基于机器视觉的烧结矿 FeO 含量在线感知

任玉辉[a]，曾小信[b]，李旭东[b]
（中冶长天国际工程有限责任公司 a. 中冶长天（长沙）智能科技有限公司；b. 工程技术研究中心，湖南 长沙 410205）

摘要：烧结矿 FeO 的含量是烧结生产的一项综合性指标，影响它的因素较多而且各因素间呈现一种非线性关系，导致对 FeO 含量的预测难度较大。针对烧结矿 FeO 含量难以预测的问题，本文提出一种基于机器视觉技术实现烧结矿 FeO 含量在线感知的系统。该系统通过在烧结台车机尾安装红外热成像设备来获取烧结断面的热成像图片信息并对图片信息特征进行提取和分析，提取的机尾断面图像特征作为 Darknet-19 算法的输入参数，建立基于改进的 Darknet-19 算法的烧结矿 FeO 含量预测模型，实现对烧结矿 FeO 含量的实时预测。现场实际使用表明，烧结矿 FeO 含量预测模型的预测值与实际值偏差 ±0.5 时，准确率在 82.5%，对稳定和优化烧结生产过程控制有积极作用。

关键词：烧结矿；FeO；机尾断面；机器视觉；Darknet-19；红外热成像
中图分类号：TF046.4；TP391.41 **文献标识码**：A **文章编号**：1000－8764（2024）03－0053－07
doi：10.13403/j.sjqt.2024.03.041

Online perception on FeO content in sinter based on machine vision

REN Yuhui[a], ZENG Xiaoxin[b], LI Xudong[b]
(Zhongye Changtian International Engineering Co., Ltd.a. Zhongye Changtian (Changsha) Intelligent Technology Co., Ltd.; b. Engineering Technology Research Center, Changsha 410205, Hunan, China)

Abstract: The FeO content of sinter is a comprehensive index of sinter production with many factors affecting it and a nonlinear relationship between the factors, which makes it difficult to predict the FeO content. In order to solve the problem that the FeO content of sinter is difficult to predict, a system based on machine vision technology to realize the online perception of FeO content in sinter is proposed. The system obtains the thermography picture information of the tail section by installing infrared thermography equipment at the tail of the sintering trolley, extracts and analyzes the picture information features, and uses the extracted image features of the tail section as the input parameters of the Darknet-19 algorithm, and establishes a prediction model of sinter FeO content based on the improved Darknet-19 algorithm to realize the real-time prediction of sinter FeO content. The field application shows that when the deviation between the predicted value and the actual value of the sinter FeO content prediction model is ±0.5, the accuracy rate is 82.5%, which has a positive effect on stabilizing and optimizing the control of the sintering production process.

Key words: sinter; FeO; tail section; machine vision; Darknet-19; infrared thermography

目前，我国钢铁企业烧结厂对烧结矿化学成分的检测主要是通过每 2 h 一次的烧结矿人工采样进行化学分析[1]。由于化学分析有着较大的滞后，很难实现对烧结过程的准确控制。烧结矿 FeO 含量是评价烧结生产的一项综合性指标，它反映了烧结过程的动态控制状况，其含量不仅受配碳量、混合料水分、返矿量的交互作用，而且还受原料配比、烧结料层厚度、透气性、烧结矿的碱度、MgO 含量和 SiO_2 含量等的共同影响；同时，它与烧结矿的转鼓强度、低温还原粉化率、还原性的相关性很大，是影响高炉炉况顺行的一个重要参数[2]。烧结矿 FeO 含量的波动区间越窄，烧结过

收稿日期：2023－07－14；**修回日期**：2023－08－21
基金项目：国家重点研发计划资助项目（2022YFB3304705）
作者简介：任玉辉（1981—），男，高级工程师，从事钢铁冶金过程控制、数据建模、大数据分析等方面的研究。

程便越稳定。因此，烧结矿 FeO 含量的适宜控制对高炉冶炼较为重要。为了实时判断烧结矿 FeO 的含量，控制烧结生产，大多烧结厂辅以机尾直接观察法进行辅助检测[3]。烧结机尾环境恶劣，在观察口的温度可达 400 ℃，且粉尘非常大，在一定程度上影响了看火工的判断；同时，看火工之间的经验、技术、素质和责任心之间的差异，导致了对 FeO 含量判断存在不稳定性。虽然化学分析方法比较准确，但化学分析时间约为1 h，这造成了信息反馈时间长，不能在线检测，实时性差[4]。上述情形使烧结矿质量和高炉冶炼效果受到一定影响，而烧结机尾断面热成像图像一定程度上可以反应丰富的烧结矿质量信息，包含了温度占比、红火层分布、气孔大小、烧结矿轮廓等特征信息，与看火工的视觉信息更加接近[5-6]，因此，以烧结机尾断面图像为研究对象，采用机器视觉技术对烧结机尾断面特征数据进行提取，利用改进的 Darknet-19 算法实现对烧结矿 FeO 含量的在线感知，对稳定和优化烧结生产过程控制有积极作用，具有重要的理论意义和实际应用价值。

1 系统硬件组成

烧结机尾断面是反应烧结过程信息的窗口(如 FeO、烧成、燃料配比、液相变化、熔融、固结、是否烧透等)，大量的烧结机尾最佳断面图像数据是烧结大数据的重要组成部分。烧结机尾断面图像主要通过在机尾平台固定安装红外成像仪拍摄烧结饼断裂后图像而得到。系统通过红外成像仪、数据传输线、数据处理服务器实现对烧结矿 FeO 的在线感知，如图 1 所示。系统硬件主要由红外热像仪、气体净化装置、和计算机控制系统三部分组成。其中：① 红外热像仪采用窄带滤波成像，并通过串行通讯的方式进行硬件连接；高温防护外套包裹在热像仪外部，采用压缩空气吹扫和水冷方式对设备进行保护；防护套设计时采用了双气帘防护结构，在保证耐高温性能的同时，确保窗口不结灰，以保证系统红外图像的清晰度，满足软件分析的需要；② 气体净化装置主要针对接入的压缩空气进行过滤处理，保证用于吹扫气体的清洁度；③ 计算机控制系统由现场控制箱和服务器系统组成，现场控制箱完成对摄像头伸进退出等相关控制功能，其通过光缆与服务器进行通讯，系统软件功能在服务器上实现。

2 系统软件组成和功能实现

整个系统的软件模块由图片采集模块、最佳断面提取模块、断面特征样本采集模块、FeO 预测模块等几部分组成，其中：① 图片采集模块：该模块主要完成与热像仪的数据交互，系统按照每秒一帧的采集频率获取图片并通过机器视觉技术提取特征数据存储于数据库；② 最佳断面提取模块：该模块根据每秒采集的图片特征数据提取出最佳断面的特征信息；③ 断面特征样本采集模块：该模块对指定时长内最佳断面的特征值进行统计分析，并与实验室 FeO 的化验结果进行匹配，形 成样本记录，存储于数据库中；④ FeO预测模

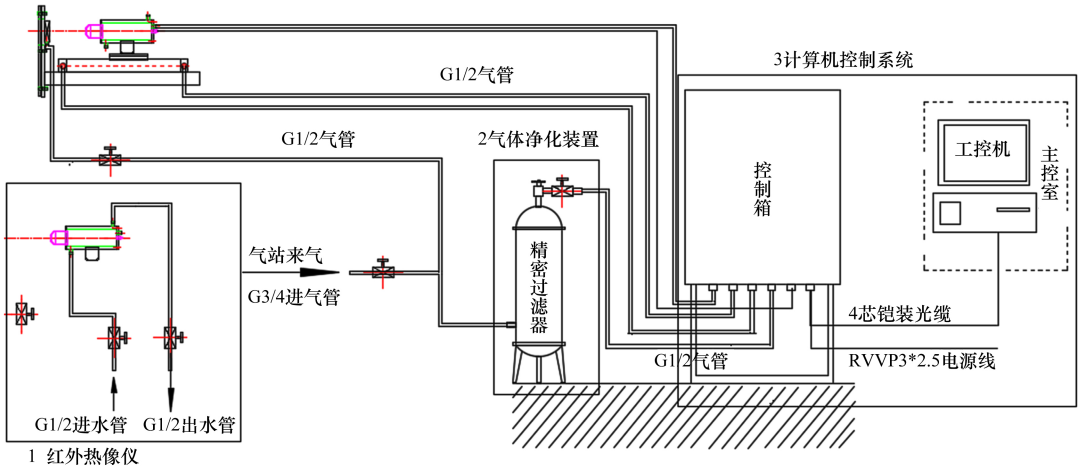


图 1 系统硬件组成

Fig. 1 System hardware composition diagram

块：该模块是利用改进的 Darknet-19 算法对样本集合进行训练，并使用训练后的模型实现对 FeO 含量的预测，当预测结果满足精度要求时，不再对样本集合进行训练更新预测模型，反之，则当有新的样本产生时，触发样本训练功能，完成对预测模型的更新，从而实现预测模型的自学习自适应功能，最终实现烧结矿 FeO 预测的目的。

整个系统功能实现的关键点是特征值的确定、最佳断面的提取和样本集合的建立，FeO 预测模型的算法实现，下面针对这几个问题进行详细描述。

2.1　特征值确定

烧结机尾断面图像包含的信息很多，红外热像仪拍摄的图片提供的信息主要是温度信息，系统通过对温度信息进行转换，得出系统需要的信息，主要包括断面温度分布情况和红火层分布情况两大类。其中温度分布反应了原料的配制比例大小和粒度大小，烧结的快慢和液相生成量的大小。当烧结温度低时，烧结过程产生的液相不足，含量较低，烧结强度下降，即黏连性不够；相反，温度高时，液相较多，烧结矿的黏连度较高；红火层分布情况可以反应出烧结矿的烧透情况，红火层位置在整个料层的下半区域时，被认为燃烧完全，另外红火层厚度的偏差可以反应烧结的饱和程度是否存在局部过烧或欠烧的情况，红火层厚度偏差值大小能够很好的反应横向燃烧的均匀性和一致性。基于以上分析，本文围绕烧结机尾断面提取以下内容作为断面特征值：① 断面面积（断面区域内像素点个数）；② 最高温（断面区域内温度的最大值）；③ 最低温（断面区域内温度的最小值）；④ 平均温度（断面区域内温度的平均值）；⑤ 统计红火区不同温度区间的占比。具体要求有：红火区面积（像素点数）S_{sum}，判定标准为温度大于 400 ℃的温度点——[400，+）；高温区面积（像素点个数）S_H，判定标准为温度大于 850 ℃的温度点——[850，+）；中温区面积（像素点个数）S_M，判定标准为温度介于 600～850 ℃的温度点——[600，850）；低温区面积（像素点个数）S_L，判定标准为温度介于 400～600 ℃的温度点——[400，600）。公式如下：

$$\text{高温区占比 } P_H = \frac{S_H}{S_{sum}} \tag{1}$$

$$\text{中温区占比 } P_M = \frac{S_M}{S_{sum}} \tag{2}$$

$$\text{低温区占比 } P_L = \frac{S_L}{S_{sum}} \tag{3}$$

⑥ 断面不同位置区间的红火分布。具体要求有：沿断面宽度方向将断面平均分成 5（具体数量可根据实际需要调整）等分，通过求取每个区间红火点纵坐标的平均值来表示该区域内红火层的厚度，公式如下：

$$L_i = \frac{\sum_{i=0}^{n} Y_i}{n} \tag{4}$$

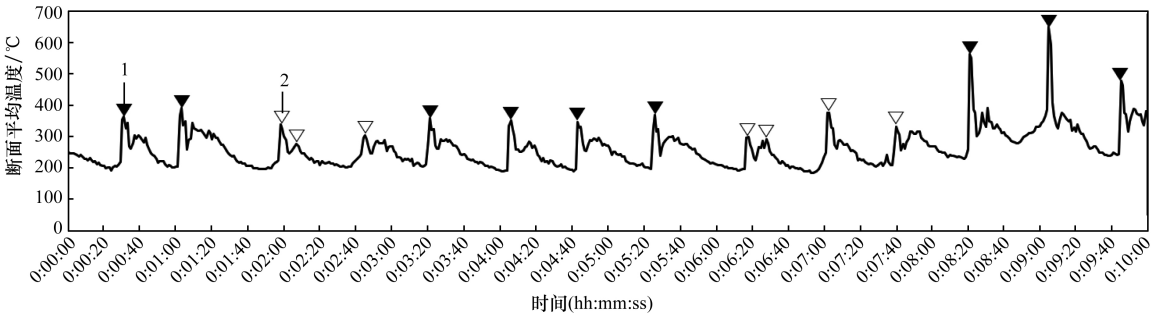
式中：L_i 为区间 i 红火层厚度；Y_i 为表示区间 i 内每个红火点的纵坐标值；n 为表示区间 i 内红火点的个数。

2.2　最佳断面的提取

通过对断面形成过程的分析，系统采用了基于断面平均温度变化趋势的提取算法，实现了对最佳断面的确定。烧结机尾断面的形成是随着台车移动呈周期性变化，具体可以分为 4 个阶段[7]：① 烧结矿在台车上随着台车向前移动，当烧结矿床到达机尾时，随着台车的缓慢迁移和倾斜，此时指定矩形区域捕获的是料面，区域内的平均温度最低；② 随着台车继续移动，倾斜角达到一定角度后，烧结矿床开始出现裂缝，裂缝随着台车倾斜角度的增大而逐渐加大直至断开，后一节台车的烧结矿断面从上之下完全显现，此时矩形区域捕获到完整断面，区域内平均温度最高；③ 烧结矿落下后会引起高温粉尘上扬，导致图像模糊，此时矩形区域的平均温度会平稳变化；④ 随着高温粉尘被慢慢抽净，图画又恢复清晰。至此一个周期变化完成。

根据实际观察发现正常情况下由①到②矩形区域内的平均温度会突然增加，由②到③温度会突然下降，但是如果配料过程中燃料配加量过多会引起烧结矿黏结台车，由步骤阶段①到阶段②的变化是一个缓慢的变化而不是突变。另外，在阶段③也会产生一系列的突变值，但突变幅度较小。

根据上述分析可将断面区域内的平均温度值绘制成为历史变化曲线，如图2所示。则最佳机



1—最佳机尾断面点；2—非最佳机尾断面点。

图 2 机尾断面平均温度趋势

Fig. 2 Trend image of tail section average temperature

尾断面形成的时间点将会在曲线的极大值点集合内产生，且最佳断面点还应满足 X 轴方向变化很小和 Y 轴方向变化很大的要求，按此要求将机尾断面分为最佳机尾断面和非最佳机尾断面。按照上述描述，系统提取最佳断面的信息并存储于数据库中，数据表结构如表 1 所示。

表 1 断面信息表

Table1 Taile section information

序号	信息名称
1	信息获取时间
2	断面区域内的像素点个数
3	框选矩形区域温度最大值
4	框选矩形区域温度最小值
5	框选矩形区域内平均温度
6	红火区面积
7	高温区占比
8	中温区占比
9	低温区占比
10	区域 1 红火层厚度
11	区域 2 红火层厚度
12	区域 3 红火层厚度
13	区域 4 红火层厚度
14	区域 5 红火层厚度
15	是否为最佳断面 （1 表示为最佳断面,0 表示为非最佳断面）

2.3 建立样本集合

目前，针对 FeO 预测建立样本集的研究更多的是先确定特征向量、针对烧结机机尾断面完成特征值提取、与 FeO 化验结果匹配形成样本向量后进行存储。这种样本集的建立方式过于理论化，在实际生产过程中，并非每节台车都会形成完美的机尾断面，而这种情况恰恰反应了当前烧结矿质量不佳，所以只获取机尾断面的特征相当于获取的都是状态相对良好的样本信息而舍弃了烧结矿质量欠佳的样本，这种方式存在 3 个缺点：① 无法完整的提供烧结质量欠佳的样本数据；② 样本数据不完整，影响预测精度；③ 单独一节台车的断面特征值代表性欠佳。

针对以上问题，本文提出了一种针对一段时间(15 min)烧结机尾断面状态统计结果作为特征向量的样本采集方法。系统在热成像监控画面上设定矩形区域，此区域的大小需确保当断面形成时能够完全落在此区域内，针对断面提取算法得出每个断面的特征值并对一段时间内的特征值进行统计，将统计结果与 FeO 化验结果进行匹配，从而组成样本向量进行存储，得到样本集。最终形成的特征向量如表 2 所示。

表 2 特征向量表

Table 2 Feature vector Table

序号	向量元素名称
1	向量获取时间
2	断面区域内的像素点个数的平均值
3	断面区域内温度最大值的平均值
4	断面区域内温度最小值的平均值
5	断面区域内平均温度的平均值
6	红火区面积平均值
7	高温区占比平均值
8	中温区占比平均值
9	低温区占比平均值
10	区域 1 红火层厚度的平均值
11	区域 2 红火层厚度的平均值

表 2（续）

序号	向量元素名称
12	区域 3 红火层厚度的平均值
13	区域 4 红火层厚度的平均值
14	区域 5 红火层厚度的平均值
15	指定时间内出现断面的个数
16	指定时间内最佳断面的个数
17	最佳断面占比
18	实验室化验结果

注：最佳断面占比为指定时间内最佳断面的个数与指定时间内出现断面的个数之比。

2.4　烧结矿 FeO 预测模型

根据表 2 的数据特征，采用 Darknet[8] 深度学习框架搭建烧结矿 FeO 预测模型。其中 Darknet-19 算法具体的网络结构如表 3 所示。

表 3　Darknet-19 网络结构

Table 3　Network structure of Darknet-19

类型	深度	尺寸/步长
卷积层	32	3×3
池化层		2×2/2
卷积层	64	3×3
池化层		2×2/2
卷积层	128	3×3
卷积层	64	1×1
卷积层	128	3×3
池化层		2×2/2
卷积层	256	3×3
卷积层	128	1×1
卷积层	256	3×3
池化层		2？2/2
卷积层	512	3×3
卷积层	256	1×1
卷积层	512	3×3
卷积层	256	1×1
卷积层	512	3×3
池化层		2×2/2
卷积层	1 024	3×3
卷积层	512	1×1
卷积层	1 024	3×3
卷积层	512	1×1
卷积层	1 024	3×3
平均池化层	1 000	1×1

Darknet-19 网络和 VGG 网络类似，主要使用卷积，并且每个 pooling 操作之后将特征图通道数加倍。使用 global average pooling 进行处理，并在卷积之间使用卷积来降低特征图通道数从而降低模型计算量和参数量。Darknet-19 网络的每个卷积层后面都是用了 BN 层来加快模型收敛，防止模型过拟合。Darknet-19 网络总共有 19 个卷积层（convolution）、5 个最大池化层（maxpooling）。

采用优化后的 Darknet-19 作为 backbone，对输入数据进行深度学习特征提取，表 2 中前 17 维数据作为模型输入，第 18 维数据作为训练数据中的标签值以及预测输出的对比值，从而搭建网络模型，其网络模型如图 3 所示。

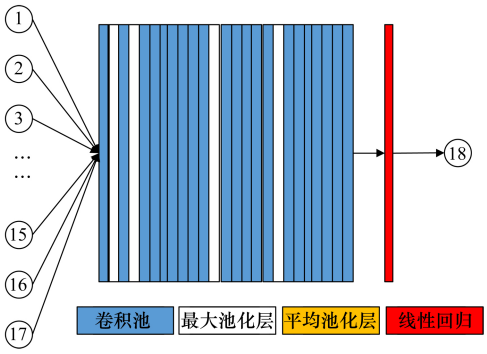


图 3　优化后网络模型结构

Fig. 3　Model structure of optimized network model structure

本文将 darknet-19 的最后一层逻辑回归（softmax）改进成线性回归[9-10]（linear regression），这可以使得网络进行数值预测，从而实现对 FeO 值的预测。该网络的损失函数采用均方根误差[11-12]（Root Mean Square Error，S_{RMSE}），计算方法见式（5）。

$$S_{\mathrm{RMSE}} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(P_i - R_i)^2} \tag{5}$$

式中：P_i 为预测的 FeO 值；R_i 为实际的 FeO 值，n 代表训练数据的总数。

2.5　系统实现

系统以 VS2017 作为开发平台，SQL SERVER2012 作为数据库平台，采用机器视觉技术实现对热像仪图片的分析和数值提取，预测算法使用 Darknet 深度学习框架完成模型训练和 FeO 预测，通过人机界面展示相关信息。系统在国内某钢铁厂投用后能够长期稳定的运行。

系统采用 C/S 架构完成整个系统的搭建，图片信息提取、最佳断面信息提取、样本提取、在线预测作为服务程序相互协同工作，运行于服务端，每 10 min 完成一次在线预测，其流程图如图 4 所示，系统每次运行首先获取训练好的预测模型，再读取断面特征数据后输入到预测模型中完成对烧结矿 FeO 含量的在线预测，预测完成之后系统通过读取变量 ISTrainFlag 的值来判断预测模型是否需要更新，如需要更新则对模型重新进行训练并保存，否则进入下一轮循环。HMI 界面作为客户端程序实时获取服务端数据，进行实时展示，运行界面如图 5 所示，界面包括 3 个区域：①区域 1 的左侧窗口显示了机尾断面视频监控画面，右侧显示的是截取到的断面图片，此区域功能为用户提供了对断面实时监控的窗口；区域 2 主要针对红火层厚度、温度占比分布、最高温度、最低温度、以及平均温度的情况进行了统计展示，通过点击“红火层厚度柱状图”、“分布饼图”、“温度高－中－平均趋势”三个按钮来实现不同画面的切换。用户可以根据柱状图的高度、不同柱状图之间的差距、温度分布情况对当前终点位置、终点温度和终点位置的一致性等烧结状态指标是否合理做出判断，实现为用户提供量化判定依据的作用；区域3将FeO的化验值和预测值的对比

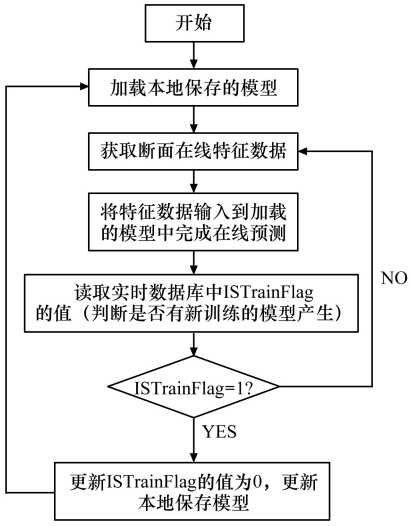


图 4 系统流程

Fig. 4 System flow diagram

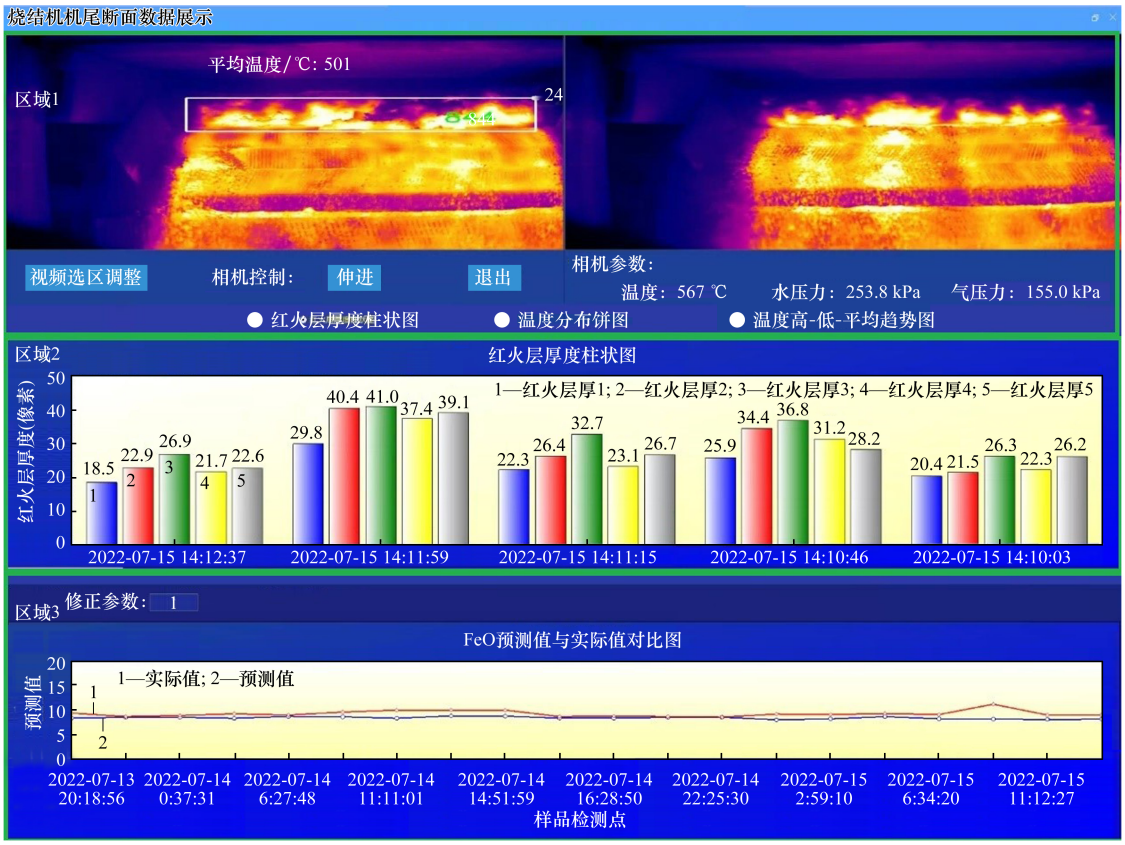


图 5 系统界面

Fig. 5 System interface diagram

曲线直观的展示给用户，系统以化验取样时间 T 为基准点，T_{Δ} 为烧结矿从机尾处运输至取样点的时间，系统获取在[($T-T_{\Delta}$)－15,($T-T_{\Delta}$)＋15] 30 min 内预测值的平均值作为最终结果与化验值进行对比，界面展示了最近 20 条化验值与预测值的对比曲线。

2.6　应用效果

系统在某钢铁厂投用 1 a，系统界面展示最近 20 条化验数据与预测数据进行比对，当有新的化验数据产生时，系统对曲线进行更新，对投用期间的预测准确率进行统计，烧结矿 FeO 含量预测值与实际值偏差 ±0.5 时，准确率在 82.5%。表 4 截取了其中 40 条数据进行展示。

表 4　FeO 化验值与预测值对比结果

Table 4　Comparison of Assay value and predicted value For FeO

序号	化验值	预测值	偏差	序号	化验值	预测值	偏差
1	7.43	7.26	0.17	21	6.8	7.26	－0.46
2	7.6	7.42	0.18	22	8.3	7.62	0.68
3	7.2	7.2	0	23	7.5	7.26	0.24
4	7.0	7.26	－0.26	24	6.7	7.26	－0.56
5	7.4	8.09	－0.69	25	7.7	7.85	－0.15
6	8.2	8.24	－0.04	26	7.2	7.26	－0.06
7	7.5	7.26	0.24	27	7.3	7.39	－0.09
8	6.5	6.71	－0.21	28	7.5	7.80	－0.30
9	7.3	7.79	－0.49	29	7.6	7.99	－0.39
10	7.8	7.26	0.54	30	7.4	7.26	0.14
11	7.5	7.26	0.24	31	6.8	7.26	－0.46
12	7.6	7.93	－0.33	32	8.5	7.71	0.79
13	7.3	7.26	0.04	33	8.0	8.12	－0.12
14	7.5	7.95	－0.45	34	8.0	7.49	0.51
15	7.2	7.26	－0.06	35	7.5	7.26	0.24
16	7.4	7.26	0.14	36	7.0	7.26	－0.26
17	7.5	7.56	－0.06	37	7.3	7.55	－0.25
18	7.4	7.26	0.14	38	7.9	7.47	0.43
19	7.6	7.5	0.10	39	7.8	7.26	0.54
20	7.5	7.26	0.24	40	8.0	7.71	0.29

3　结　论

针对烧结厂烧结矿 FeO 含量分析的滞后性和难以预测的情况，利用机器视觉技术分析机尾断面图像的特征信息，把机尾断面图像特征信息作为 Darknet-19 算法的输入参数，建立基于Darknet-19 算法的烧结矿 FeO 含量预测模型，实现烧结矿 FeO 含量的在线感知。系统在某钢铁厂投用 1 a，烧结矿 FeO 含量预测值与实际值偏差 ±0.5 时，准确率在 82.5%。预测结果可以正确指导操作人员调整配碳量，来实现对 FeO 的控制，同时，用户可根据红火层的分布情况，调整辅门开度，确保烧结终点横向的一致性。

参考文献：

[1] 刘竹林. 烧结 FeO 含量的影响因素探讨[J]. 重庆科技学院学报,2005,7(1):8－10.
LIU Zhulin. Discussion on influencing factors of sintered FeO content[J]. Journal of Chongqing University of Science and Technology,2005,7(1):8－10.

[2] 石烟翠. 烧结矿 FeO 含量的研究[J]. 烧结球团,2004,29(3):19－22.
SHI Tianhui. Research on FeO content of sintered ore[J]. Sintering and Pelletizing,2004,29(3):19－22.

[3] 余骏,孟飞,陈生利,等. FeO 含量对烧结矿冶金性能影响研究[J]. 矿业工程,2021,19(5):41－45.
YU Jun, MENG Fei, CHEN Shengli, et al. Effect of FeO content on metallurgical properties of sinter[J]. Mining Engineering,2021,19(5):41－45.

[4] 黄绮君. 烧结矿 FeO 含量与烧结产质量的关系[J]. 烧结球团,1980(1):17－26.
HUANG Qijun. Relationship between FeO content of sinter and sinter output[J]. Sintering and Pelletizing,1980(1):17－26.

[5] 马洛文. 基于机尾红外热图像的烧结矿质量监测[J]. 炼铁,2005(增刊 1):107.
MA Luowen. Supervising sinter quality with infrared image system of end-most section[J]. Ironmaking,2005(S1):107.

[6] 孙铁强,尹怡欣,董洁,等. 基于机器视觉和神经网络的烧结质量预测[J]. 计算机工程,2008(11):240－242.
SUN Tieqiang, YIN Yixin, DONG Jie, et al. Sintering quality prediction based on machine vision and ANN[J]. Computer Engineering,2008(11):240－242.

（下转第 88 页）

particle size detection based on image processing[C]// Proceedings of 2017 Chinese Intelligent Systems Conference. Mudanjiang: Chinese Association for Artificial Intelligence, 2017: 505 – 514.

[10] 唐庆博,唐超,张恒浩. 一种改进的基于 Hough 变换的精确圆检测方法[J]. 航空计算技术,2017,47(3): 58 – 61.
TANG Qingbo, TANG Chao, ZHANG Henghao. An improved circle detection method based on hough transform[J]. Aeronautical Computing Technique, 2017, 47(3): 58 – 61.

[11] LAND E H, MCCANN J J. Lightness and retinex theory [J]. Journal of the Optical Society of America, 1971, 61(1): 1 – 11.

[12] 王浩,张叶,沈宏海,等. 图像增强算法综述[J]. 中国光学,2017,10(4): 438 – 448.
WANG Hao, ZHANG Ye, SHEN Honghai, et al. Review of image enhancement algorithms [J]. Chinese Optics, 2017, 10(4): 438 – 448.

[13] 王萍,孙振明. 多级分解的 Retinex 低照度图像增强算法[J]. 计算机应用研究,2020,37(4): 1204 – 1209.
WANG Ping, SUN Zhenming. Multi-level decomposition Retinex low-light image enhancement algorithm[J]. Application Research of Computers, 2020, 37(4): 1204 – 1209.

[14] JOBSON D J, RAHMAN Z, WOODELL G A. A multi-scale Retinex for bridging the gap between color images and the human observation of scenes [J]. IEEE Transactions on Image Processing, 1997, 6(7): 965 – 976.

[15] MA J X, FAN X N, NI J J, et al. Multi-scale Retinex with color restoration image enhancement based on Gaussian fltering and guided fltering[J]. International Journal of Modern Physics B, 2017, 31: 16 – 19.

[16] 张学锋,陈天宇,储岳中,等. 基于霍夫变换的烧结矿粒度识别研究[J]. 重庆工商大学学报(自然科学版),2022,39(6): 118 – 124.
ZHANG Xuefeng, CHEN Tianyu, CHU Yuezhong, et al. Study on particle size identification of sinter based on hough transform [J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(6): 118 – 124.

(上接第59页)

[7] 刘征建,左海滨,张建良. 烧结机尾特征断面图像采集算法的研究及应用[J]. 钢铁,2008. 43(3): 21 – 24.
LIU Zhengjian, ZUO Haibin, ZHANG Jianliang. Research and Application of Image Acquisition Algorithm for Characteristic Section of Sintering Machine Tail[J]. Iron and Steel, 2008. 43(3): 21 – 24.

[8] 刘博,王胜正,赵建森,等. 基于 Darknet 网络和 YOLOv3 算法的船舶跟踪识别[J]. 计算机应用,2019,39(6): 1663 – 1668.
LIU Bo, WANG Shengzheng, ZHAO Jiansen, et al. Ship tracking recognition based on darknet network and YOLOv3 algorithm[J]. Journal of Computer Applications, 2019, 39(6): 1663 – 1668.

[9] VISWESVARANi C. Multiple regression in behavioral research: Explanation and prediction [J]. Personnel Psychology, 1998, 51(1): 223 – 226.

[10] 成常杰,陆晓骏. 基于多元线性回归的螺纹钢价格分析[J]. 冶金管理,2023(459): 49 – 53.
CHENG Changjie, LU Xiaojun. Price analysis of rebar based on multiple linear regression [J]. China Steel Focus, 2023(459): 49 – 53.

[11] HYNDMAN R J, KOEHLER A B. Another look at measures of forecast accuracy[J]. International journal of forecasting, 2006, 22(4): 679 – 688.

[12] LEE Z J, LUO X X. Predicting rainfall-induced landslide using bee colony algorithm based on support vector regression [J]. Recent Advances in Computer Science and Communications, 2023, 16(1): 33 – 37.