评估特征集的优劣,并作为目标函数;
- 4) 使用改进的 BSPSA 算法进行迭代优化,通过当前特征集的基础上进行随机扰动来估计目标函数的梯度,并更新特征集以最小化目标函数;
- 5) 检查算法是否满足停止条件,如果满足停

止条件,则停止迭代,否则继续迭代.

2.3 混合特征选择

虽然 MIC 是一种高效的方法,能够有效地发现 2 个变量之间的相关性,但它局限于识别与目标变量相关的特征,而忽略了特征之间的相互作用和组合效应.相比之下,SPSA-FS 在选择特征时,会考虑特征之间的相互作用和组合效应,旨在找到最适合模型的特征集.然而,当特征数量较多时,SPSA-FS 收敛速度较慢,并且容易陷入局部最优.因此,本文将 MIC 与 SPSA-FS 两种特征选择方法相结合,以应对复杂且高维烧结数据的挑战.这种组合利用它们各自的优势,MIC 擅长发现 2 个变量之间的相关性,SPSA-FS 则能考虑特征之间的相互作用和组合效应.通过这种方式,可以选择出更能代表数据特征的最佳特征集,从而提高模型的性能.

混合特征选择方法的流程如图 3 所示,具体步骤如下:首先,利用 MIC 算法从烧结原始特征集中筛选出与转鼓指数高度相关的 25 个特征参数,形成候选特征集.然后,考虑到烧结数据的特性,综合评估并选择适用的预测模型.最后,运用 SPSA-FS 算法对候选特征集进一步优化,为所选模型精选出 15 个与转鼓指数高度相关且不冗余的特征参数,构建最佳特征集.

3 烧结矿转鼓指数预测模型

3.1 GRU 算法

门控循环单元(GRU)是循环神经网络(recurrent neural network, RNN)的一种变体,由 Cho 等^[13]在 2014 年提出.GRU 通过整合和简化 LSTM(long short-term memory)的门控机制,保持了处理长序列数据的能力,同时在模型复杂度、计算效率和内存占用方面提供了优势.它既解决了 RNN 在处理长期依赖时的局限性,又在不牺牲太多性能的前提下,相比 LSTM 提供了更轻量级的解决方案^[14].GRU 模型充分利用了烧结过程的连续性,可以捕捉时间依赖性,提高计算效率,能够准确把握时间特征.

GRU 的核心在于其门控机制,如图 4 所示.GRU 有 2 个门:重置门和更新门.每个时间步 t , GRU 会对输入数据和前一时间步的隐藏状态进行操作,以生成新的隐藏状态.

GRU 的操作可以分为以下几个步骤:

- 1) GRU 首先会计算更新门和重置门的门值.

更新门决定当前时间步中前一时间步的隐藏状态有多少信息需要保留,以及有多少新信息需要通过候选隐藏状态来更新.重置门决定在生成候选隐藏状态时,前一隐藏状态中哪些信息应当被遗忘或重置,哪些信息应该被用于生成新的候选状态.更新门 z_t 与重置门 r_t 通过式(2)~(3)计算:

$$z_t = \sigma(x_t W_{xz} + h_{t-1} W_{hz} + b_z), \quad (2)$$

$$r_t = \sigma(x_t W_{xr} + h_{t-1} W_{hr} + b_r). \quad (3)$$

式中: σ 是sigmoid激活函数; x_t 是当前输入; h_{t-1} 是前一时间步的隐藏状态; $W_{xz}, W_{hz}, W_{xr}, W_{hr}$ 是权重矩阵; b_z, b_r 是偏置项.

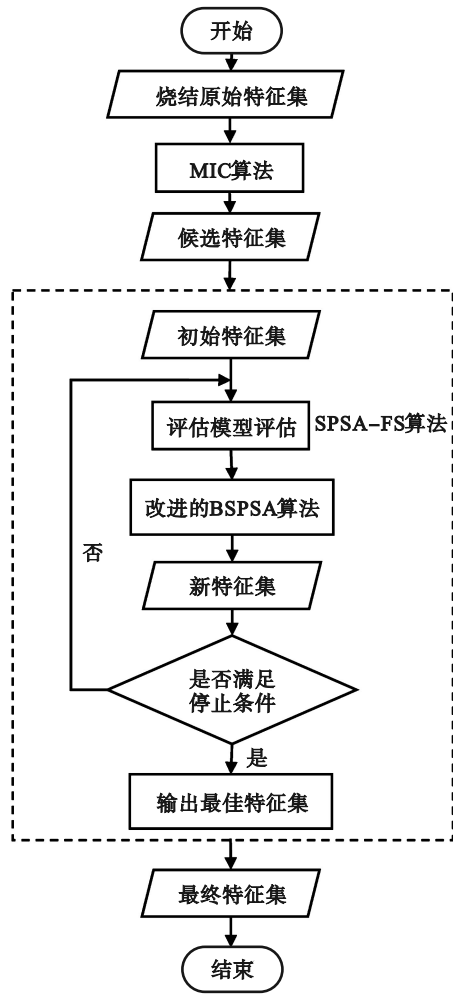


图3 混合特征选择方法流程图

Fig. 3 Flow chart of hybrid feature selection method

2) 计算候选隐藏状态 \tilde{h}_t :

$$\tilde{h}_t = \tanh(x_t W_{xh} + (r_t \odot h_{t-1}) W_{rh} + b_h). \quad (4)$$

式中: W_{xh}, W_{rh} 是权重矩阵; b_h 是偏置项; \odot 表示元素乘法.

3) 计算隐藏状态 h_t :

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t. \quad (5)$$

这一步结合了更新门和候选隐藏状态,以及

前一隐藏状态.更新门 z_t 决定了新旧信息的混合比例,如果 z_t 接近1,则更多保留前一隐藏状态,若接近0,则主要采用候选隐藏状态.

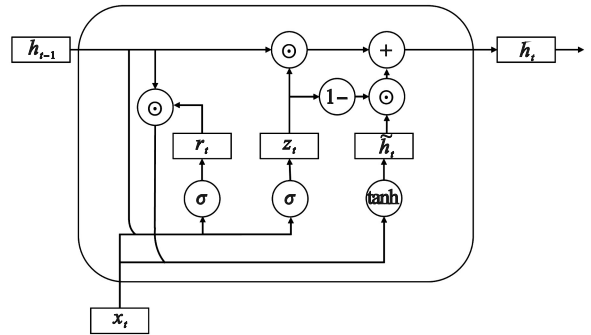


图4 GRU结构图

Fig. 4 GRU structure diagram

3.2 BiGRU 算法

BiGRU是基于GRU的一种变体,它不仅考虑了序列数据的正向时间顺序,同时还考虑了逆向时间顺序,克服了GRU仅依赖过往信息的局限^[15].由于能够捕捉到更广泛的时间依赖性,BiGRU通常能够比单向的GRU提供更准确的预测结果,尤其是在烧结序列特征既受过去影响也受未来预示的场景下.BiGRU的结构图如图5所示,在每个时间步上,正向GRU和反向GRU分别生成各自的隐藏状态.通过特定操作,这些隐藏状态可以合成一个综合的隐藏状态,作为该时间步的最终表示.




图5 BiGRU结构图

Fig. 5 BiGRU structure diagram

3.3 BiGRU-Att

注意力机制源于对人类大脑信息处理模式的启发,旨在模拟人类在处理信息时的选择性注意特性.其设计目的是将注意力资源有针对性地分配给最相关或最重要的部分,而不是均匀地处理所有信息.通过引入注意力机制,模型能够在每个时间步上学习到输入序列中需要重点关注的部分,从而提高模型对关键信息的捕捉能力.

这种方法有助于优化模型处理长序列时的性能,并提升模型的泛化能力.因此,在 BiGRU 网络之后引入注意力机制,可以动态地配置影响转鼓指数变化的因素的权重,以提高预测模型的准确性.

3.4 模型评价指标

本文采用平均绝对偏差(MAE,记为 e_{MA})、均方误差(MSE,记为 e_{MS})及均方根误差(RMSE,记为 e_{RMS})三项评价指标来严谨衡量模型的预测性能,其中,更低的数值标志着更好的预测性能.上述三项指标的量化公式分别为

$$e_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (6)$$

$$e_{MS} = \frac{1}{n} (y_i - \hat{y}_i)^2, \quad (7)$$

$$e_{RMS} = \sqrt{\frac{1}{n} (y_i - \hat{y}_i)^2}. \quad (8)$$

式中: n 为样本数; \hat{y}_i 表示第 i 个样本的预测值; y_i 表示第 i 个样本的实际值.

4 结果分析与讨论

本文利用预处理后的国内某烧结厂收集的真正烧结数据建立了基于混合特征选择的 BiGRU-Att 烧结矿转鼓指数预测模型,通过对比几种常见的预测模型和单一特征选择方法,验证了所提模型的准确性以及混合特征选择方法的有效性.本文以 8:2 的比例将数据划分为训练集和测试集,使用的软件环境是 Python 3.8 和 scikit-learn 1.2.2,硬件环境是型号为 Intel (R) Core(TM) i5-9300H CPU 和 16 GB 的 RAM.

4.1 特征选择结果分析

混合特征选择方法的第一步是通过计算 MIC 从烧结工艺参数中选择与转鼓指数密切相关的输入变量.按照 MIC 值从大到小的顺序,选择了 25 个与转鼓指数相关的过程参数,如表 3 所示.从表 3 可以看出,与转鼓指数相关的过程参数主要有风机风量、风箱负压、风箱废气温度、铁粉、燃料等.国内外烧结生产实践已经证明,在一定范围内增加单位烧结面积的风量,能够提高烧结矿的产量和质量,风机风量和风箱负压对烧结过程的顺利进行有着决定性的影响^[16].风箱废气温度也是转鼓指数的重要影响因素,烧结生产中经常通过风箱废气温度来判断烧结终点的位置.燃料用量对烧结矿转鼓指数有较大影响.燃料用量过低时,烧结过程形成的液相量少,液相黏结强度低,造成烧结矿转鼓指数下降;燃料用量过

多则会造成烧结过程高温区温度提高,增加液相流动性,液相经冷凝后形成大孔薄壁结构,降低了烧结矿的转鼓指数^[17-18].

表 3 MIC 计算结果前 25 的参数

Table 3 Top 25 parameters of MIC calculation results

过程参数	MIC 值	过程参数	MIC 值
风机风量	0.218 0	1号风箱负压	0.125 7
铁粉下料量	0.213 2	3号风箱废气温度	0.121 7
5号风箱负压	0.213 0	燃料下料量	0.119 7
石灰粉下料量	0.201 0	20号风箱废气温度	0.118 4
7号风箱负压	0.190 4	w(混合料水分)	0.105 3
13号风箱负压	0.180 2	南烟道负压	0.099 5
烧结机速度	0.160 7	2号风箱废气温度	0.098 7
1号风箱废气温度	0.150 4	21号风箱废气温度	0.095 9
11号风箱负压	0.146 1	22号风箱废气温度	0.086 8
9号风箱负压	0.145 5	5号风箱废气温度	0.079 4
烧结返矿下料量	0.135 3	22号风箱负压	0.077 3
7号风箱废气温度	0.133 2	北烟道温度	0.076 2
2号风箱负压	0.133 1		

在第二步中,运用 SPSA-FS 算法进一步优化第一步得到的 25 个参数,为给定模型选出 15 个参数作为最终的特征集.表 4 展示了为 BiGRU-Att 模型选出的最佳特征参数.由表 4 可知,SPSA-FS 算法会考虑特征之间的相互作用和组合效应,以及预测模型的特性,从而选出最佳的参数组.

表 4 最佳特征参数

Table 4 Optimal characteristic parameters

参数类型	参数名称
原料参数	铁粉下料量
	燃料下料量
混合料参数	w(混合料水分)
操作参数	烧结机速度
状态参数	北烟道温度
	5号风箱负压
	13号风箱负压
	22号风箱负压
	1号风箱废气温度
	7号风箱废气温度
	3号风箱废气温度
20号风箱废气温度	
21号风箱废气温度	
22号风箱废气温度	
5号风箱废气温度	

4.2 模型预测性能对比分析

为了更好地展示所提模型的预测性能并凸

显混合特征选择方法的优势,对比分析采用混合特征选择、MIC 方法以及 Spearman 秩相关法的 BiGRU-Att, LightGBM, KNN 和 BPNN (back propagation neural network)模型的预测性能.其中 Spearman 秩相关法提取出的前 15 个参数如表 5 所示,对比结果如表 6 所示.

表 5 Spearman 计算结果前 15 的参数
Table 5 Top 15 parameters of Spearman calculation results

过程参数	Spearman 值	过程参数	Spearman 值
1 号风箱负压	0.332 5	9 号风箱负压	0.234 7
11 号风箱负压	-0.326 3	烧结机速度	0.227 6
5 号风箱负压	0.311 7	南烟道温度	-0.205 0
w(混合料水分)	-0.289 6	烧结返矿下料量	0.200 4
2 号风箱负压	0.283 2	南烟道负压	0.176 0
石灰粉下料量	0.269 3	高炉返矿下料量	-0.168 8
13 号风箱负压	0.265 6	风机风量	0.132 0
铁粉下料量	-0.243 7		

表 6 不同组合的烧结矿转鼓指数预测性能比较
Table 6 Comparison of prediction performance for different combinations of sinter drum index

模型	特征选择方法	e_{MA}	e_{MS}	e_{RMS}
LightGBM	Spearman	0.127 4	0.034 4	0.185 4
	MIC	0.120 5	0.031 6	0.177 8
	混合特征选择	0.107 4	0.025 0	0.158 0
KNN	Spearman	0.151 0	0.047 6	0.218 2
	MIC	0.141 6	0.141 6	0.210 4
	混合特征选择	0.129 1	0.035 8	0.189 3
BPNN	Spearman	0.199 9	0.075 5	0.274 7
	MIC	0.261 6	0.117 1	0.342 2
	混合特征选择	0.196 4	0.070 7	0.265 9
BiGRU-Att	Spearman	0.046 0	0.008 6	0.092 6
	MIC	0.043 1	0.008 3	0.091 0
	混合特征选择	0.037 4	0.007 9	0.089 1

表 6 为不同组合的烧结矿转鼓指数预测效果.由表 6 可知,采用混合特征选择方法的 BiGRU-Att 模型在 MAE, MSE 及 RMSE 三项关键指标上均展现出最优值,显著低于其他模型组合的数值.表明使用混合特征选择方法的 BiGRU-Att 模型在预测精度方面具备显著优势.这是因为混合特征选择方法的独特能力,它不仅有效识别出与预测目标强相关的特征,还能捕捉特征间的相互作用与组合效应,从而确保筛选出最佳特征集,提升了模型的整体预测性能.此外, BiGRU-Att 模型擅长捕捉烧结过程参数的长期

依赖关系,并在每个时间步上动态地分配注意力,确保对转鼓指数影响较大的关键时间点和关键特征获得优先关注.因此,采用混合特征选择方法的 BiGRU-Att 模型具有较高的预测性能.

MSE, MAE 与 RMSE 虽能评估模型的整体预测性能,但它们无法细致揭示模型的局部表现能力.因此,为了深入分析采用混合特征选择方法的 BiGRU-Att 模型在转鼓指数预测中的局部表现能力,探究其预测误差的分布特征显得尤为重要.如图 6 所示,构建预测误差的频数直方图,统计直方图信息可得,转鼓指数预测命中率在允许误差 ± 0.25 范围内可达 97.27%,并且可以直观地观察到误差值紧密聚集于零点附近.这一趋势有力地证明了模型预测的准确性和可靠性,进一步证实了所采用方法的有效性.




图 6 烧结矿转鼓指数预测误差频数直方图
Fig. 6 Frequency histogram of prediction error for sinter drum index

为了直观展示采用混合特征选择方法的 BiGRU-Att 模型在烧结矿转鼓指数预测任务中的卓越性能,对比分析了模型预测结果与实际观测值的分布契合度.如图 7 所示,预测值与真实值之间呈现出高度的吻合态势.这表明采用混合特征选择方法的 BiGRU-Att 模型具有较好的预测效果.




图 7 烧结矿转鼓指数预测结果
Fig. 7 Prediction results of sinter drum index

5 结 论

1) 针对单一特征选择方法难以有效地筛选出最优特征集的问题,本文提出了一种混合特征选择方法.该方法结合了 MIC 与 SPSA-FS 的优点,既克服了 MIC 忽略特征之间的相互作用和组合效应的不足,又改善了 SPSA-FS 收敛速度较慢、容易陷入局部最优的缺陷,从而提高了特征选择的准确性和稳定性,最终有效提升了模型预测精度.

2) 针对当前烧结矿转鼓指数预测精度不足的问题,本文建立了 BiGRU-Att 模型,该模型能够有效捕捉烧结过程参数的长期依赖关系,同时关注重要信息,实现了更高的预测精度.所建的预测模型为烧结工艺优化提供了可靠的决策支持.

参考文献:

- [1] 李宇轩.基于深度学习的烧结过程关键指标软测量方法[D].杭州:浙江大学,2022.
(Li Yu-xuan. Soft sensing methods for key indexes of sintering process based on deep learning [D]. Hangzhou: Zhejiang University, 2022.)
- [2] 刘然,张智峰,刘小杰,等.基于工艺理论和卷积神经网络的烧结矿转鼓指数预测[J].钢铁研究学报,2023,35(6): 651-658.
(Liu Ran, Zhang Zhi-feng, Liu Xiao-jie, et al. Prediction of sinter drum index based on convolutional neural network and process theory[J]. *Journal of Iron and Steel Research*, 2023, 35(6): 651-658.)
- [3] Li X, Liu X J, Li H Y, et al. Research on sinter quality prediction system based on Granger causality analysis and stacking integration algorithm[J]. *Metals*, 2023, 13(2): 13020419.
- [4] 张振,李欣,刘颂,等.基于多类别生产状态的烧结矿转鼓指数预测模型[J].中国冶金,2022,32(1): 27-35.
(Zhang Zhen, Li Xin, Liu Song, et al. Predictive model of sinter drum index based on multi-category production status [J]. *China Metallurgy*, 2022, 32(1): 27-35.)
- [5] Ren X Y, Yang B, Luo N, et al. The prediction of sinter drums strength using hybrid machine learning algorithms [J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 4790736.
- [6] 郝良元,刘福龙,刘小杰,等.基于深度森林算法的烧结矿转鼓指数预测模型[J].冶金自动化,2022,46(4): 78-85.
(Hao Liang-yuan, Liu Fu-long, Liu Xiao-jie, et al. Prediction model of sintered ore drum index based on deep forest algorithm [J]. *Metallurgical Industry Automation*, 2022, 46(4): 78-85.)
- [7] Xia G L, Wu Z X, Liu M Y, et al. Prediction interval estimation of sinter drum index based on light gradient boosting machine and kernel density estimation [J]. *Ironmaking & Steelmaking*, 2023, 50(8): 909-920.
- [8] Apolloni J, Leguizamón G, Alba E. Two hybrid wrapper-filter feature selection algorithms applied to high-dimensional microarray experiments [J]. *Applied Soft Computing*, 2016, 38: 922-932.
- [9] Hsu H H, Hsieh C W, Lu M D. Hybrid feature selection by combining filters and wrappers [J]. *Expert Systems with Applications*, 2011, 38(7): 8144-8150.
- [10] Du S, Wu M, Chen L F, et al. Operating mode recognition of iron ore sintering process based on the clustering of time series data [J]. *Control Engineering Practice*, 2020, 96: 104297.
- [11] Yenice Z D, Adhikari N, Wong Y K, et al. SPSA-FSR: simultaneous perturbation stochastic approximation for feature selection and ranking [EB/OL]. (2018-04-16) [2023-12-11]. <https://doi.org/10.48550/arXiv.1804.05589>.
- [12] Aksakalli V, Malekipirbazari M. Feature selection via binary simultaneous perturbation stochastic approximation [J]. *Pattern Recognition Letters*, 2016, 75: 41-47.
- [13] Cho K, Van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [EB/OL]. (2014-06-03) [2023-12-11]. <https://arxiv.org/abs/1406.1078>.
- [14] Yamak P T, Li Y J, Gadosey P K. A comparison between ARIMA, LSTM, and GRU for time series forecasting [C]// Proceedings of the 2019 2nd International Conference on Algorithms, Computing and Artificial Intelligence. Sanya, 2019: 49-55.
- [15] Duan Y H, Li H H, He M Q, et al. A BiGRU autoencoder remaining useful life prediction scheme with attention mechanism and skip connection [J]. *IEEE Sensors Journal*, 2021, 21(9): 10905-10914.
- [16] Umadevi T, Brahmacharyulu A, Sah R, et al. Influence of sinter grate suction pressure (flame front speed) on microstructure, productivity and quality of iron ore sinter [J]. *Ironmaking & Steelmaking*, 2014, 41(6): 410-417.
- [17] Gao Q J, Wang H, Pan X Y, et al. A forecast model of the sinter tumble strength in iron ore fines sintering process [J]. *Powder Technology*, 2021, 390: 256-267.
- [18] Yi Z M, Liu Q, Qin J Z. Optimization of sintering strength based on response surface methodology [J]. *Transactions of the Indian Institute of Metals*, 2021, 74(12): 3085-3092.