基于 LSTM-DNN 混合模型的烧结矿 FeO 含量预测

陈振民[1]，李来胜[1]，聂险峰[1]，谭康康[2]，毕 兢[2]，余正伟[2]
（1. 湖南华菱涟源钢铁集团有限公司，湖南 娄底 417000；2. 安徽工业大学 冶金工程学院，安徽 马鞍山 243002）

摘要：为实现烧结矿 FeO 含量的高精度、前瞻性预测，支撑高炉稳定顺行、炉料质量优化与能效提升，本文提出一种融合时序信息与非时序信息的深度学习预测方法。基于某钢厂烧结机实际生产数据，采用孤立森林算法对异常样本进行识别与清洗，并结合归一化方法消除不同工艺参数间的量纲差异；在此基础上，利用 Spearman 相关性分析与最大互信息系数（MIC）相结合的特征筛选方法，从多项生产变量中提取出 9 项与 FeO 含量密切相关的关键工艺参数，构建预测数据集；进一步建立融合长短期记忆网络（LSTM）与深度神经网络（DNN）的 LSTM-DNN 混合模型，以充分挖掘烧结过程中的时序依赖特征及高维非线性映射关系。结果表明：与单一 LSTM 模型和 DNN 模型相比，所建立的 LSTM-DNN 混合模型的预测性能更优，在 ±0.5 误差范围内的预测准确率达到 93.33%，具有较高的稳定性和泛化能力。该模型已成功集成至烧结机尾断面热成像监测系统，实现图像信息与工艺参数联动的 FeO 含量在线预测与预警，可为抑制 FeO 含量波动、提升烧结矿质量稳定性和促进烧结过程智能化提供有效技术支撑。

关键词：烧结矿；FeO 含量；深度学习；LSTM-DNN 混合模型；在线预测
中图分类号：TF046.4；TF325.1 **文献标志码**：A **文章编号**：1000－8764（2026）02－0045－09
doi：10.13403/j.sjqt.2026.02.028

Prediction of FeO content in sinter based on LSTM-DNN hybrid model

CHEN Zhenmin[1], LI Laisheng[1], NIE Xianfeng[1], TAN Kangkang[2], BI Jing[2], YU Zhengwei[2]
(1. Hunan Valin Lianyuan Iron and Steel Group Co., Ltd., Loudi 417000, Hunan, China;
2. School of Metallurgical Engineering, Anhui University of Technology, Ma'anshan 243002, Anhui, China)

Abstract: In order to achieve high-precision and forward-looking prediction of FeO content in sinter, and support the stable forward operation of blast furnace, charge quality optimization and energy efficiency improvement, a deep learning prediction method that combines temporal and non-temporal information is proposed. Based on the actual production data of a steel mill's sintering machine, the isolated forest algorithm is used to identify and clean the abnormal samples, and the dimensional differences between different process parameters are eliminated by the normalization method. On this basis, the feature screening method combined with Spearman correlation analysis and maximum information coefficient (MIC) is used to extract 9 key process parameters closely related to FeO content from multiple production variables, and a prediction dataset is constructed. The LSTM-DNN hybrid model integrating long short-term memory network (LSTM) and deep neural network (DNN) is further established to fully explore the time-series-dependent features and high-dimensional nonlinear mapping relationship in the sintering process. The results show that compared with the single LSTM model and DNN model, the proposed LSTM-DNN hybrid model has better prediction performance, with a prediction accuracy of 93.33% within the ±0.5 error range, and has high stability and generalization ability. The model has been successfully integrated into the thermal imaging monitoring system of the tail section of the sintering machine, which realizes the online prediction

收稿日期：2025－12－03；**修回日期**：2026－02－04
基金项目：国家自然科学基金面上项目（52374315）
作者简介：陈振民（1983—），男，高级工程师，从事冶金设备技术方面的研究与应用。
通信作者：聂险峰（1978—），男，高级工程师，从事冶金设备技术方面的研究与应用。

and early warning of FeO content linked with image information and process parameters, and can provide effective technical support for inhibiting the fluctuation of FeO content, improving the quality stability of sinter, and promoting the intelligence of the sintering process.

Key words: sinter; FeO content; deep learning; LSTM-DNN hybrid model; online prediction

烧结矿是高炉炼铁的主要原料，其质量直接影响高炉冶炼过程及技术经济指标。在烧结矿质量指标中，FeO 含量是关键参数之一，影响烧结过程和烧结矿质量[1]。FeO 含量与烧结矿的还原性、强度密切相关，决定高炉内的还原反应和粉化行为。适宜的 FeO 含量可保证良好的强度和还原性，降低焦比和固体燃料消耗；而 FeO 含量过高或过低均会影响炉况、烧结矿强度及透气性。因此，控制 FeO 含量在合理范围并保持其稳定性对烧结生产的高效和稳定运行至关重要[2-3]。

在烧结生产过程中，影响 FeO 含量的因素包括混合料水分、料层透气性、风箱温度、风箱压力和烟道温度等。混合料水分影响制粒效果和料层结构，该值过大或过小均会恶化透气性，进而影响 FeO 含量。烧结布料不均匀会导致料层透气性差异，影响烧结状态并引起 FeO 含量波动。烧结终点位置也是关键因素，终点滞后会导致烧结强度不足，使 FeO 含量波动；终点提前则可能提高强度，但降低生产率。因此，准确预测和控制 FeO 含量一直是烧结生产中的研究重点[4-6]。国内外针对烧结矿 FeO 含量的检测与预测开展了大量研究，提出了多种方法。人工观察法依赖经验判断，准确性较差；化学分析法虽准确，但结果显示时间滞后，无法满足实时控制需求；废气检测法受现场漏风和气体复杂性影响，精度有限；磁导率法受温度和设备稳定性影响，结果波动较大[7]。近年来，随着红外热成像和图像识别技术的发展，研究者尝试将图像分析与专家系统结合，提高 FeO 含量的在线监测精度。国内一些钢厂通过安装热像仪和图像分析系统，结合工艺参数实时监测断面温度并推断 FeO 含量，取得了一定效果。但此类方法多侧重图像特征，未充分利用工艺参数，且预测稳定性仍需提高。国外如澳大利亚、意大利、日本等钢厂也采用磁导仪、废气分析和图像处理等方法辅助控制 FeO 含量，但普遍存在检测时间滞后或稳定性差的问题[8-10]。国内如攀钢、鞍钢、东北大学、中南大学等单位开展了基于神经网络、支持向量机和热力学模型等方法的研究和应用[11-13]。尽管研究结果取得了一定成效，但这些方法普遍存在预测精度有限、泛化性差、工艺变量考虑不足等问题，难以长期稳定应用于生产现场。

随着深度学习算法的快速发展，其在工业过程建模中展现出强大的特征提取和非线性建模能力。对于复杂且耦合性强的烧结过程，深度学习算法能够从多源数据中挖掘潜在关联，突破传统方法在预测精度、实时性和泛化能力等方面的局限。近年来，深度神经网络已成功应用于烧结温度预测、球团质量评价和喷煤比优化等领域，但针对 FeO 含量的研究较少，尤其在工艺参数与生产数据融合建模方面仍需进一步探索[14-16]。本文通过构建基于深度学习算法的 FeO 含量预测模型，通过采集关键工艺参数并构建多层神经网络，实现精准预测，为烧结过程的智能化和稳定化提供技术支持。

1 数据采集与处理

1.1 数据采集

基于某钢铁企业 1#烧结机的实际生产过程，本文构建了用于分析的数据集。该数据集覆盖 2025 年 4 月 14 日 23:00 至 7 月 25 日 11:00 期间的连续生产过程，以每 4 h 一次的频率采集，总计包含 610 组时序样本。1#烧结机的烧结原料性质在此期间保持稳定，为后续模型构建提供数据一致性支持。结合一线工程师经验，最终确定 51 项关键工艺参数用于表征烧结过程，如表 1 所示。其中，烧结矿 FeO 含量为输出变量，其他 50 项参数作为输入变量，涵盖风箱工况、配料与混合条件、返矿比、料层特征、点火参数及烧结机运行状态等，全面反映热工制度与物料特性的耦合关系。

表 1　51 项表征烧结过程的关键工艺参数

Table 1　51 key process parameters used to characterize the sintering process

参数编号	工艺参数名称	参数编号	工艺参数名称	参数编号	工艺参数名称
X_1 ~ X_{10}	1# ~ 10#风箱压力	X_{36}、X_{37}	混合料流量(无返矿)、温度	X_{44}、X_{45}	点火炉热空气流量、压力
X_{11} ~ X_{20}	1# ~ 10#风箱温度	X_{38}	烧结终点温度	X_{46}、X_{47}	点火炉煤气流量、压力
X_{21} ~ X_{30}	1# ~ 10#配料流量	X_{39}	烧结机混合煤气流量	X_{48}	点火炉炉膛压力
X_{31}、X_{32}	一、二混加水流量	X_{40}	烧结机炉膛负压	X_{49}	出点火炉前料面温度
X_{33}、X_{34}	一、二混后水分质量分数	X_{41}	点火炉平均温度	X_{50}	烧结台车料层厚度
X_{35}	返矿流量	X_{42}、X_{43}	烧结机、环冷机速度	X_{51}	烧结矿 FeO 含量

1.2　数据处理

1.2.1　数据异常值处理

由于设备和环境等因素的影响，烧结现场采集的数据常存在异常值，需要进行数据清洗与剔除。常见的异常值检测方法有 3σ 准则和箱型图，但由于其对复杂工况数据适用性差，本文采用孤立森林算法(isolation forest)进行异常检测。孤立森林算法是一种无监督的机器学习方法，能够高效检测异常值，无需预设模型或标注异常数据，适用于烧结数据的异常值处理，其原理结构如图 1 所示[17]。

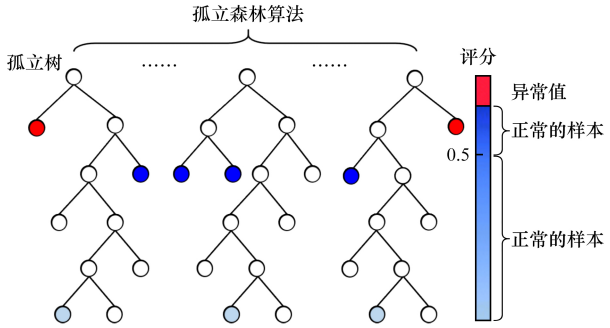


图 1　孤立森林结构

Fig. 1　Schematic diagram of isolation forest

孤立森林算法通过随机划分数据空间并构建二叉树。以样本从根结点到叶子结点的路径长度反映其离散程度，路径越短，样本越可能被判定为异常。多棵随机树形成的孤立森林可综合评估样本的异常程度，并计算关键参数的异常分数。具体计算过程如式(1)~(3)所示。

$$s(x,n) = 2^{-\frac{E[h(x)]}{c(n)}} \tag{1}$$

$$c(n) = \begin{cases} 2H(n-1) - \dfrac{2(n-1)}{n}, & n > 2 \\ 1, & n = 2 \\ 0, & n < 2 \end{cases} \tag{2}$$

$$H(i) = \ln(i) + \gamma \tag{3}$$

式中：$E[h(x)]$表示数据在森林中路径长度的均值；$s(x,n)$为节点 x 的异常分数；$c(n)$为在二叉搜索树中搜索失败的平均路径长度；$H(i)$为调和级数；γ 为欧拉常数，取 0.577 215 664 9。

算法通过设定的阈值来判断异常数据，$s(x,n)$的取值越大越有可能为异常点。异常值分析：对烧结过程中关键参数进行综合分析，并结合烧结机理，判断异常值的原因和合理性。异常值剔除与保留：对于因仪器故障引起的异常值予以剔除；对于烧结过程中的异常工况导致的异常值则予以保留，以反映工况特征。

1.2.2　归一化处理

在烧结生产过程中，各关键工艺参数具有不同的物理意义和量纲，可能影响烧结矿 FeO 含量的预测结果。如 FeO 质量分数范围为[1,10]，而点火炉温度范围为[800,1 200]，直接输入原始数据会导致模型权重失衡。为此，需要对关键工艺参数进行归一化处理，确保在统一量纲下进行比较和建模。

对于数据集 $X(i) = (x_1, x_2, \cdots, x_n)$，此方法采用最大值与最小值对数据进行线性变换，使得结果映射到[0,1]范围。计算方法如式(4)所示。

$$y_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}, i = 1、2、\cdots、n \tag{4}$$

式中：$\max(x)$、$\min(x)$分别为数据集中的最大值与最小值。

2　特征参数选取

特征参数选取旨在减少输入变量数量，提高模型泛化能力并避免过拟合。本文通过斯皮尔曼(Spearman)相关性分析和最大互信息系数(MIC)

分析评估工艺参数与 FeO 含量的相关性。Spearman 分析反映变量间的单调性，MIC 分析捕捉线性与非线性依赖关系。结合两种方法结果，筛选出与 FeO 含量强相关的关键工艺参数，确保输入变量的代表性与合理性。

2.1 Spearman 相关性

Spearman 相关性分析通过 Spearman 秩相关系数判别相关性强度[18]。其原理是通过求解原始数据的排序位置，对烧结生产过程中 51 个关键工艺参数进行非线性数据分析，将关键性参数(X_1,X_2,X_3,…,X_{51})分别按数值的大小进行排序并建立顺序表，顺序表的位置被称为秩次。51 个关键工艺参数的 Spearman 相关性分析结果如图 2 所示。

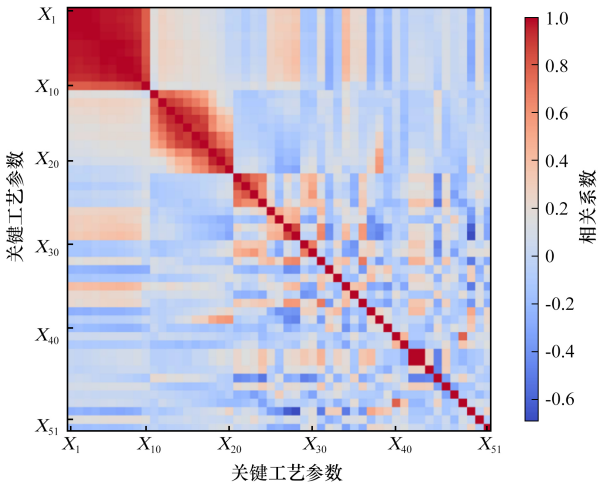


图 2 51 个关键工艺参数的斯皮尔曼相关性分析

Fig. 2 Spearman correlation analysis of 51 key process parameters

50 个关键工艺参数的 Spearman 相关性分析结果对比如表 2 所示。Spearman 相关性系数的取值范围为[-1,1],该值的绝对值越大,表示两者之间的相关性越高。本文选取相关性系数绝对值大于 0.2 的关键工艺参数作为烧结矿 FeO 含量预测模型的初步输入变量。由表 2 可知，选取的 10 个输入变量的组合为(X_{49},X_{37},X_{38},X_{26},X_{36},X_{25},X_{31},X_{27},X_{28},X_{34})。

2.2 最大互信息系数

最大互信息系数(MIC)分析是一种衡量参数间非线性关系强弱的有效方法。基于机器学习的特征选择理念，MIC 值越大，表示参数间的关联性越强[19]。本文对影响烧结过程的 51 个关键工艺参数数据集进行 MIC 分析，重点分析烧结矿 FeO 含量与其他关键性参数之间的 MIC 值。筛选出 MIC 值大于 0.2 的 20 个关键工艺参数的组合为(X_{21},X_{25},X_{22},X_{23},X_{24},X_{26},X_{29},X_{28},X_{30},X_{34},X_{27},X_{36},X_{37},X_1,X_5,X_7,X_{31},X_{49},X_2,X_6)，如图 3 所示，进一步揭示其关联性特征。

基于上述 Spearman 相关性、最大互信息系数分析的特征参数选取方法的结果，最终选择 9 个关键工艺参数的组合(X_{49},X_{37},X_{26},X_{36},X_{25},X_{31},X_{27},X_{28},X_{34})，将其作为数据驱动预测模型输入参数。相关输入参数如表 3 所示。

3 烧结矿 FeO 含量预测模型构建

在烧结生产过程中，FeO 含量的控制是确保高炉冶炼稳定性与经济效益的关键因素。为准确预测烧结矿 FeO 含量，本文提出一种基于深度学习的混合模型，通过融合多种深度学习算法，旨在提升预测的精度与稳定性。该混合模型能够充分利用烧结生产过程中复杂的时序性与非时序性数据，为智能化生产控制提供技术支持。

表 2 50 个关键工艺参数的斯皮尔曼相关性分析结果对比

Table 2 The comparison of Spearman correlation analysis results of 50 key process parameters

X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}
-0.19	-0.17	-0.19	-0.16	-0.17	-0.19	-0.18	-0.16	-0.13	-0.06	-0.01	-0.07	-0.04
X_{14}	X_{15}	X_{16}	X_{17}	X_{18}	X_{19}	X_{20}	X_{21}	X_{22}	X_{23}	X_{24}	X_{25}	X_{26}
-0.04	-0.02	0.01	0.02	0.09	0.11	0.16	0	0.07	0.04	-0.02	-0.28*	-0.24*
X_{27}	X_{28}	X_{29}	X_{30}	X_{31}	X_{32}	X_{33}	X_{34}	X_{35}	X_{36}	X_{37}	X_{38}	X_{39}
-0.30*	-0.31*	0.12	0.19	-0.29*	0.16	0.08	-0.33*	-0.09	-0.25*	0.25*	0.23*	0.19
X_{40}	X_{41}	X_{42}	X_{43}	X_{44}	X_{45}	X_{46}	X_{47}	X_{48}	X_{49}	X_{50}	—	—
0.10	0.15	0.05	-0.05	-0.08	-0.10	0.02	-0.07	0.06	0.27*	-0.04	—	—

注:上标 * 为符合要求的输入变量。

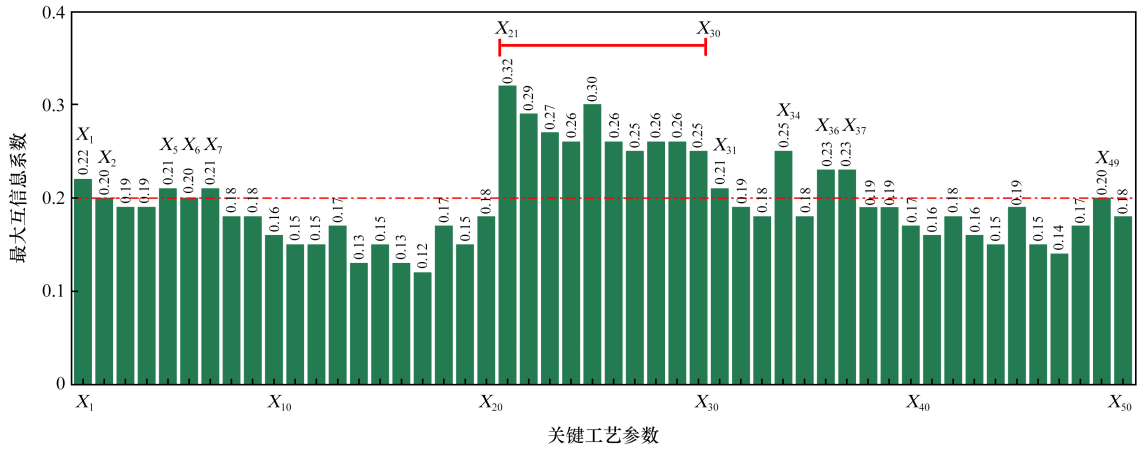


图 3　50 个关键工艺参数的最大互信息系数(MIC)

Fig. 3　Maximal information coefficient(MIC) of 50 key process parameters

表 3　预测模型输入参数

Table 3　Input parameters for the prediction model

X_{25} ~ X_{28}	X_{31}	X_{34}	X_{36}	X_{37}	X_{49}
5# ~ 8# 配料流量	一混加水流量	二混后水分质量分数	混合料流量（无返矿）	混合料温度	出点火炉前料面温度

3.1　深度学习模型的选择

3.1.1　长短时记忆网络(LSTM)深度学习算法

在烧结过程中，关键工艺参数随时间变化且具有复杂的时序关联性。传统建模方法往往过度依赖数据，难以有效捕捉这些特征。为了提高 FeO 含量预测精度，采用长短时记忆网络(LSTM)。LSTM 是一种专门用于处理时序数据的深度学习模型，能够克服传统递归神经网络(RNN)中的梯度消失与爆炸问题，有效捕捉烧结过程中的长期时序关系，广泛应用于时序数据预测与分析[20-22]。LSTM 专为捕捉时序数据中的长期依赖关系而设计，能够捕捉烧结过程中的复杂时序动态。它由多个 LSTM 单元组成，每个单元通过独特的门控机制控制信息流。

3.1.2　深度神经网络(DNN)深度学习算法

烧结过程中的关键工艺参数通常存在复杂的非线性关系，传统回归分析和线性模型难以捕捉这些关系。虽然 LSTM 在时序数据处理上表现优秀，但许多烧结参数并非简单的时间序列，且其交互作用常呈现复杂的非线性。而 DNN 作为一种深度学习模型，能够有效处理这些高维非时序性特征，并通过深层结构提取更高层次的抽象特征[23-25]。DNN 是一种多层感知机(MLP)模型，由多个全连接层组成，每层神经元通过加权连接传递信息。每个神经元根据输入信号和权重计算激活值，并通过激活函数输出结果。DNN 结构如图 4 所示。

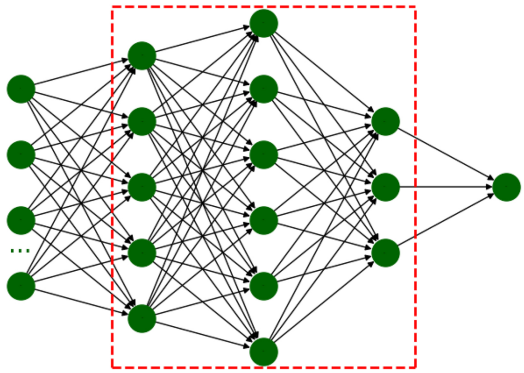


图 4　深度神经网络(DNN)结构

Fig. 4　Structure of deep neural network(DNN)

3.2　烧结矿 FeO 含量预测混合模型(LSTM-DNN)的构建

在烧结矿 FeO 含量预测中，单一深度学习算法虽有效捕捉某些特征，但存在局限性。LSTM 擅长处理时序数据，但对静态数据处理较弱；DNN 能提取非线性特征，但在长时间依赖的时序数据上表现不足。为克服两者的缺点，本文提出 LSTM-DNN 混合模型，结合 LSTM 处理时序数据和 DNN 捕捉非线性关系的优势，提升 FeO 含量预测的准确性与稳定性。模型包括 LSTM 层处理时序参数，DNN 层处理静态参数。模型的具体结构设计如下。

（1）LSTM 部分的输出：将时序性工艺参数输入 LSTM 网络，通过多个 LSTM 单元学习长期依赖关系。LSTM 的输出经过全连接层（FC 层）进行特征提取，生成时序特征向量。对于 LSTM 网络中的每个时间步，假设输入为$\boldsymbol{x}_t$，上一时刻的隐藏状态为$\boldsymbol{h}_{t-1}$，上一时刻的记忆状态为$\boldsymbol{c}_{t-1}$，则 LSTM 单元的计算过程如下。

遗忘门：

$$\boldsymbol{f}_t = \sigma(\boldsymbol{W}_f[\boldsymbol{h}_{t-1},\boldsymbol{x}_t] + \boldsymbol{b}_f) \tag{5}$$

输入门：

$$\boldsymbol{i}_t = \sigma(\boldsymbol{W}_i[\boldsymbol{h}_{t-1},\boldsymbol{x}_t] + \boldsymbol{b}_i) \tag{6}$$

候选记忆单元：

$$\tilde{\boldsymbol{c}}_t = \tanh(\boldsymbol{W}_c[\boldsymbol{h}_{t-1},\boldsymbol{x}_t] + \boldsymbol{b}_c) \tag{7}$$

记忆单元更新：

$$\boldsymbol{c}_t = \boldsymbol{f}_t \times \boldsymbol{c}_{t-1} + \boldsymbol{i}_t \times \tilde{\boldsymbol{c}}_t \tag{8}$$

输出门：

$$\boldsymbol{o}_t = \sigma(\boldsymbol{W}_o[\boldsymbol{h}_{t-1},\boldsymbol{x}_t] + \boldsymbol{b}_o) \tag{9}$$

隐藏状态：

$$\boldsymbol{h}_t = \boldsymbol{o}_t \times \tanh(\boldsymbol{c}_t) \tag{10}$$

式中：$\boldsymbol{f}_t$为遗忘门的输出；σ 为 Sigmoid 激活函数；$\boldsymbol{W}_f$和$\boldsymbol{b}_f$分别为遗忘门的权重矩阵和偏置项；$\boldsymbol{i}_t$为输入门的输出；$\boldsymbol{W}_i$和$\boldsymbol{b}_i$分别为输入门的权重矩阵和偏置项；$\boldsymbol{b}_i$为候选记忆单元；$\boldsymbol{o}_t$为输出门的输出；$\boldsymbol{W}_o$和$\boldsymbol{b}_o$分别为输出门的权重矩阵和偏置项。

LSTM 的输出$\boldsymbol{h}_t$在每个时间步都被传递到全连接层，最终通过多个 LSTM 单元获得时序特征向量$\boldsymbol{h}_{\text{LSTM}}$。

（2）DNN 部分的输出：DNN 网络由多个全连接层（即感知机）组成。对于每一层的输出计算公式：

$$\boldsymbol{h}^{(l)} = f(\boldsymbol{W}^{(l)}\boldsymbol{h}^{(l-1)} + \boldsymbol{b}^{(l)}) \tag{11}$$

式中：$\boldsymbol{h}^{(l)}$为第 l 层的输出；$\boldsymbol{W}^{(l)}$为权重矩阵；$\boldsymbol{b}^{(l)}$为偏置项；$\boldsymbol{f}(\ )$为激活函数，通常为 ReLU 或 Sigmoid 函数。

DNN 部分的输出为静态工艺参数的高层次特征向量$\boldsymbol{h}_{\text{DNN}}$。

（3）特征融合层的输出：LSTM 和 DNN 部分的输出通过特征融合层进行融合。假设两部分输出的特征向量分别为$\boldsymbol{h}_{\text{LSTM}}$和$\boldsymbol{h}_{\text{DNN}}$，则融合后的特征向量：

$$\boldsymbol{h}_{\text{fusion}} = \text{concat}(\boldsymbol{h}_{\text{LSTM}},\boldsymbol{h}_{\text{DNN}}) \tag{12}$$

式中：concat( )表示拼接操作。融合后的特征向量$\boldsymbol{h}_{\text{fusion}}$将作为最终预测的输入。

（4）输出层：通过全连接层进行 FeO 含量的预测。输出层的计算公式：

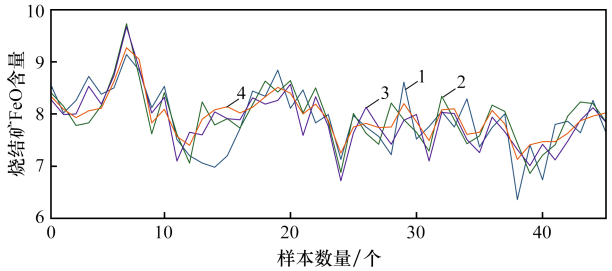
$$\hat{\boldsymbol{y}} = \boldsymbol{W}_{\text{out}}\boldsymbol{h}_{\text{fusion}} + \boldsymbol{b}_{\text{out}} \tag{13}$$

式中：$\hat{\boldsymbol{y}}$为预测的 FeO 含量；$\boldsymbol{W}_{\text{out}}$和$\boldsymbol{b}_{\text{out}}$分别为输出层的权重矩阵和偏置项。

LSTM-DNN 混合模型结合了 LSTM 和 DNN 的优势，充分考虑了烧结过程中的时序数据和静态数据特征。LSTM 有效捕捉了长期依赖关系，而 DNN 则通过深层结构提取复杂的非线性特征。通过这种融合方法，模型能够更全面地分析影响 FeO 含量的因素，从而提高预测的精度和稳定性。

4 烧结矿 FeO 含量预测结果分析与应用

对特征参数选取的烧结矿 FeO 含量数据集按时间序列排序，应用 LSTM-DNN 混合模型进行预测，构建烧结矿 FeO 含量预测模型。选取 LSTM 模型和 DNN 模型进行仿真预测，并通过评价指标对比三种模型的预测结果。三种模型的预测结果如图 5 所示。由图 5 可知，LSTM-DNN 混合模型的预测结果与实际值高度吻合，预测误差为 ±0.5，命中率达到 93.33%，表明该模型具有较好的工程适用性和推广价值。因此，本文选用 LSTM-DNN 混合模型对烧结矿 FeO 含量进行在线预测与前瞻性评估，以加强烧结矿质量的稳定控制。



预测值：1—LSTM；2—DNN；3—LSTM-DNN。4—实际值。

图 5 三种模型的预测结果与实际值对比

Fig. 5 Comparison of the prediction results of the three models with the actual values

为对比评估 3 种模型的综合性能，选取均方根误差（σ_{RMSE}）、平均绝对误差（σ_{MAE}）、平均绝对百分比误差（σ_{MAPE}）、模型准确率（σ_{Accuracy}，误差

为 ±0.1）4 个常用评价指标对比上述 3 种预测模型的性能，对预测结果进行直观评价。4 个指标的计算方法如式(14)～(17)所示[26]。

$$\sigma_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i-y_i)^2} \tag{14}$$

$$\sigma_{\mathrm{MAE}}=\frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i-y_i| \tag{15}$$

$$\sigma_{\mathrm{MAPE}}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i-y_i}{y_i}\right| \tag{16}$$

$$\sigma_{\mathrm{Accuracy}}=\frac{\dot{n}}{n} \tag{17}$$

式中：n 为样本总量；$\hat{y}_i$ 为预测值；y_i 为真实值；$\dot{n}$ 表示在误差允许范围内预测值的数量。

根据烧结矿 FeO 含量仿真预测结果计算上述 3 种预测模型评价结果，如表 4 所示。由表 4 可知：LSTM-DNN 混合模型对烧结矿 FeO 含量预测整体性能最好，预测精度最高。该模型的均方根误差、平均绝对误差及平均绝对百分比误差最低，分别为 0.254、0.188 和 2.36%，在误差为 ±0.5 时，模型准确率最高，达到 93.33%。因此，LSTM-DNN 混合模型对烧结矿 FeO 含量预测的综合性能优于其他两种模型。

为验证模型在实际生产中的可用性，开发了烧结机机尾断面热成像监测系统，并集成基于 LSTM-DNN 模型的 FeO 含量在线预测功能。系统

表 4　模型综合性能对比

Table 4　Comprehensive performance comparison of models

模型名称	均方根误差	平均绝对误差	平均绝对百分比误差/%	模型准确率/%
LSTM	0.458	0.342	4.32	82.22
DNN	0.302	0.226	2.89	86.67
LSTM-DNN	0.254	0.188	2.36	93.33

架构：① 前端。基于 JavaScript 与 Element UI 开发，提供高效、友好的工艺界面与可视化展示。② 后端。使用 Spring Boot 构建业务逻辑层，通过注解映射前端请求，DAO 层负责数据管理与模型推理结果持久化。③ 数据库。采用 Navicat 连接本地数据库，支持历史数据归档、特征样本管理与在线预测结果追溯。

系统实现了热成像数据与模型预测结果的联动显示与报警触发，为烧结矿 FeO 含量的预判及烧结过程质量稳定与能效优化提供了支持。系统界面如图 6 所示。

5　结　论

（1）基于烧结生产过程中采集的数据，通过孤立森林清洗与归一化处理，结合 Spearman 与 MIC 相关性筛选，本文构建了影响烧结矿 FeO 含

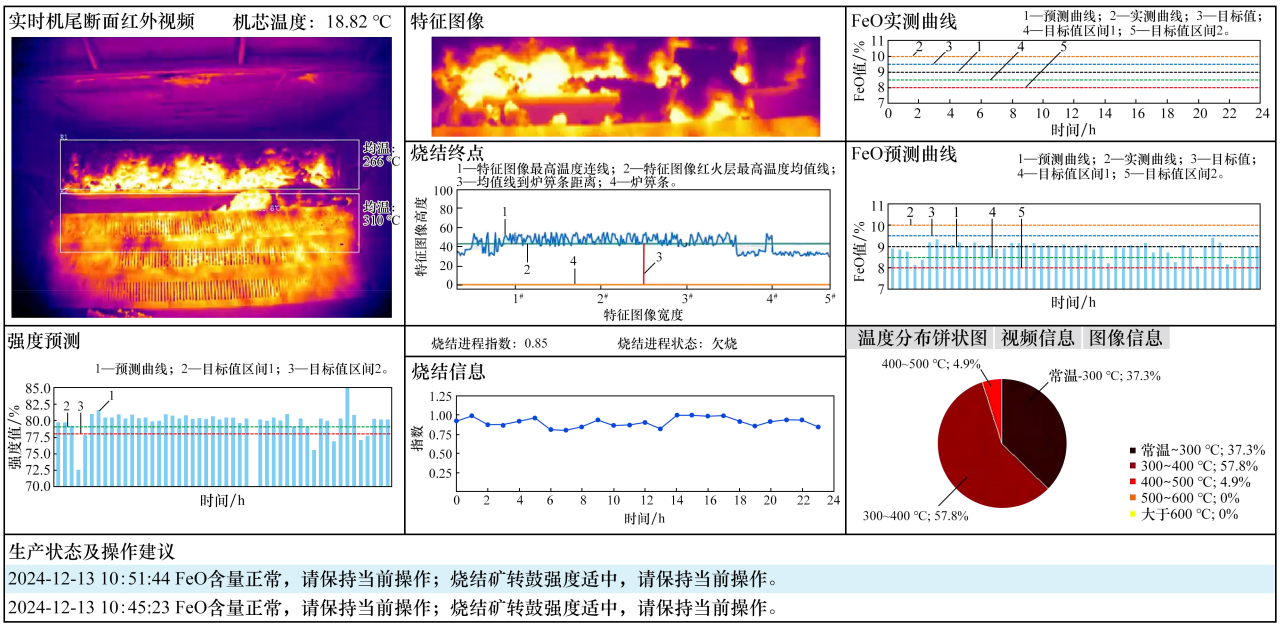


图 6　烧结机尾断面热成像监测系统界面

Fig. 6　Interface diagram of thermal imaging monitoring system for sinter machine tail section

量关键工艺参数的数据集。在此基础上构建的LSTM-DNN混合模型可同时表征烧结过程的时序依赖与非线性关系。

（2）混合模型的整体预测性能优于LSTM与DNN单一模型，在误差为±0.5时，模型准确率最高，达到93.33%，且均方根误差为0.254、平均绝对误差为0.188、平均绝对百分比误差为2.36%，显著优于对比模型（以平均绝对百分比误差为例，LSTM的值为82.22%，DNN的值为86.67%），体现出更高的精度与泛化能力。

（3）将该模型集成至烧结机尾断面热成像监测后，系统实现了FeO含量的在线预测与FeO工况预警，预测结果与实测值高度一致。系统可联动展示图像信息与工艺参数，为生产提供即时决策支持，提升烧结矿质量的稳定性，推动烧结过程的智能化、绿色化与稳定化。

参考文献：

[1] 唐佳润,刘月明,张福明,等. 烧结矿FeO含量预测技术的探讨[J]. 烧结球团,2025,50(1):21－30;37.
TANG Jiarun, LIU Yueming, ZHANG Fuming, et al. Discussion on prediction technology of FeO content in sinter[J]. Sintering and Pelletizing,2025,50(1):21－30,37.

[2] LI Z Z, LI Y F, DUAN Y S, et al. Study on the basic characteristics of iron ore powder with different particle sizes[J]. Minerals,2022,12(8):973.

[3] 黄鼎尧,黄晓贤,向家发,等. 基于TCN-DenseNet的烧结矿FeO含量预测[J]. 河北冶金,2024(10):14－19;49.
HUANG Dingyao,HUANG Xiaoxian,XIANG Jiafa,et al. Prediction of FeO content in sinter based on TCN-DenseNet[J]. Hebei Metallurgy,2024(10):14－19;49.

[4] 任玉辉,曾小信,李旭东. 基于机器视觉的烧结矿FeO含量在线感知[J]. 烧结球团,2024,49(3):53－59;88.
REN Yuhui,ZENG Xiaoxin,LI Xudong. Online perception on FeO content in sinter based on machine vision[J]. Sintering and Pelletizing,2024,49(3):53－59;88.

[5] LI X M, WANG B R, YU Z H, et al. Identification of working conditions and prediction of FeO content in sintering process of iron ore fines[J]. Journal of Iron and Steel Research International,2024,31(9):2090－2100.

[6] 张学锋,闻亦昕,熊大林,等. 面向智能烧结的机尾断面烧结矿FeO预测研究[J]. 钢铁研究学报,2024,36(5):580－588.
ZHANG Xuefeng, WEN Yixin, XIONG Dalin, et al. Research on FeO prediction of sintered ore in machine tail section for intelligent sintering[J]. Journal of Iron and Steel Research,2024,36(5):580－588.

[7] HU J, WU M, CHEN L F, et al. Real-time dynamic prediction model of carbon efficiency with working condition identification in sintering process[J]. Journal of Process Control,2022,111:97－105.

[8] 李一帆,李锦祥,杨锦堂,等. 基于BO-RF的烧结矿化学成分预测模型研究[J]. 烧结球团,2023,48(6):109－115;138.
LI Yifan,LI Jinxiang,YANG Jintang,et al. Research on chemical composition prediction model of sinter based on BO-RF[J]. Sintering and Pelletizing,2023,48(6):109－115;138.

[9] XI J H,XING X D,ZHENG Z Y,et al. Effect of feature selection on the prediction model of FeO content in sinter[J]. JOM,2023,75(12):5930－5939.

[10] 惠佳豪,邢相栋,郑兆颖,等. 基于KPCA和Logistic-SSA-BP的烧结矿FeO含量预测[J]. 钢铁研究学报,2024,36(6):717－726.
XI Jiahao, XING Xiangdong, ZHENG Zhaoying, et al. Prediction of FeO content in sinter based on KPCA and Logistics-SSA-BP[J]. Journal of Iron and Steel Research,2024,36(6):717－726.

[11] 蒋大军. 烧结矿FeO含量预报系统开发与应用[J]. 钢铁,2006,41(9):13－17.
JIANG Dajun. Development and application of prediction system of FeO content in sinter[J]. Iron & Steel,2006,41(9):13－17.

[12] 姜宏洲,张学东,张宏勋,等. 烧结生产专家指导系统研究[J]. 烧结球团,2000,25(1):8－10.
JIANG Hongzhou,ZHANG Xuedong,ZHANG Hongxun,et al. A real-time expert instruction system for sinter production[J]. Sintering and Pelletizing,2000,25(1):8－10.

[13] 郭宇浩,蒋朝辉,潘冬,等. 基于红外热图像多类异质特征的烧结矿FeO含量检测[C]//2019中国自动化大会(CAC2019)论文集. 北京:中国自动化学会,

2019:57 – 64.
GUO Yuhao, JIANG Zhaohui, PAN Dong, et al. FeO content detection of sinter based on infrared thermal image with multiclass and heterogeneous characteristics [C]//Proceedings of the 2019 China Automation Congress (CAC2019). Beijing: Chinese Association of Automation, 2019:57 – 64.

[14] DU S, WU M, CHEN L F, et al. Operating performance improvement based on prediction and grade assessment for sintering process[J]. IEEE Transactions on Cybernetics, 2022, 52(10):10529 – 10541.

[15] 张振,唐珏,储满生,等. 基于 EEMD 和机器学习的烧结矿 FeO 成分长短期综合预报[J]. 钢铁, 2023, 58(8):32 – 40.
ZHANG Zhen, TANG Jue, CHU Mansheng, et al. Long short term comprehensive prediction of sinter FeO components based on EEMD and machine learning[J]. Iron and Steel, 2023, 58(8):32 – 40.

[16] 方怡静,蒋朝辉,黄良,等. 基于知识与 AW-ESN 融合的烧结过程 FeO 含量预测[J]. 自动化学报, 2024, 50(2):282 – 294.
FANG Yijing, JIANG Zhaohui, HUANG Liang, et al. FeO content prediction in sintering process based on fusion of data-knowledge and AW-ESN[J]. Acta Automatica Sinica, 2024, 50(2):282 – 294.

[17] TAN K K, LI Z Z, HAN Y, et al. Research and application of coupled mechanism and data-driven prediction of blast furnace permeability index[J]. Applied Sciences, 2023, 13(17):9556.

[18] EJEGWA P A, WANZENKE T D, OGWUCHE I O, et al. A robust correlation coefficient for fermatean fuzzy sets based on Spearman's correlation measure with application to clustering and selection process[J]. Journal of Applied Mathematics and Computing, 2024, 70(2):1747 – 1770.

[19] ZHENG K F, WANG X J, WU B, et al. Feature subset selection combining maximal information entropy and maximal information coefficient[J]. Applied Intelligence, 2020, 50(2):487 – 501.

[20] WEN X Y, LI W B. Time series prediction based on LSTM-attention-LSTM model[J]. IEEE Access, 2023, 11:48322 – 48331.

[21] AL-SELWI S M, HASSAN M F, ABDULKADIR S J, et al. RNN-LSTM: From applications to modeling techniques and beyond: Systematic review[J]. Journal of King Saud University: Computer and Information Sciences, 2024, 36(5):102068.

[22] LANDI F, BARALDI L, CORNIA M, et al. Working memory connections for LSTM[J]. Neural Networks, 2021, 144:334 – 341.

[23] HUSSAIN H, TAMIZHARASAN P S, RAHUL C S. Design possibilities and challenges of DNN models: A review on the perspective of end devices[J]. Artificial Intelligence Review, 2022, 55(7):5109 – 5167.

[24] ALDAHDOOH A, HAMIDOUCHE W, FEZZA S A, et al. Adversarial example detection for DNN models: A review and experimental comparison[J]. Artificial Intelligence Review, 2022, 55(6):4403 – 4462.

[25] HU Q, GUO Y J, XIE X F, et al. Test optimization in DNN testing: A survey[J]. ACM Transactions on Software Engineering and Methodology, 2024, 33(4): 1 – 42.

[26] 张智峰,刘小杰,李欣,等. 基于 MIV-GA-BP 模型预测烧结矿 FeO 含量[J]. 中国冶金, 2022, 32(10): 75 – 81.
ZHANG Zhifeng, LIU Xiaojie, LI Xin, et al. Prediction of FeO content in sinter based on MIV-GA-BP model[J]. China Metallurgy, 2022, 32(10):75 – 81.

(上接第 14 页)

[82] AL-HARAHSHEH M, KINGMAN S, AL-MAKHADMAH L, et al. Microwave treatment of electric arc furnace dust with PVC: Dielectric characterization and pyrolysis-leaching[J]. Journal of Hazardous Materials, 2014, 274: 87 – 97.

[83] ALTARAWNEH S. Unravelling the underpinning mechanisms associated with the microwave treatment of electric arc furnace dust with polyvinyl chloride: An electromagnetic and kinetic investigation[D]. Nottinghamshire: University of Nottingham, 2023.

[84] YE Q, PENG Z W, LI G H, et al. Microwave-assisted reduction of electric arc furnace dust with biochar: An examination of transition of heating mechanism[J]. ACS Sustainable Chemistry & Engineering, 2019, 7(10): 9515 – 9524.