

基于机器学习的板坯加热炉性能 预测模型研究

刘 勇¹, 宁 榛², 廖哲晗², 朱焱麟^{2*}, 唐 政¹, 付 芹¹, 邓 超¹

(1. 攀钢集团攀枝花钢铁钒有限公司板材厂, 四川 攀枝花 617061; 2. 成都先进金属材料产业技术研究院股份有限公司, 四川 成都 610300)

摘 要: 基于国内某钢铁厂 1 450 mm 热连轧加热炉生产线采集的 8 297 组数据, 建立了四组不同输入变量的 XGBoost 和 LSTM 模型, 对出炉钢温、单耗和烧损进行了预测和比较分析。结果表明, LSTM 模型在出炉钢温和烧损的预测中表现出色, 决定系数 R^2 均超过 0.95, 预测精度和稳定性均较高; 而 XGBoost 模型在单耗预测方面表现优异, 决定系数达 0.94 以上变化趋势稳定。通过对比分析得出, LSTM 在出炉钢温和烧损的预测中具有更高的可靠性, 而 XGBoost 在单耗预测上精度更高。研究还显示, LSTM 因门控机制擅长捕捉时序依赖(如钢温、烧损), 而 XGBoost 通过特征组合优化对静态参数(如单耗)更敏感。将两种模型联合建模构建 LSTM-XGBoost 联合模型, 分别处理时序特征与静态特征, 应用于加热炉工艺控制, 可进一步提升出炉钢温、单耗和烧损的预测精度, 为钢铁行业加热工艺的优化控制和资源的高效利用提供了理论支持与数据依据。

关键词: 热连轧; 加热炉; 机器学习; 加热工艺优化

中图分类号: TF319, TP181

文献标志码: A

文章编号: 1004-7638(2025)05-0065-10

DOI: 10.7513/j.issn.1004-7638.2025.05.007

开放科学(资源服务)标识码(OSID):



听
语
音
与
作
者
互
动
聊
科
研

Study on performance of Machine-Learning-Based prediction model for slab reheating furnaces

LIU Yong¹, NING Zhen², LIAO Zhehan², ZHU Yanlin^{2*}, TANG Zheng¹, FU Qin¹, DENG Chao¹

(1. Pangang Group Panzhihua Steel and Vanadium Co. Ltd. Panzhihua 617067, Sichuan, China; 2. Chengdu Advanced Metal Materials Industry Technology Research Institute Co., LTD. ChengDu 610300, Sichuan, China)

Abstract: Based on 8 297 data samples from a 1 450 mm hot-strip mill reheating furnace in a Chinese steel plant, XGBoost and LSTM models using four sets of input variables had been developed and used to predict furnace discharge temperature, energy consumption of per ton steel, and oxidation burn rate. It was found out that the LSTM model performed well in predicting furnace discharge temperature and oxidation burn rate, with coefficients of determination (R^2) exceeding 0.95. The XGBoost model was superior in predicting energy consumption, achieving R^2 values above 0.94 and stable prediction trends. Comparative analysis indicated that LSTM was more reliable for predicting time-dependent parameters (such as discharge temperature and oxidation burn), while XGBoost provided higher accuracy for static parameters (such as energy consumption). Further investigation revealed that LSTM effectively captures time-related patterns due to its gated mechanism. In contrast, XGBoost performed better on static

收稿日期: 2025-07-28; 修回日期: 2025-08-08; 接受日期: 2025-08-08

作者简介: 刘勇, 1972 年出生, 男, 四川阆中人, 硕士, 正高级工程师, 主要从事热连轧工艺技术研究及产品开发工作, E-mail: liuy@pzhsteel.com.cn; *通讯作者: 朱焱麟, 1989 年出生, 男, 重庆市人, 博士研究生, 工程师, 主要从事数据驱动的新材料设计与数字孪生驱动的生产力提升研究, E-mail: ali.yanlinzhu@outlook.com。

features due to its ability to optimize feature combinations. Based on these findings, a hybrid LSTM-XGBoost model was proposed. In this combined model, LSTM deals with time-series data, and XGBoost processes static data. Applying the combined model to furnace control can further improve prediction accuracy. This study provides theoretical guidance and data support for optimizing reheating furnace operations and enhancing resource efficiency in the steel industry.

Key words: hot strip rolling, reheating furnace, machine learning, heating-process optimization

0 引言

钢铁产业是国民经济发展的重要基础,其发展状况反映了一个国家工业化水平和综合国力。加热炉是钢铁生产中主要的耗能设备,约占生产过程能源消耗的 60%^[1]。加热炉的主要功能是加热钢坯,使其达到预定温度,然后进行轧制。钢坯的加热温度是钢坯质量的决定因素之一,由于钢坯温度无法直接测量,研究者们通常利用数字模拟技术对钢坯温度进行预测。然而,由于钢坯加热过程具有大滞后、大惯性、多变量、时变和非线性等特点^[2],很难精确预测钢坯温度。

目前对于钢坯温度预测模型的研究可以分为两大类:①基于工艺理论的多元回归模型^[3-4];②基于工艺理论和现代控制理论融合的智能学习模型^[5-7]。多元回归模型忽略了非线性因果关系,准确性相对较差,容易被外界影响,故目前研究者们多采用智能学习模型对加热炉的加热效果进行预测。例如,周建新等^[8]通过改进鸚鵡算法对长短期记忆网络(Long Short-Term Memory, LSTM)模型进行参数优化,最终建立的 IPOA-LSTM 温度预测模型取得了很高的预测精度。孙洁等^[9]使用蚁群优化后的反传播神经网络(Back Propagation Neural Network, BPNN)模型,不仅预测温度的精度更高,而且收敛速度也更快。HU 等^[10]提出了一种将数据驱动模型与传统机理知识相结合的混合模型,该模型通过热传导机理建立温度分布方程,并结合过程参数使用 LSTM 预测温度,优化后续加热阶段参数,最终温度预测误差小于 4 °C,异常出炉温度的钢坯减少 42.9%。从以上研究可以看出,对加热炉的模型预测目前大部分集中在钢坯出炉温度方面,而想要更好地优化加热炉的加热效果、降低能量消耗、提高钢坯质量,除了钢坯的出炉温度外,准确预测加热炉的单耗和烧损也十分重要。加热炉工艺优化的经济价值显著,通过降低单耗和烧损可直接减少能源成本与金属损失,有效降低生产总成本和碳排放,实现

经济效益与环境效益的双赢。

尽管现有研究在加热炉温度预测上取得进展,但存在两个关键空白:①多目标预测缺失:当前模型多聚焦于温度单一指标,而实际生产需同步优化能耗与烧损;②工业数据特性处理不足:现有方法对加热炉数据的高噪声、强耦合特性缺乏针对性设计。因此,文中基于国内某钢铁厂加热炉现场采集的数据,结合 XGBoost (Extreme Gradient Boosting) 和 LSTM 两种模型,融合构建了 LSTM-XGBoost 联合模型,用于预测加热炉出炉钢温 T_d 、单耗 E_i 和烧损 B_o 。通过对比分析两种模型的综合性能,为后续优化加热炉的参数控制提供了基础。

1 数据处理

1.1 数据收集与预处理

数据数量和质量是建立机器学习模型的基础。模型共采集现场 8 297 组数据。主要包括温度参数(预热段炉温 T_p 、加热段炉温 T_h 、均热段炉温 T_s 、热风温度 T_b 、入炉钢温 T_i)、钢坯特性(钢坯重量 W_b 、钢坯宽度 D_b 、钢坯长度 L_b)、加热时长(总时长 t 、预热段时长 t_p 、加热段时长 t_h 、均热段时长 t_s)、阀门开度(预热段煤气开度 O_{gp} 、加热段煤气开度 O_{gh} 、均热段煤气开度 O_{gs} 、预热段空气开度 O_{ap} 、加热段空气开度 O_{ah} 、均热段空气开度 O_{as})、流量参数(预热段煤气流量 F_{gp} 、加热段煤气流量 F_{gh} 、均热段煤气流量 F_{gs} 、预热段空气流量 F_{ap} 、加热段空气流量 F_{ah} 、均热段空气流量 F_{as})等,共计 24 个不同维度的特征参数。然而,由于工业现场环境的复杂性,原始数据中存在噪声、缺失值及异常值等问题,需通过预处理方法提升数据质量。

加热炉数据中的缺失值主要由传感器故障、数据库异常或人为操作等因素引起,表现为离散点缺失或连续长缺失。常见的处理方法包括删除法和插补法。然而,简单删除缺失数据可能破坏时间序列的完整性,并导致有价值信息的丢失,从而影响模型预测的可靠性。因此,采用插补法以尽可能保持数

据的原始特征。首先,需要评估数据缺失的程度。对于长时间、大范围缺失的数据,由于无法有效补全,其使用价值较低,应予以剔除。对于短时间的零星缺失数据,如因传感器故障或记录误差导致的缺失等,考虑到生产的连续性特征,可以采用线性插值方法进行补全。

此外,为了避免因采集数据的数值差异引发的梯度不稳定或特征偏好,提升模型的训练速度和预测精度,对采集的数据进行归一化处理,用公式(1)计算。

$$x' = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x_0 为原始特征值,即数据集中某个特征的原始值; $x_{\min}$ 为该特征在数据集中的最小值,用于确定缩放范围的下界; $x_{\max}$ 为该特征在数据集中的最大值,用于确定缩放范围的上界; x' 为归一化后的特征值,缩放到 0 和 1 之间。

采用公式(1)Min-Max 归一化将特征缩放至 [0,1] 区间。该方法的选择主要基于其计算简便且能有效消除不同特征量纲差异带来的负面影响,特别适用于文中特征取值范围差异较大(如温度数值在百位级,开度在 0 ~ 100%)且后续使用的机器学习算法(如 XGBoost、LSTM)对输入特征的尺度较为敏感的场景。虽然 Z-score 标准化也是常见方法,但在本数据集特征分布非严重偏斜的情况下,Min-Max 归一化足以满足提升模型收敛速度和优化效果的需求,并避免了标准化后部分特征可能出现负值对某些模型(如要求非负输入的算法)的潜在影响。

为避免模型在训练数据上过拟合,确保模型在新数据上也能保持准确和稳定的预测效果,将采集到的 8 297 组数据按 7:3 比例(训练集 70%,测试集 30%)随机划分为 5 808 组训练样本集和 2 489 组测试样本集。训练集用来确定模型的参数,让模型学习数据中的模式、规律和特征。测试集用于评估模型的性能,检查模型是否从未见过的数据上也能表现良好。

1.2 相关性分析方法

为了进一步分析不同特征参数对加热炉出炉钢温、单耗和烧损的影响程度,从数据分析的角度出发,采用多种方法解析参数之间的线性与非线性相关关系,筛选出具有代表性且高预测能力的特征参

数。其中,皮尔逊相关系数 (Pearson Correlation Coefficient, 以下简称: PCC) 是用于衡量两个参数之间的线性相关关系强弱的统计指标,可以帮助判断参数间的冗余并辅助参数的筛选^[11]。假设两个变量 x 和 y , 其样本值分别为 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, 皮尔逊相关系数 r_{xy} 的计算如式 (2) 所示。

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

式中, $\bar{x}$ 和 $\bar{y}$ 分别为 x 和 y 的均值, n 为样本量。 r_{xy} 值的取值范围为 $[-1, 1]$, 当 r_{xy} 越接近 1 或 -1 时, 表明变量之间的线性相关性越强; 接近 0 时, 表明两者基本无线性相关性。

此外, 互信息 MI (Mutual Information) 则是另一种基于信息论的特征选择方法, 用于度量两个随机变量之间的关联程度^[12]。与皮尔逊相关系数不同, 互信息法不仅能检测线性关系, 也能识别非线性相关性, 在多种数据场景下具有广泛的应用。具体来说, 互信息法反映了一个变量中包含的关于另一个变量的信息量, 或解释为已知某个变量后, 对另一个变量的不确定性减少的程度。当两个变量完全独立时, 互信息值为零; 而当两个变量相关性越强时, 互信息值越大。对于两个离散随机变量 x 和 y , 互信息的定义如式(3)所示。

$$I(x; y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log_2 \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (3)$$

式中, $p(x, y)$ 是 x 和 y 的联合概率分布函数, $p(x)$ 和 $p(y)$ 分别是 x 和 y 的边缘概率分布函数。互信息在特征选择过程中可用于评估变量之间的依赖性, 从而筛选出对目标变量影响较大的特征。

2 模型框架与原理

2.1 XGBoost 模型算法

XGBoost 是一种高效的梯度提升算法, 广泛应用于回归和分类任务。其基本原理是通过集成多个弱学习器(通常是决策树)来逐步优化模型性能。XGBoost 首先从一个初始模型(通常为均值)开始预测, 并计算当前模型预测值与真实值之间的残差。随后, 通过训练新的决策树以拟合这些残差, 逐步纠正前一棵树的错误, 并将新树的预测结果加入当前模型中, 不断迭代, 直到满足停止条件, 其训练流程

如图 1 所示^[13]。其关键组件包括损失函数、正则化项和并行计算,其中损失函数用于衡量模型预测的准确性,正则化项有助于控制模型复杂度以防止过拟合,而并行计算则利用多核 CPU 加速训练过程。此外,XGBoost 采用贪心算法选择最佳分裂点,以最大化信息增益或最小化损失,最终通过优化目标函数来提升模型的预测精度。这些特点使 XGBoost 在处理大规模数据时表现出色,成为许多机器学习任务中的优选模型。




图 1 XGBoost 的训练流程
Fig. 1 XGBoost training workflow

2.2 LSTM 模型网络

LSTM 是一种特殊的递归神经网络 (Recurrent Neural Network, RNN),旨在解决传统 RNN 在处理长序列数据时遇到的梯度消失和爆炸问题。LSTM 通过引入门控机制,有效地控制信息的保存和遗忘,从而捕捉长期依赖关系。其基本单元包括输入门、遗忘门和输出门^[14]。

遗忘门决定了先前单元状态中信息的保留程度,输入门则决定当前输入信息的更新程度,并结合新的候选状态来更新单元状态。最终,输出门控制从当前单元状态输出的信息量。通过这些机制,LSTM 能够选择性地保留或遗忘信息,使其在处理长序列数据(如时间序列和自然语言处理)时表现出色,克服了传统 RNN 的局限性。

遗忘门 (f_t) 的任务是负责控制记忆单元状态信息的舍弃与保留,其计算公式见式 (4)。

$$f_t = \sigma(W_{xf}x_t + w_{hf}h_{t-1} + b_f) \quad (4)$$

式中, W_f 和 b_f 分别为权重矩阵和偏置, h_{t-1} 为上一时刻的隐状态, x_t 为当前输入, σ 为 Sigmoid 激活函数。遗忘门的输出范围为 $[0, 1]$, 当值接近 0 时, 表示信息被遗忘; 当值接近 1 时, 表示信息被保留。

输入门 (i_t) 的任务是负责更新记忆单元状态, 用于控制当前输入数据流入记忆单元的多少。其计算见式 (5)(6)。

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (5)$$

$$\tilde{C}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (6)$$

式中, i_t 代表输入门的激活值, $\tilde{C}_t$ 为新的候选记忆单元状态, $\tanh$ 函数用于生成新的状态信息。最终, 输入门的输出将用于更新单元状态。

Sigmoid 函数 ($\sigma(x)$) 和 Tanh 函数 ($\tanh(x)$) 的表达式见式 (7)(8)。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8)$$

单元状态 (C_t) 是 LSTM 神经网络的核心, 其计算公式见式 (9)。

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (9)$$

式中, 遗忘门决定上一时刻的状态 C_{t-1} 该保留多少, 输入门决定新计算的候选状态 $\tilde{C}_t$ 该添加多少, 从而实现对记忆信息的动态调整。

输出门 (h_t) 控制当前时刻的隐状态输出, 其计算公式见式 (10)(11)。

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (10)$$

$$h_t = o_t \times \tanh(C_t) \quad (11)$$

式中, o_t 控制单元状态 C_t 传递到输出层的比例, 最终决定 LSTM 单元的输出 h_t 。

LSTM 通过门控机制有效地调整信息流, 使得模型在长期趋势学习和短期波动捕捉之间取得平衡, 适用于处理复杂的时间序列问题。对于传感器噪声, LSTM 的遗忘门具有天然滤波特性; 在加热炉加热过程中, 出炉钢温、单耗和烧损受到多因素影响, 如煤气流量、热风温度、入炉钢温等, 并且不同时间尺度下的参数的重要性并不完全相同。LSTM 通过门控单元自动调整不同时间步的权重, 遗忘门(式(4))的 sigmoid 输出实质是历史状态的衰减系数。当钢坯进入均热段时, 会对预热段温度赋予 0.2 ~ 0.3 的

低权重,符合热传导过程中历史影响递减的物理规律。使其在出炉钢温、单耗和烧损预测任务中具有优势。

2.3 模型评价指标

为了验证模型在预测加热炉出炉温度、单耗和烧损方面的准确性,采用了均方根误差 (Root Mean Square Error, 简称 RMSE) 和决定系数 (Coefficient of Determination, R^2) 两个评价指标,其表达式如式 (12)(13) 所示。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

式中, n 为样本数量; y_i 为样本的真实值; $\hat{y}_i$ 为样本的预测值; $\bar{y}$ 为真实值的平均值。选择 RMSE 和 R^2 作为评价指标可以分别从误差精度和拟合优度两个角度全面衡量模型的性能。其中 RMSE 的数值越小,模型的预测结果越接近真实值,模型的精度越高。 R^2 的数值越接近 1,则表明模型对整体数据拟合度越好。

2.4 模型联合建模

基于 XGBoost 和 LSTM 的互补特性,可构建 LSTM-XGBoost 联合模型,用于预测加热炉出炉钢温、单耗和烧损。两类模型的优势互补主要体现在三个层面:①在特征处理维度上 LSTM 通过细胞状态建立跨时间步的微分关系,可精确刻画炉温变化率对烧损的影响;而 XGBoost 则通过特征分裂点优化捕捉参数间的非线性交互(如分析单耗指数级增长时);②在工业数据适应性方面, LSTM 凭借其遗忘门机制天然具备对传感器噪声的滤波能力;而 XGBoost 则对数据缺失具有更强的鲁棒性。③在计算效率方面, XGBoost 利用特征并行技术高效处理静态特征,单次预测耗时通常低于 5 ms; LSTM 借助 CUDA 加速,处理包含 1 000 个时间步的序列仅需约 12 ms,其内存占用也优化至传统 RNN 的三分之一左右。进行混合建模既保留了 LSTM 对加热过程动态特性的建模能力,又发挥了 XGBoost 在静态特征解析上的优势,为多目标协同预测提供统一框架。

3 结果与讨论

基于前述的联合模型(XGBoost 和 LSTM 模型),系统探讨了两个模型分别对加热炉出炉钢温、单耗和烧损的预测性能,并深入分析了不同输入特征组合对预测有效性的影响。

3.1 特征筛选

加热炉生产线收集的特征参数众多,并且不同特征参数对于加热炉出炉钢温、单耗和烧损的影响程度各不相同。因此,结合皮尔逊相关系数和互信息两种方法,分别从线性相关性分析和非线性相关性分析的多变量分析视角,筛选出既具有代表性又能提升预测性能的关键特征参数。


图 2 为加热炉部分特征参数对于出炉钢温(图 2(a))、单耗(图 2(b))和烧损(图 2(c))的皮尔逊相关性系数分布图。结果表明,多数特征参数与加热炉出炉钢温、单耗和烧损的线性相关系数较低,这是由于加热炉加热过程的高度非线性特征,出炉钢温、单耗和烧损受多因素耦合作用影响,其变化规律难以通过单一线性关系准确描述。然而,尽管整体线性相关性较弱,皮尔逊相关系数仍可反映变量之间的作用方向,为进一步分析参数对出炉钢温、单耗和烧损的影响提供参考。此外,图中也表明部分操作参数之间存在较高相关性,例如均热段和加热段炉温等变量与出炉钢温的相关性系数分别为 0.65 和 0.45,并且这两个特征值对出炉钢温均具有正向相关性影响。总时长和入炉钢温与单耗的相关系数分别为 0.77 和 -0.64,因此总时长对单耗具有正向相关性影响,而入炉钢温对单耗具有负向相关性影响。对于烧损而言,煤气开度具有较高的相关性,相关系数最高可达 -0.43,因此煤气开度对于烧损具有负向相关性影响。

由此可以得到关键特征分别为:均热段炉温,入炉钢温,煤气开度;可以从冶金机理角度解释关键特征的影响;均热段炉温主导钢温预测,符合热传导方程,末端炉温决定钢坯表面热流密度;入炉钢温与单耗负相关:初始温度每升高 10 ℃,煤气消耗约减少 1.72 m³/t(验证能量守恒定律);煤气开度影响烧损:开度>65%时空燃比升高,促进氧化铁反应加速(与氧化动力学模型一致);通过数据-机理的相互印证,增强了特征选择的可靠性。

综上所述,部分参数信息与出炉钢温、单耗和烧损存在多重共线性。皮尔逊方法有效去除了冗余信息,但后续仍需结合其他方法进一步探索参数间

的非线性关系,以更精确地描述加热炉特征参数与出炉钢温、单耗和烧损之间复杂的影响。

图3分别展示了通过互信息方法量化了部分特征参数与出炉钢温(图3(a))、单耗(图3(b))和烧损(图3(c))的非线性依赖关系。从图中可以看出,对于出炉钢温而言,均热段炉温(MI=0.46)和总时长(MI=0.18)对于出炉钢温影响最大;对于单耗而言,入炉钢温(MI=0.64)和总时长(MI=0.49),以及热风温度(MI=0.42)对于单耗影响最大;而对于烧损而言,预热段煤气流量(MI=0.34)相对影响较大。然而,在单因素分析中,大部分特征参数与出炉钢温、单耗和烧损之间的互信息值普遍较低,包括板坯物理属性、空气开度、热风温度等重要参数,其互信息值也未超过0.1。这表明,单一参数所携带的信息有限,难以独立精准预测出炉钢温、单耗和烧损。




(a) 出炉钢温; (b) 单耗; (c) 烧损

图2 部分输入特征与出炉钢温、单耗和烧损的皮尔逊相关系数

Fig. 2 Pearson correlation coefficient values between selected input features and T_d , E_i and B_o

结合皮尔逊相关系数以及互信息值,综合筛选出候选输入特征值可以用于出炉钢温、单耗、烧损的预测。这些输入特征分别为:钢坯宽度,钢坯长度,

入炉钢温,每个加热段的加热时长,总时长,每个加热段的开度以及每个加热段的炉温。为了研究输入特征参数对模型精度的影响,并得到最佳的模型输入特征,设置了四组输入变量作为模型的数据集,具体如表1所示。



(a) 出炉钢温; (b) 单耗; (c) 烧损

图3 部分输入特征与出炉钢温、单耗和烧损的互信息值

Fig. 3 Mutual information values between selected input features and T_d , E_i and B_o

表1 机器学习模型的输入与输出特征参数

Table 1 Input and output feature parameters of the machine-learning models

Condition	Input features	Output features
1	$D_b, L_b, T_i, t_p, t_h, t_s, t, O_{gp}, O_{gh}, O_{gs}$	
2	$D_b, L_b, T_i, t, O_{gp}, O_{gh}, O_{gs}$	T_d, E_i, B_o
3	$D_b, L_b, T_i, t_p, t_h, t_s, t, T_p, T_h, T_s$	
4	$D_b, L_b, T_i, t, T_p, T_h, T_s$	

3.2 超参数调优

在完成特征筛选后,为确保模型性能达到最优,对XGBoost和LSTM模型进行了系统的超参数调优。

调优过程采用网格搜索(Grid Search)方法,针对两类模型的核心参数设定搜索空间:XGBoost模型聚焦于树结构相关参数(如树深度、学习率、子采

样率)和正则化强度(如 L_1/L_2 系数); LSTM 模型则侧重网络结构(如隐藏层单元数、时间步长)和训练策略(如丢弃率、优化器选择)。通过五折交叉验证评估不同参数组合的性能,最终选定在验证集上预测误差最小且收敛稳定的最优参数配置。所有后续试验均基于此最优参数组合开展,以保证模型对比的公平性。表 2 展示了调优过程中关键超参数的搜索范围及最终确定的最优值。

表 2 模型超参数调优配置
Table 2 Hyperparameter tuning configurations for the models

Model	Hyperparameter	Search scope	Optimal value
XGBoost	Tree depth	[3, 5, 7, 10]	7
	Learning rate	[0.01, 0.05, 0.1, 0.2]	0.1
	Subsample	[0.6, 0.8, 1.0]	0.8
	L_1 regularization coefficient	[0, 0.1, 0.5]	0.1
LSTM	Number of hidden layer units	[32, 64, 128]	64
	Time steps	[5, 10, 15]	10
	Dropout	[0.1, 0.2, 0.3]	0.2
	Optimizer	[Adam, RMSprop, SGD]	Adam

3.3 XGBoost 模型预测效果

表 3 展示了不同输入条件下 XGBoost 模型对三项指标的预测性能。结果表明,输入特征的组合显著影响模型精度。

表 3 XGBoost 模型预测能力评价指标
Table 3 Evaluation metrics for the predictive capability of the XGBoost model

No.	RMSE			R^2		
	T_d	E_i	B_o	T_d	E_i	B_o
1	9.99	0.054	0.141	0.86	0.95	0.85
2	11.17	0.054	0.15	0.83	0.95	0.83
3	6.59	0.06	0.197	0.94	0.94	0.70
4	9.0	0.063	0.231	0.89	0.94	0.59

在均方根误差方面,出炉钢温的 RMSE 在条件 3 下最低,为 6.59,表明在这一条件下模型的预测精度最佳。单耗的 RMSE 在条件 1 和条件 2 下均为 0.054,显示出相对稳定的预测性能,但在其他条件下略有上升。烧损的预测在条件 4 下表现最弱(RMSE=0.231),凸显 XGBoost 对烧损非线性机制的捕捉能力有限。

在决定系数方面,出炉钢温在条件 3 下的 R^2 值为 0.94,显示出模型对出炉钢温的优良拟合度。单耗的 R^2 值在所有条件下均较高,最高达到了 0.95,表明模型对单耗的预测非常准确。相比之下,烧损的 R^2 值在条件 3 和条件 4 下表现较差,分别为 0.70

和 0.59,说明 XGBoost 对烧损的预测能力较弱,表明其难以捕捉烧损的非线性机制。

综上, XGBoost 在单耗预测中的卓越表现($R^2 \geq 0.94$)印证了其对于静态特征组合的强解析能力;对出炉钢温的预测效果一般,但在条件 3 下决定系数也达到了 0.94;而在烧损预测中的弱势(R^2 最低仅 0.59)则暴露了其对于时序动态特征建模的局限性。对于出炉钢温预测,以各个加热段炉温为输入变量的模型,其决定系数要高于以开度为输入变量的模型,这表明在 XGBoost 模型中,炉温对出炉钢温的影响更为直接。而在烧损的预测中,开度则表现出更明显的直接影响。此外,考虑每个加热段时长后,模型精度略有提升,说明每个加热段的加热时长对模型的预测效果有一定影响。

以上结果可分析得出,单耗作为全局能耗指标,主要受坯料属性(尺寸、入炉温度)和操作总量(总时长、开度均值)等静态参数的综合影响。XGBoost 通过特征分裂和集成学习能高效挖掘这些参数的复杂非线性交互(如入炉温度与总时长的协同效应),故预测精度突出。相反,烧损是典型的时序累积过程,依赖各加热段的动态炉温变化和氧化反应历程。XGBoost 缺乏对时间序列显式建模的能力,导致其难以捕捉烧损演化的内在动力学机制。这种“静态特征强、时序特征弱”的特性分化,是 XGBoost 在三项指标上表现悬殊的根本原因。

3.4 LSTM 模型预测效果

不同输入变量条件下, LSTM 模型对出炉钢温、单耗和烧损的预测结果如表 4 所示。从表 4 可以看到,各个输入条件下模型对出炉钢温、单耗和烧损的 RMSE 都较为接近,说明模型在这三项预测上的一致性较好。在决定系数方面,出炉钢温在所有条件下均高于 0.95,尤其在条件 2 下达到 0.97,显示出极强的预测能力。单耗的 R^2 值变化不大,条件 1 为 0.79,条件 2 和条件 3 分别为 0.86 和 0.84,表明模型在单耗预测方面的稳定性良好。烧损的 R^2 值同样较高,最高为 0.96,进一步证明了模型的优秀拟合度。

表 4 LSTM 模型预测能力评价指标
Table 4 Evaluation metrics for the predictive capability of the LSTM model

No.	RMSE			R^2		
	T_d	E_i	B_o	T_d	E_i	B_o
1	5.7	0.12	0.08	0.95	0.79	0.96
2	4.69	0.10	0.09	0.97	0.86	0.95
3	5.28	0.10	0.08	0.96	0.84	0.95
4	5.50	0.11	0.08	0.96	0.81	0.96

由表可得, LSTM 在出炉钢温($R^2 \geq 0.95$)和烧损($R^2 \geq 0.95$)预测中展现出显著优势, 其门控机制对加热过程时序动态的建模能力是关键驱动; 单耗预测虽稍逊($R^2=0.79 \sim 0.86$), 但整体稳定性仍满足工程需求。

此外, 如图 4 所示(条件 1 的时序对比), LSTM 预测值与实际值高度吻合, 验证了其温度演化轨迹的精准跟踪能力, 可见在温度快速上升段($t=15 \sim 25$ min)模型仍保持高精度, 证明其捕捉非线性动态的能力。

据此可分析得到, 出炉钢温与烧损的预测本质是典型的时序依赖问题: 钢温变化遵循热传导方程, 受历史炉温序列的持续影响; 烧损速率由实时氧化反应动力学主导, 与煤气开度的时序波动强相关。LSTM 的遗忘门-输入门联动机制可自适应调节历史状态的记忆强度(如过滤传感器噪声), 并通过细胞状态传递关键跨时段依赖(如均热段温度对出炉温度的滞后效应)。这种对长短期过程的显式建模能力, 是其在钢温和烧损预测中超越 XGBoost 的结构性优势。尽管单耗预测依赖静态特征组合导致

LSTM 相对弱势, 但其在时序指标上的鲁棒性为混合模型提供了关键支撑。





图 4 LSTM 预测值与实际值对比(条件 1)
Fig. 4 Comparison between LSTM predicted values and actual values (condition1)

3.5 XGBoost 与 LSTM 模型对比

XGBoost 与 LSTM 模型对出炉钢温的预测效果对比如图 5 所示, 从图中可以看到, 在所有的模拟条件下, LSTM 模型的均方根误差 RMSE 均低于 XGBoost 模型, 同时决定系数 R^2 也更高, 并且变化趋势也更加平稳。这表明, 在出炉钢温预测方面, LSTM 模型有更好的精度和稳定性。



(a) RMSE; (b) R^2

图 5 出炉钢温预测结果对比

Fig. 5 Comparison of T_d prediction results


XGBoost 与 LSTM 模型对单耗的预测效果对比如图 6 所示, 从图中可以看到, 与出炉钢温相反, 在所有的模拟条件下, XGBoost 模型拥有更低的均方根误差 RMSE, 同时决定系数 R^2 也更高。这表明, 在单耗预测方面, XGBoost 模型有更好的精度和稳定性。

XGBoost 与 LSTM 模型对烧损的预测效果对比如图 7 所示, 从图中可以看到, 烧损的预测结果与出炉钢温相同, LSTM 模型表现出更高的预测精度和稳定性。

综上所述, XGBoost 模型在单耗预测方面表现尤为突出(决定系数普遍高于 0.90), 而 LSTM 模型则在出炉钢温和烧损预测上展现出更高的精度和稳定性(决定系数普遍超过 0.95)。这种性能差异源于模型的固有特性: LSTM 凭借其门控机制, 能够有效捕捉加热过程中炉温、时长等参数的时序动态特性, 故在具有较强时间依赖性的出炉钢温和烧损预测上表现优异; 而 XGBoost 则擅长学习特征间的复杂非线性组合关系, 对于受入炉温度、总时长、操作参数组合等多因素综合影响的单耗指标预测更具优势。

LSTM 在出炉钢温和烧损预测上的优势,深刻反映了加热过程内在的时序动力学特性。钢坯温度变化、氧化烧损的形成均是典型的时间累积过程,高度依赖于历史状态(如各段炉温历程、停留时间)。LSTM 的门控机制(遗忘门、输入门、输出门)使其能够有效捕捉这种长短期依赖关系,动态调整记忆单元状态,从而精准建模温度传导和氧化反应的动态过程。反观单耗,虽然也受过程时间影响,但其本质更侧重于描述特定加热任务(如加热特定坯料到


目标温度)所消耗的能量总量。这个总量受坯料初始状态(入炉温度)、物理属性(尺寸)以及全局操作参数(总时长、各段平均炉温/开度组合)的综合影响,呈现出强烈的静态特征组合与非线性交互效应。XGBoost 通过其强大的特征分裂、组合优化能力以及集成学习框架,在处理这类复杂的、非时序依赖的输入-输出映射关系时展现出天然优势。这种模型特性与预测目标内在物理机制的匹配性差异,是导致两者在不同指标上性能分化的根本原因。



(a) RMSE; (b) R^2

图6 单耗预测结果对比

Fig. 6 Comparison of E_1 prediction results



(a) RMSE; (b) R^2

图7 烧损预测结果对比

Fig. 7 Comparison of B_0 prediction results

因此,在后续的加热炉工艺优化研究中,将考虑结合两种模型的优势进行联合建模,分别对出炉钢温、单耗和烧损进行预测。

4 结论

针对板坯加热炉的出炉钢温、单耗和烧损,使

用国内某钢铁厂现场采集的 8 297 组数据建立了四组不同输入变量的 XGBoost 和 LSTM 模型,并进行了比较分析,得到以下结论:

1) 在出炉钢温和烧损的预测方面, LSTM 模型表现出很高的预测精度和稳定性,模型的决定系数 (R^2) 达到 0.95 以上,并且变化趋势也十分的稳定。

2) 在单耗预测方面, XGBoost 模型有更好的预测精度和稳定性, 模型的决定系数 (R^2) 达到 0.94 以上, 并且变化趋势十分稳定。

3) 通过对比两种模型的预测结果, 发现 LSTM 模型在出炉钢温和烧损的预测能力方面更为可靠, 而 XGBoost 则在单耗预测中展现出更高的精度, 但在烧损预测上表现相对较差。

4) 预测效果的差异主要归因于模型固有特性与目标变量物理本质的匹配度: LSTM 凭借其门控

机制和时序记忆能力, 擅长捕捉出炉钢温(热传导过程)和烧损(氧化反应累积过程)中蕴含的动态时序依赖关系; 而 XGBoost 则通过特征组合优化和集成学习, 更有效地解析了单耗(能量消耗总量)所涉及的复杂静态特征交互与非时序非线性关系。

5) 未来的加热炉工艺优化研究可考虑融合两种模型的优势构建联合模型(如 LSTM-XGBoost), 以进一步提升出炉钢温、单耗和烧损的预测精度, 为更有效的生产管控和资源高效利用提供支撑。

参考文献

- [1] LU B, TANG K, CHEN D, *et al.* A novel approach for lean energy operation based on energy apportionment model in reheating furnace[J]. *Energy*, 2019, 182: 1239-1249.
- [2] LIAO Y X, SHE J H, WU M, *et al.* Integrated hybrid-PSO and fuzzy-NN decoupling control for temperature of reheating furnace[J]. *IEEE transactions on industrial electronics*, 2009, 56(7): 2704-2714.
- [3] WEI E Z, PENG Y H. Status and prospect of control technology for slab reheating furnace(A)[J]. *Metallurgical Industry Automation*, 2010, 34(3): 5-9.
(卫恩泽, 彭燕华. 板坯加热炉控制技术现状及发展(上)[J]. *冶金自动化*, 2010, 34(3): 5-9.)
- [4] ZHANG Q G, LI S Y, CHEN L Q. "Black Box" test and application of mathematical model for walking beam slab reheating furnace[J]. *Industrial Furnace*, 2012, 34(3): 5-7.
(张强国, 李仕一, 陈亮全. 步进梁式板坯加热炉数学模型的“黑匣子”测试与应用[J]. *工业炉*, 2012, 34(3): 5-7.)
- [5] YANG X J, DUAN Y, HE S F, *et al.* Prediction of slab unit energy consumption in steel rolling heating furnace based on all influencing factors[J]. *Energy for Metallurgical Industry*, 2024, 43(3): 14-18.
(杨筱静, 段毅, 何胜方, 等. 基于全影响因素的轧钢加热炉板坯单耗预测[J]. *冶金能源*, 2024, 43(3): 14-18.)
- [6] ZHAI N, ZHOU X. Temperature prediction of heating furnace based on deep transfer learning[J]. *Sensors*, 2020, 20(17): 4676.
- [7] CHEN Y W, CHAI T Y. Modelling and prediction for steel billet temperature of heating furnace[J]. *International Journal of Advanced Mechatronic Systems*, 2010, 2(5-6): 342-349.
- [8] ZHOU J X, ZHENG R C, HOU H Y, *et al.* Improved pelican algorithm for optimizing LSTM based temperature prediction of reheating furnace billets[J]. *Foreign Electronic Measurement Technology*, 2023, 42(5): 174-179.
(周建新, 郑日成, 侯宏瑶, 等. 改进鹈鹕算法优化 LSTM 的加热炉钢坯温度预测[J]. *国外电子测量技术*, 2023, 42(5): 174-179.)
- [9] SUN J, YU M H. Temperature neural network prediction model of billet in rolling heating furnace[J]. *Foreign Electronic Measurement Technology*, 2021, 40(9): 5.
(孙洁, 于孟晗. 轧钢加热炉钢坯温度神经网络预测模型[J]. *国外电子测量技术*, 2021, 40(9): 5.)
- [10] YU H, GONG J, WANG G, *et al.* A hybrid model for billet tapping temperature prediction and optimization in reheating furnace[J]. *IEEE Transactions on Industrial Informatics*, 2022, 19(8): 8703-8712.
- [11] SHI Q, TANG J, CHU M S. Key issues and progress of industrial big data-based intelligent blast furnace ironmaking technology[J]. *International Journal of Minerals, Metallurgy and Materials*, 2023, 30(9): 1651-1666.
- [12] RESHEF D N, RESHEF Y A, FINUCANE H K, *et al.* Detecting novel associations in large data sets[J]. *Science*, 2011, 334(6062): 1518-1524.
- [13] RAMRAJ S, UZIR N, SUNIL R, *et al.* Experimenting XGBoost algorithm for prediction and classification of different datasets[J]. *International Journal of Control Theory and Applications*, 2016, 9(40): 651-662.
- [14] XIE C L. Wind-induced acceleration prediction of cable-stayed bridges based on LST model[D]. Guang Zhou: Guangzhou University, 2023.
(谢诚朗. 基于 LSTM 模型的斜拉桥风致加速度预测[D]. 广州: 广州大学, 2023.)