

智能算法在转炉热损失率预测中的应用

闵义^{1,2*}, 景林^{1,2}, 陈硕^{1,2}, 张龙强^{1,2}, 亓捷^{1,2}, 刘承军^{1,2}

1. 多金属共生矿生态化冶金教育部重点实验室, 辽宁 沈阳 110819; 2. 东北大学冶金学院, 辽宁 沈阳 110819

Application of Intelligent Algorithm in Prediction of Heat Loss Rate of Converter

Min Yi^{1,2*}, Jing Lin^{1,2}, Chen Shuo^{1,2}, Zhang Longqiang^{1,2}, Qi Jie^{1,2}, Liu Chengjun^{1,2}

1. Key Laboratory for Ecological Metallurgy of Multimetallurgical Ministry (Ministry of Education), Shenyang 110819, Liaoning, China; 2. School of Metallurgy, Northeastern University, Shenyang 110819, Liaoning, China

1. 前言

转炉冶炼的目标是为精炼和连铸提供合格成分和温度的钢水, 冶炼目标的达成对于钢水质量、生产效率及经济效益具有重要影响, 受限于转炉冶炼本身所具有的高温复相反应, 附加原料条件、生产节奏多变的影响, 控制难度高, 冶炼目标往往难于稳定达成。

转炉冶炼目标的达成主要受到两个方面的影响, 一方面是氧耗、渣料、冷却剂等物料消耗控制, 另一方面是供氧、投料等冶炼过程控制, 其中物料消耗控制是基础。在实际生产中, 物料消耗通常通过建立在物料平衡和热平衡基础上的模型进行预测, 模型中包含了热损失率、氧气利用率等系列参数, 这些参数通常是固定的, 无法适应原料条件、过程操作及冶炼目标多变的需求, 导致模型预测精度有限, 在根本上制约了冶炼目标的达成。

近年来, 人工智能技术快速发展, 在蛋白质预测、聊天机器人等领域展现了良好的发展前景[1], 冶金也逐步成为重要的应用场景, 对于转炉, 在渣料消耗预测、冶炼终点成分预测、冶炼终点温度预测等方面进行积极探索[2-5]。本文尝试利用转炉冶炼历史数据, 采用智能算法对转炉热损失率进行预测, 以期能够提高物料消耗模型的适用性及预测精度。

2. 研究方法

2.1. 数据采集与处理

数据来自于国内某炼钢厂 150 吨转炉冶炼实绩, 共选取了 1900 炉次有效数据作为样本数据, 样本数据中包括熔炼号、生产日期、钢种、炉次间隔时间、铁水重量、铁水成分、铁水温度、废钢重量、渣料种类、渣料重量、出钢温度、目标钢水成分等信息。根据冶炼数据, 依据物料平衡和热平衡计算出了每个炉次的热损失, 其中热收入包括铁水物理热、元素氧化热及成渣热、烟尘中铁的氧化热和炉衬中碳的氧化热; 其中热支出包括钢水物理热、炉渣物理热、造渣剂的分解热、烟尘物理热、炉气物理热; 热损失定义为除了上述热支出之外的转炉向外部空间的散热, 热损失率为热损失与热收入的比值。

2.2. 算法实现与评价

采用皮尔逊相关系数法确定转炉热损失率预测模型的特征变量。采用 python 编程语言, 在 Jupyter lab 开发环境下, 使用 `train_test_split` 函数拆分数据并划分训练集和测试集, 其中训练集与测试集的比例为 7:3, 并对各智能算法进行训练及热损失率预测。采用决定系数 (R^2) 和均方根误差 (RMSE) 评价模型预测结果, 其中 R^2 用于评价模型的拟合程度, 范围在 0~1 之间, 其值越接近 1, 表明特征变量对热损失率预测值的解释能力越强; 其中 RMSE 用于评价模型预测值的准确度, 其值越小, 表明模型精确度越高。

3. 结果分析与讨论

3.1. 特征选择

转炉热损失是指冶炼过程转炉向外部空间的散热，影响散热的主要因素为温度和吹炼时间，与铁水条件、冶炼目标及生产节奏等密切相关。为进一步确定模型的特征参数，采用皮尔逊相关系数法评价了各特征变量与热损失率的相关程度。在本研究中，剔除了相关系数在-0.06 与 0.06 之间的特征变量，确定用于模型训练的特征变量（按相关程度排序）包括铁水温度、铁水重量、废钢重量、铁水碳含量、铁水硅含量、铁水锰含量、钢种目标温度、钢种目标碳含量和上炉次终点温度。

3.2. 预测结果与评价

本研究选用了八种智能算法对热损失率进行预测，分别属于三大类别，第一类是神经网络算法，包括 BP 神经网络(Back Propagation Neural Network)和径向基函数神经网络(Radial Basis Function Neural Network)两种算法；第二类是基于核函数的算法，包括支持向量回归(Support Vector Regression, SVR)和核岭回归(Kernal Ridge Regression, KRR)两种算法；第三类是基于决策树的算法，包括随机森林(Random Forest, RF)、梯度提升树(Gradient Boosting Decision Tree, GBDT)、极限梯度提升树(Extreme Gradient Boosting, XGB)和轻量级梯度提升机(Light Gradient Boosting Machine, LGBM)四种。对于每种算法，均采用随机搜索方法对参数进行了优化，以获得最佳的预测结果。

表 1 为八种智能算法预测结果的评价数据。综合来看，对于转炉热损失率预测，在三类模型中，基于决策树的算法的预测效果最好，神经网络次之，而基于核函数的算法较差。其中 LGBM 算法的预测效果最好， R^2 和 RMSE 值分别达到了 0.94 和 0.008，在 ± 0.01 和 ± 0.005 精度范围内的命中率分别达到了 94%和 91%。

表 1 智能算法预测结果的评价
Table 1 Evaluation of prediction results of different algorithms

	SVR	KRR	RF	GBDT	XGB	LGBM	BPNN	RBFNN
R^2	0.79	0.83	0.89	0.88	0.93	0.94	0.93	0.91
RMSE	0.02	0.014	0.01	0.01	0.009	0.008	0.009	0.009
精度范围 ± 0.005	75%	81%	88%	85%	90%	91%	90%	89%
精度范围 ± 0.01	80%	84%	91%	90%	93%	94%	92%	91%

4. 结论

(1) 对于转炉热损失率预测，特征参数按相关程度依次为铁水温度、铁水重量、废钢重量、铁水碳含量、铁水硅含量、铁水锰含量、钢种目标温度、钢种目标碳含量和上炉次终点温度，与机理相符。

(2) 各种智能算法均可实现转炉热损失率的预测，但预测精度存在差异，其中基于决策树的 LGBM 算法的预测精度最高，在 ± 0.01 和 ± 0.005 精度范围内的命中率分别可达到 94%和 91%。

参考文献

- [1] Quinlan J R. Induction of decision trees[J]. Machine Learning, 1986, 1: 81-106.
- [2] Bae Juhee, LI Y, Ståhl N, et al. Using machine learning for robust target prediction in a basic oxygen furnace system[J]. Metallurgical & Materials Transactions B, 2020, 51(4): 1632.
- [3] Rahnama A, LI Z, Sridhar S. Machine learning-based prediction of a BOS reactor performance from operating parameters[J]. Processes, 2020, 8(3): 371.
- [4] Dogan N, Brooks G A, Rhamdhani M A. Comprehensive model of oxygen steelmaking part 1: model.development and validation[J]. ISIJ International, 2011, 51(7): 1086.
- [5] Lytvyniuk Y, Schenk J, Hiebler M, et al. Thermodynamic and kinetic model of the converter steelmaking process. Part 2: the model validation[J]. Steel Research International, 2014, 85(4): 544.