研究

基于烧结机尾红外热图像特征的烧结完成度智能识别

哈奉伶，潘 冬，余浩洋，蒋朝辉
（中南大学 自动化学院，湖南 长沙 410083）

摘要： 烧结完成度是烧结热状态的直观体现，其精准识别对提升烧结过程稳定性和生产效率、降低烧结生产能耗具有重要意义。由于烧结现场生产环境恶劣，燃烧反应复杂，烟气和物料对流换热频繁，烧结完成度实时精准识别困难，目前仍依赖于“人工看火”。针对存在的问题，提出一种基于烧结机尾红外热图像特征的烧结完成度智能识别方法。该方法首先对红外热图像进行预处理，提出一种双阶段关键帧提取方法，获取受扬尘干扰小，红层完整清晰的关键帧图像；然后基于热图像RGB属性中R通道值变化趋势精准提取烧结红层ROI区域；并基于图像结构纹理分解挖掘隐含的料层信息，获取分区料层高度；设计并提取燃烧层高度占比分布等特征表征烧结完成度；最后构建DS-CEFNet智能识别模型，融合图像深层特征和手工设计的浅层特征，实现烧结完成度精准识别。结果表明，所提模型对烧结完成度的识别准确率达96%，具有良好的应用价值。

关键词： 烧结过程；完成度；红外图像特征；特征融合；智能识别；精准识别
中图分类号： TF046.4；TP273 **文献标识码：** A **文章编号：** 1000－8764(2023)06－0044－10
doi： 10.13403/j.sjqt.2023.06.083

Intelligent recognition of sintering completeness based on infrared thermal image features of sintering machine tail

HA Fengling, PAN Dong, YU Haoyang, JIANG Zhaohui
(School of Automation, Central South University, Changsha 410083, Hunan, China)

Abstract: The sintering completeness is the intuitive embodiment of the sintering thermal state, and its accurate identification is of great significance to improve the stability and production efficiency of the sintering process and reduce the energy consumption of sintering production. Due to the harsh production environment at the sintering site, the complex combustion reaction, and the frequent convection & thermal exchange between flue gas and materials, it is difficult to accurately identify the sintering completeness in real time. At present, it still relies on “artificial fire watching”. In order to solve the existing problems, an intelligent recognition method of sintering completeness based on infrared thermal image features of sintering machine tail is proposed. In this method, firstly, the infrared thermal image is preprocessed, and a two-stage keyframe extraction method is proposed to obtain the keyframe image with little dust interference and complete and clear red layer; and then the ROI area of the sintered red layer is accurately extracted based on the change trend of the R channel value in the RGB attribute of the thermal image, and the hidden layer information is mined based on the image structure texture decomposition to obtain the height of the partitioned layer, and the characteristics such as the proportion distribution of the burning layer height are designed and extracted to characterize the sintering completeness; finally, the DS-CEFNet intelligent recognition model is constructed, which integrates the deep features of the image and the hand-engineered shallow features to achieve accurate recognition of sintering completeness. The results show that the model

收稿日期： 2023－10－31；**修回日期：** 2023－11－08
基金项目： 国家自然科学基金重大科研仪器研制项目(61927803)；长沙市自然科学基金资助项目(kq2202075)；湘江实验室重大项目(22XJ01005)
作者简介： 哈奉伶(2000—)，女，硕士研究生，从事图像处理、智能识别等方面的研究。
通信作者： 潘 冬(1992—)，男，博士，讲师，从事红外热成像、视觉检测、图像处理、深度学习等方面的研究。

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

proposed has an accuracy of 96% for the recognition of sintering completeness，which has good application value.

Key words: sintering process，completeness，infrared image features，feature fusion，intelligent recognition，accurate identification

钢铁工业是我国经济发展和基础建设的重要组成部分[1]。烧结是钢铁冶炼的重要工艺，为高炉工艺生产出合格的烧结矿，高炉炼铁的铁水质量与烧结矿质量关系紧密。同时，烧结也是钢铁冶炼中能耗的第二大工序，约占总能耗的 10%～20%。因此，烧结工序节能减排及烧结矿质量的稳定与优化对整个炼铁流程的技术经济指标都有着重要的影响[2]。烧结完成度是指烧结混合料燃烧的完成程度，能够反映烧结料层的最终燃烧情况。烧结完成度是一类烧结过程工况，能够直接体现烧结过程热状态，并与烧结矿的产量与质量密切相关。烧结完成度精准识别是提升烧结过程稳定性和生产效率，降低烧结生产能耗的前提[3]。

烧结完成度智能识别本质上是一种烧结过程工况识别。目前，烧结过程工况识别研究较少，其方法可分为两类：一类是基于数据驱动的工况识别；另一类是基于图像分析的工况识别。CHEN 等[4]通过两次 k-Means 聚类划分出 7 类烧结过程工况。HU 等[5]通过改进的模糊 C 均值聚类(fuzzy c-means，FCM)方法对烧结过程工况进行分类。然而这类工况识别方法通过数据相似性进行聚类，不具有可解释性，无法为后续调控提供指导。DU 等[6]采用基于动态时间规整(dynamic time warping，DTW)距离的 FCM 聚类方法建立烧结运行操作模式识别子模型，并基于运行模式出现的频率对子模型识别结果进行融合，共构建了 5 类操作模式。但这类方法依赖大量的过程检测数据，需要考虑各类数据的时间配准，处理过程复杂。WU 等[7]提出一种基于红绿蓝(red，green，blue，RGB)颜色灰度划分烧结机尾火焰图像，提取出烧结截面面积等图像几何特征，为烧结过程工况识别提出一种新的思路，但提取的图像特征受图像对比度、镜头曝光、镜头孔径等多种参数的影响，工况表征鲁棒性较差。BULNES[8]提出了一种在烧结机尾部采集红外热图像来提取特征的方法，但提取的主要是浅层特征，无法有效表征烧结工况。JIANG 等[9]通过机理分析对烧结红层分级分类，提取红外热图像非均匀特征建立多态机制模型实现工况划分。

烧结现场环境恶劣，燃烧过程复杂，烟气和物料对流换热频繁，传感器采集的生产数据存在波动较大、滞后严重等现象，导致烧结完成度实时精准识别困难。目前，烧结完成度识别仍依赖于“人工看火”。近年来，图像处理技术被广泛应用于工业过程分析，深度学习也在图像处理领域飞速发展，这为烧结完成度智能识别提供了新的思路。由于红外热成像技术具有无接触、无有害辐射等优势[10]，因此本文根据烧结机尾红外热图像特征，提出深－浅特征协同嵌入融合网络(DS-CEFNet)，以实现烧结完成度精准识别。

1　烧结机尾红外热图像预处理

1.1　图像周期序列关键帧获取

由于烧结过程复杂，受物料、燃料、操作、环境等因素波动影响，烧结生产周期呈动态性变化。同时，由于烧结机尾环境恶劣，落料时扬起的烟尘严重干扰工况监控(图 1)，因此需要获取一个周期内受扬尘干扰较小、红层完整清晰的图像作为关键帧图像，以便进行后续分析。



图 1　受扬尘干扰的烧结机尾红外热图像

Fig. 1　Disturbed infrared thermal image by raised dust of the sinter machine tail

现场获取的烧结机尾红外热图像为连续拍摄的图像，但由于烧结生产周期呈动态变化，扬尘干扰波动，同时获取的图像虽为定时间间隔拍摄，但拍摄过程由于相机过热等因素，图像拍摄存在卡顿现象，导致获取的图像周期并不固定。因此，本文提出一种双阶段关键帧提取方法。该方法首

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

先基于 ResNet50 模型识别周期起始帧，划分出图像周期序列，并基于密度峰值聚类初步筛选出受扬尘干扰小、红层清晰的图像；然后获取每个周期中最靠前的清晰图像作为关键帧。

以前排烧结料掉落，后排烧结料暴露在拍摄范围的前 1 ~2 张图像作为周期起始帧，模型通过识别周期起始帧划分出烧结料掉落周期序列。由于深度学习方法区别于传统机器学习，能够通过更多的样本试验降低人工特征选择参与并获得更高的准确率，因此本文通过构建基于残差网络 ResNet50[11] 和 Adam 优化器的深度学习模型来识别周期起始帧。

基于人眼视觉感知系统(human visual system，HVS)，图像结构信息高度适用于 HVS 理解并感知图像[12]。因此本文基于局部二进制(local binary patterns，LBP)的空间分布来表征图像结构信息。LBP 能稳健识别图像灰度变化，有效分辨大量旋转纹理。假设 g_c 为某一局部区块中心像素值，$\{g_0,g_1,\cdots,g_{P-1}\}$ 为以 g_c 为圆心半径为 R 的圆对称领域加权像素值，P 为设计的加权像素个数，如图 2 所示。

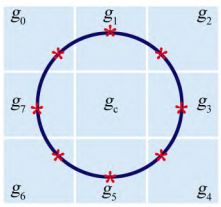


图 2 LBP_8^1 可视化

Fig. 2 LBP_8^1 visualization

LBP 算子定义为

$$s(g_i-g_c)=\begin{cases}1 & g_i-g_c\geqslant 0\\ 0 & g_i-g_c<0\end{cases} \tag{1}$$

经过 LBP 算子可产生 2^P 种二进制模式，以按位转换次数作为 LBP 模式，则 LBP 模式定义为

$$U(\mathrm{LBP}_{P,R})=\|s(g_{p-1}-g_c)-s(g_0-g_c)\|+\sum_{i=0}^{P-1}\|s(g_i-g_c)-s(g_{i-1}-g_c)\| \tag{2}$$

此时可产生 $P(P-1)+2$ 种模式，而在实际图像中，绝大多数图像只包含 2 次跳变[13]，共 $P+1$ 种，定义为均匀 LBP，如图 3 所示。

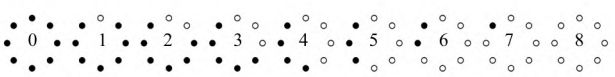


图 3 均匀 LBP

Fig. 3 Uniform LBP

将超过两次跳变的模式计为一种，即非 uniform LBP。则新的 LBP 模式共有 $P+2$ 种，定义为:

$$U'(P,R)=\begin{cases}\sum_{i=0}^{P-1}s(g_i-g_c), U(P,R)\leqslant 2\\ P+1, U(P,R)>2\end{cases} \tag{3}$$

将新的 LBP 模式记为 ULBP，基于 ULBP 可获取 LBP 特征直方图(local binary patterns histogram，LBPH[14])，LBPH 能够结合 LBP 特征和图像空间信息分布，从而更好地表征图像结构信息，其表达式如下。

$$H_{\mathrm{ULBP}}(k)=\frac{1}{MN}\sum_{i=1}^{M}\sum_{j=1}^{N}f(U'(P,R),k),k\in[0,K] \tag{4}$$

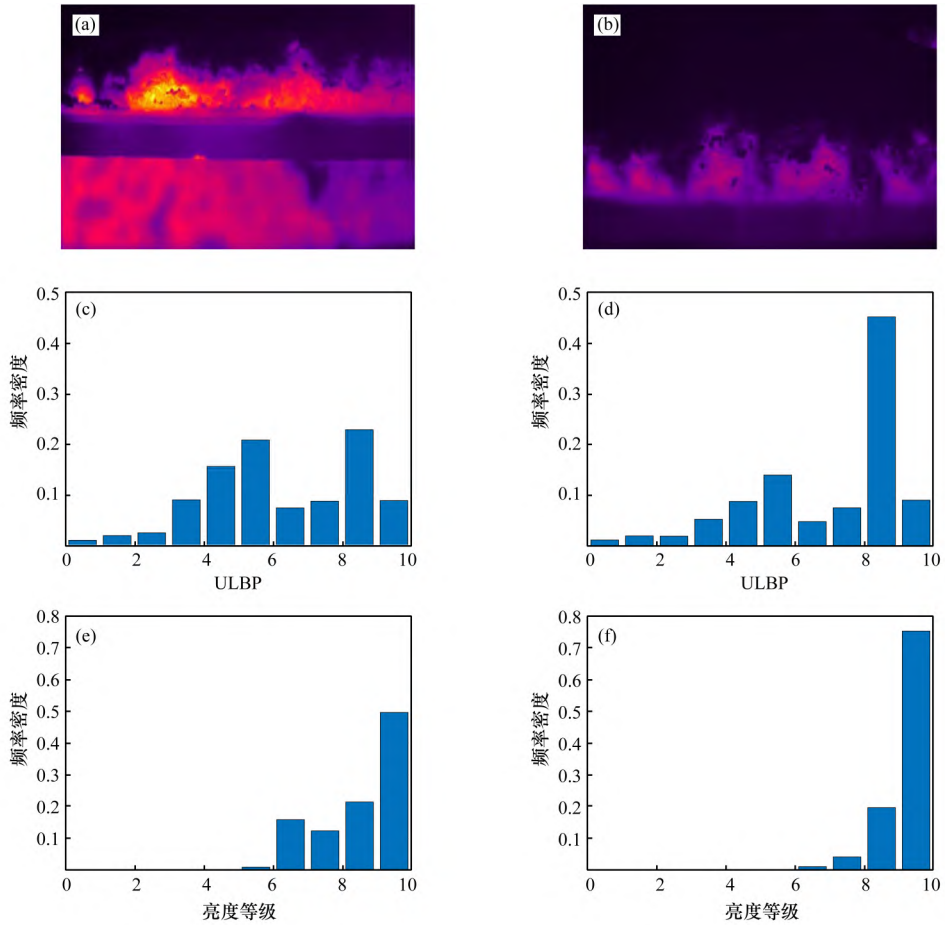
$$f(x,y)=\begin{cases}1, & x=y\\ 0, & x\neq y\end{cases} \tag{5}$$

式中：M、N 分别为图像的长和宽；K 为 ULBP 最大值；H_{ULBP} 为直方分布频率密度。

神经科学研究表明 HVS 对图像的亮度变化高度敏感[15]，因此本文基于图像亮度分布图(luminance histogram，LH)来表征图像亮度变化特征，即 $lh=\mathrm{hist}(I)$，其中 I 表示图像亮度，lh 为其直方分布图频率密度。本文将 LH 划分为 10 个等级与 LBPH 相对应，最终提取出的结构亮度分布特征如图 4 所示。

同时，本文采用密度峰值聚类算法(DCP)[16]对提取的结构亮度分布特征进行分析，实现关键帧初步筛选。区别于基于划分的聚类方法如 K-means 算法和基于层次的聚类方法如凝聚式层次聚类(agglomerative nesting，AGNES)算法等，基于密度的聚类方法能够挖掘出非球状簇，适用范围更广。DCP 算法能自动找出簇中心，实现任意形状数据的高效聚类。该算法通过点局部密度(ρ)和相对距离(δ)的决策判断确定聚类中心，并将剩余点进行分配，其定义如下。

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net



(a) 实例 1 原图；(b) 实例 2 原图；(c) 实例 1 LBPH 可视化；(d) 实例 2 LBPH 可视化；(e) 实例 1 LH 可视化；(f) 实例 2 LH 可视化

图 4　图像结构亮度分布特征可视化

Fig. 4　Visualization of image structure brightness distribution features

$$\rho_i = \sum_{i \neq j} \chi(d_{ij} - d_c) \tag{6}$$

$$\chi(x) = \begin{cases} 1, & x < 0 \\ 0, & x \geqslant 0 \end{cases} \tag{7}$$

$$\delta_i = \min_{j:\rho_j > \rho_i} (d_{ij}) \tag{8}$$

$$\delta_i = \max_{i \neq j} (d_{ij}) \tag{9}$$

式中：d_{ij}表示点 i 到点 j 的距离；d_c 为截断距离；$\chi(\,)$ 为逻辑判断函数，局部密度 ρ_i 定义为与点 i 距离小于 d_c 的点的个数；相对距离 δ_i 定义为密度比点 i 大的点与点 i 距离的最小值；当点 i 为密度最大的点时，相对距离 δ_i 定义为点 i 到其他点距离的最大值。以 ρ_i 为横轴，δ_i 为纵轴，可以作出决策图。通过决策图取出 ρ_i 和 δ_i 均相对较高的点作为簇中心，将 ρ_i 相对较低但 δ_i 相对较高的点标记为噪点，将剩余点分配给最近邻且密度大于它的点所在簇。

由于烧结料处于下落状态，周期内越靠后的图像实际红层倾斜角度越大，红层被压缩越严重。此外，虽然烧结起始帧图像受扬尘干扰较小，但此时烧结块可能处于风箱上方，由于风箱抽风存在强度不均等现象，同时抽风使得红层温度快速升高，红层特征受到干扰，并不能较好地反映最终生产情况。因此取每个周期除起始帧以外的最靠前的清晰图像作为关键帧图像。

1.2　烧结红层感兴趣区域提取

已裁剪的烧结机尾红外图像仍包含烧结台车、背景等无关信息，只有烧结红层区域对烧结完成度分析具有重要意义。由于提取出的关键帧图像红层所在位置并不固定，因此需要自适应地确定红层范围。

获取的烧结机尾图像为红外热图像，红外热图像由红外热像仪利用红外探测器和光学成像物

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

镜接受被测目标的红外辐射能量分布，反映到红外探测器的光敏元件上，经过彩色编码得到。红外热图像与物体表面热分布场对应，热图像上的不同颜色代表不同温度。常见的彩色编码方式有蓝红、灰度、铁红等，本文获取的烧结机红外热图像为铁红 X 编码。对于铁红 X 编码的热图像，被测物体的辐射强度变化在图像 RGB 属性中 R 通道值的变化中体现得最明显。因此，本文提出一种基于红外热图像 RGB 属性中 R 通道值变化趋势的红层感兴趣区域(region of interest，ROI) 提取方法。

首先自上而下获取图像每一行像素点的最大 r 值，计为序列 R_{max}。R_{max} 在红层出现和结束时均有两次规律性变化：红层出现时，r 值稳步递增且超过阈值 40；红层结束时，即红层与台车边界的过渡区域，r 值下降至 200 以下且稳步递减(图 5) 。

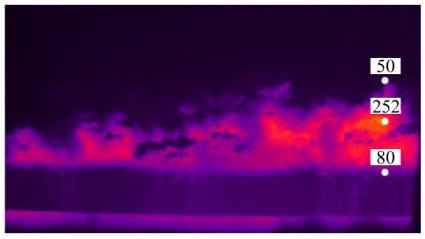


图 5 图像红层区域 r 值变化示意

Fig. 5 Schematic diagram of r-value variation in the red layer region of the image

为排除前后烧结料粘连和后排烧结料部分区域暴露等干扰，设定红层高度范围为 100 ~ 180。小于该范围为受到后排烧结料干扰，获取到了后排红层区域，此时重新设定起始线；超出该范围则是由于前后烧结料粘连，前一块烧结料严重遮挡了后一块料层，红层特征受到干扰，不利于后续分析，此时作为异常数据剔除该帧图像，如图 6 所示。

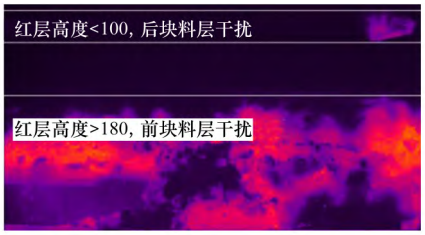


图 6 红层获取异常情况

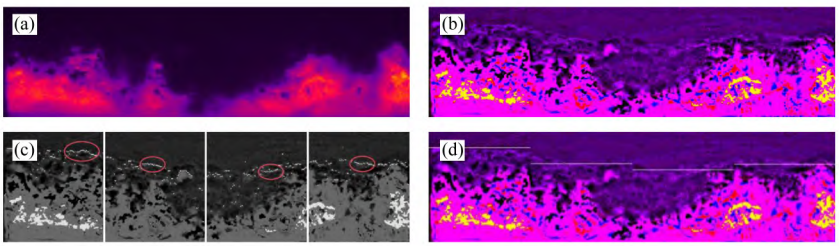
Fig. 6 Abnormal situation of red layer acquisition

1.3 烧结料层高度提取

由于烧结矿布料存在不均匀等现象，烧结料层高度并不一致，为更合理地表征烧结完成度，模型需要提取出料层高度信息。

根据提取的红层 ROI 区域，将红层起始位置向上移动 60 个像素以保留完整料层部分。由于烧结矿已反应完成的部分热辐射强度与烧结机尾环境近似，获取的红外热图像几乎无法用肉眼识别出料层信息，因此本文对料层图像 [图 7(a)] 基于区间梯度进行图像滤波实现结构纹理分解[17]，挖掘出隐含的料层高度信息，分解图像如图 7(b) 所示。再将提取的结构纹理分解图转换为灰度图，基于灰度阈值初步获取料层轮廓，如图 7(c) 所示。由于烧结布料时主要存在南北倾斜和中间凹陷两种不均匀情况，且偏差并不十分显著，因此本文将料层划分为 4 个区域，每个区域的高度以同一个值表示。

由于提取出的料层轮廓线受噪声干扰较强，基于噪点分布呈跳跃性的特点，本文提出基于最长连续轮廓线均值获取料层高度。既提取出每个区域最长连续轮廓线，并判断像素高度差≤2 连续点个数，以最长连续轮廓线均值作为该区域料层高度值，最终提取的料层高度结果如图 7(d) 所示。



(a) 料层图像；(b) 料层结构纹理分解图；(c) 料层灰度图像轮廓线提取结果；(d) 料层分区高度提取结果

图 7 烧结料层高度信息提取结果

Fig. 7 Extraction results of sinter layer height information

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

2　烧结完成度智能识别方法

2.1　烧结红层图像浅层特征提取

根据专家经验知识可知，烧结料燃烧层在烧结机尾处的高度信息是判断烧结完成度的重要依据，燃烧层几乎消失说明烧结混合料过烧，燃烧层过高则表明烧结混合料欠烧(图 8)。因此本文设计并提取出燃烧层高度占比分布等特征来表征烧结完成度。

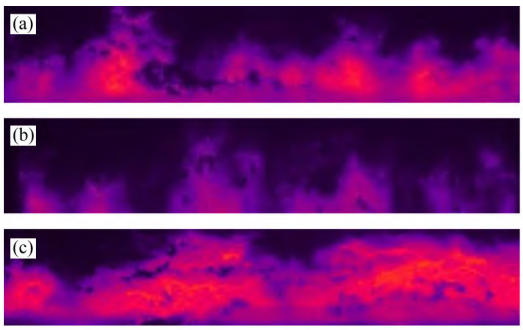
已提取的烧结红层 ROI 图像中包括料层已燃烧完成的部分，定义为完成层；正在燃烧的部分，定义为燃烧层；以及完成层与燃烧层之间的燃烧火焰等部分，定义为过渡层。

本文基于图像对比度调节分离出烧结完成层、燃烧层和过渡层(图 9)。给定阈值 t 和对比度增量 $c(\ >0)$，新的图像 RGB 分量:

$$V'_{\mathrm{RGB}} = V_{\mathrm{RGB}} + (V_{\mathrm{RGB}} - t) \times \left(\frac{255}{1-c} - 1\right) \qquad (10)$$

其中，V_{RGB}为原来的图像 RGB 分量，V'_{RGB}为新的图像 RGB 分量。

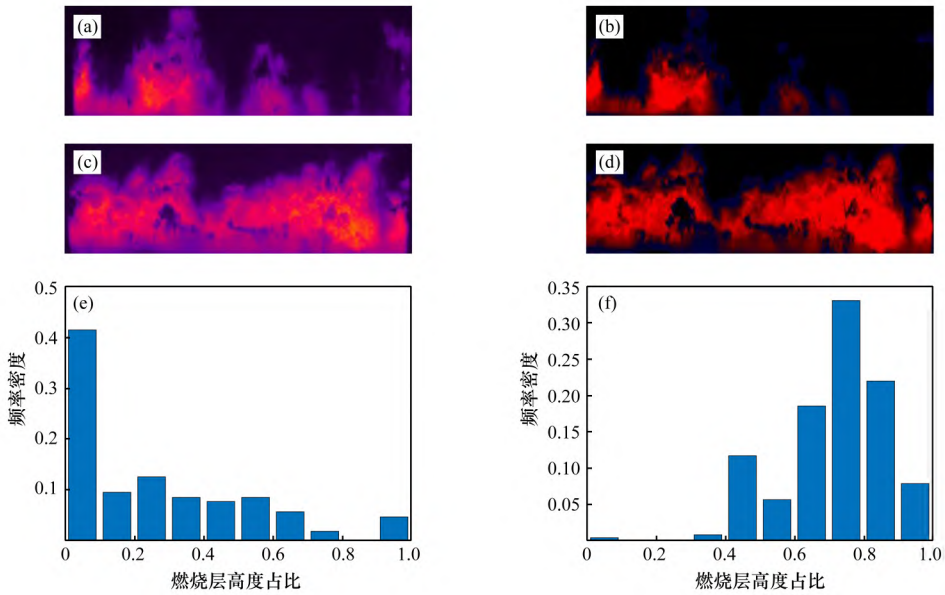
通过提取的料层高度信息，计算图像每列燃烧层高度占比(PB)，获取 PB 直方图分布(PBH)，如图 9 所示，同时获取 PB 的平均值、最大值和最小值等数学统计特征，将这些特征统称为红层高度占比特征(PBF)。



(a) 正常；(b) 过烧；(c) 欠烧

图 8　不同烧结完成度示例

Fig. 8　Examples of different sintering competition



(a) 红层图像 1；(b) 图像 1 分层结果；(c) 红层图像 2；(d) 图像 2 分层结果；(e) 图像 1PBH 可视化；(f) 图像 2PBH 可视化

图 9　不同完成度 PBH 特征对比

Fig. 9　Comparison of PBH characteristics for different completion

2.2　烧结红层图像深层特征提取

深度学习方法可提取出图像潜在或抽象的特征，本文基于 ResNet50 提取出图像深层特征，进一步表征烧结完成度。

ResNet50 包含 4 层 Bottleneck，即 conv2_x，conv3_x，conv4_x，conv5_x，并用全局平均池化层代替全连接层。由于全局平均池化不保留图像位置关系，而燃烧层位置关系是烧结完成度识别的重要依据，同时考虑最后的特征向量大小和尽可能获取深层特征等因素，本文以 conv5_x 即第 4

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

个 Bottleneck 输出的特征作为深层特征，并用全连接层代替全局平均池化。

假设输入图像为 $W \times H$，经过 $m-1$ 层 Bottleneck 后，得到特征向量 $\boldsymbol{X}_{\text{convm_x}} = [X_1, X_2, \cdots, X_n]$，其中 $n = 2^{m+6}$，$X_i \in R^{w \times h}$，$w = W/2^m$，$h = H/2^m$。经过全连接层，特征向量转变为 $\boldsymbol{X}'_{\text{linear}} = [X'_1, X'_2, \cdots, X'_n]$，$X'_i \in R^{w' \times h'}$，$w' = w$，$h' = 1$。

2.3 基于 DS-CEFNet 烧结完成度智能识别模型

基于 ResNet50 第四个 Bottleneck 即 conv5_x 提取的图像特征为深层视觉特征，手工设计的结构亮度分布特征和燃烧层高度占比分布等特征为浅层视觉特征，不同层级的视觉特征均包含烧结完成度特征信息。因此本文提出一种深浅特征协同嵌入融合网络(deep-shallow features co-embedding for feature fusion network，DS-CEFNet)，以 ResNet50 为骨干网络，协同嵌入手工设计的浅层特征与图像深层特征进行融合，以实现烧结完成度精准识别。

首先对手工特征进行卷积操作，扩充手工特征通道数并与深层特征对应，得到 $\boldsymbol{C} = [C_1, C_2, \cdots, C_n]$，其中 $n = 2^{m+6}$，$C_i \in R^{l \times 1}$，l 为手工特征数据长度。将提取的深层特征 $\boldsymbol{X}'_{\text{linear}}$ 与手工特征 $\boldsymbol{C}$ 进行拼接，得到 $\boldsymbol{F} = [F_1, F_2, \cdots, F_n]$，其中 $F_i \in R^{L \times 1}$，$L = l + h'$，最后对融合特征 F 进行分类预测，网络结构如图 10 所示。

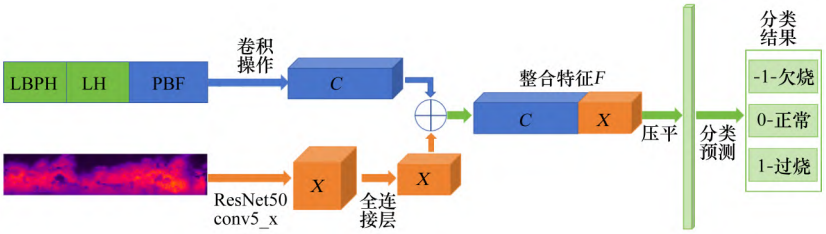


图 10 DS-CEFNet 结构可视化

Fig. 10 Visualization of DS-CEFNet structure

3 试验结果与讨论

为验证本文所提方法的准确性和有效性，在某钢厂 3#烧结厂烧结机尾安装红外热像仪，以 5 s 时间间隔拍摄机尾烧结料截面红外热图像，获取 3 115张红外热图像，并根据专家经验知识获取关键帧图像工况标签，将烧结完成度划分为过烧、欠烧、正常，最终共获取 280 张标注数据。

3.1 评价指标

本文通过准确率(A)、精确率(P)、召回率(R)和 $F1$(精确率和召回率的加权调和平均值)指标进行模型性能评价，表达式如下。

$$A = \frac{C_{\text{TP}} + C_{\text{TN}}}{C_{\text{TP}} + C_{\text{TN}} + C_{\text{FP}} + C_{\text{FN}}} \times 100\% \tag{11}$$

$$P = \frac{C_{\text{TP}}}{C_{\text{TP}} + C_{\text{FP}}} \times 100\% \tag{12}$$

$$R = \frac{C_{\text{TP}}}{C_{\text{TP}} + C_{\text{FN}}} \times 100\% \tag{13}$$

$$F1 = \frac{2 \times P \times R}{P + R} \times 100\% \tag{14}$$

对于每一个类别而言，C_{TP} 表示模型识别为该类别且真实值为该类别的样本数，C_{FP} 表示模型识别为该类别且真实值非该类别的样本数，C_{TN} 表示模型识别为其他类别且真实值非该类别的样本数，C_{FN} 表示模型识别为其他类别且真实值为该类别的样本数。$F1$ 表达式中，P 表示精确率，R 表示召回率。

3.2 关键帧识别试验方法与结果

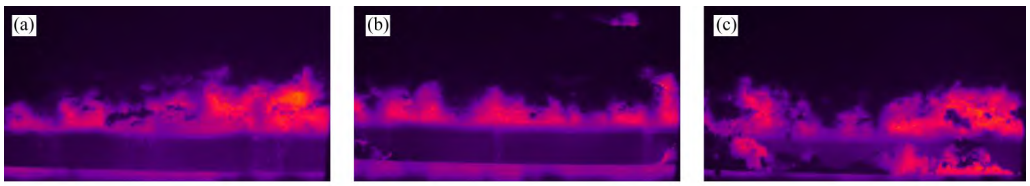
将红外热图像数据划分为起始帧和其他，以 7∶3的比例构建训练集和测试集，基于 ResNet50 进行起始帧识别，最终测试准确率为 0.83。

将提取的结构亮度分布特征输入 DCP 聚类模型，类别数设置为 3，初步获取受扬尘干扰较少，红层完整清晰的图像。

基于识别出的起始帧图像，划分出烧结机尾落料的图像周期序列，在基于 DCP 聚类的目标类集合中，提取每个周期内最靠前的图像作为该周期的关键帧图像，获取的关键帧图像如图 11 所示。

由图 11 可以看出，本文提出的双阶段关键帧提取方法能有效提取出受扬尘干扰较少、红层完整清晰的图像，实现关键帧精准提取。

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net



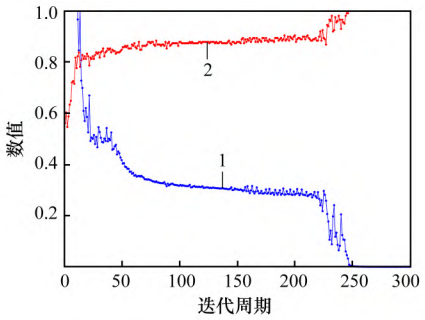
（a）第 1 个周期关键帧；（b）第 2 个周期关键帧；（c）第 3 个周期关键帧

图 11　关键帧提取结果

Fig. 11　Results of keyframe extraction

3.3　烧结完成度智能识别试验方法与结果

本文以 7∶3的比例将关键帧标注数据集划分为训练集和测试集。对输入图像进行 resize，线性采样大小为 64 ×64 的正方形，并进行标准化，与提取的结构亮度分布和燃烧层高度分布等特征数据一起输入 DS-CEFNet。初始学习率设置为 0.001，并对学习率的更新运用‘poly’学习率策略[18]。采用交叉熵损失作为损失函数，最终分类结果以 -1 表征欠烧工况，0 表征正常工况，1 表征过烧工况。训练结果如图 12 所示。由图 12 可以看出，融合浅层特征和深层特征的 DS-CEFNet 最终训练结果损失完全降为 0，准确率也达到 1。

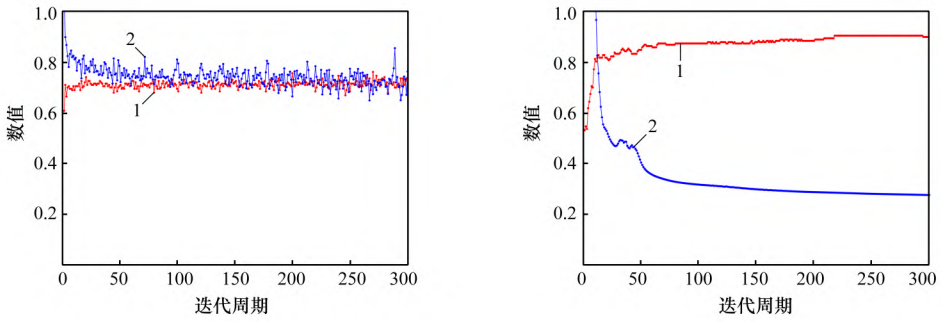


1—准确率；2—损失值。

图 12　基于 DS-CEFNet 烧结完成度智能识别训练结果

Fig. 12　Training results of intelligent recognition of sintering completion based on DS-CEFNet

为验证融合特征对烧结完成度智能识别的优越性，本文进行了两组消融实验，分别采用 DS-CEFNet 的图像深层特征分支和手工设计浅层特征分支进行试验，试验结果如图 13 所示。



（a）图像深层特征分支训练结果；（b）手工设计浅层特征分支训练结果

1—准确率；2—损失值。

图 13　DS-CEFNet 消融试验训练结果

Fig. 13　Training results of DS-CEFNet ablation test

由于烧结机尾红外热图像存在低对比度、弱纹理、强辐射等特性，不同完成度对应的图像相似度较高，同时由于数据采集困难，获取的数据有限，导致传统深度学习方法，即 DS-CEFNet 图像深层特征分支在模型训练时无法较好地收敛。仅采用手工设计的浅层特征数据进行完成度识别，训练的收敛效果和准确率也不如融合特征模型。

本文利用训练好的模型进行测试，结果见表 1 ~4。

表 1　不同输入数据完成度识别准确率测试结果

Table 1　Recognition accuracy test results of sintering competition for different input data

输入数据	方法	准确率/%
图像 + 手工设计特征	DS-CEFNet	96.43
图像	DS-CEFNet 图像分支	66.67
手工设计特征	DS-CEFNet 数据分支	86.91

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

表2 不同输入数据完成度识别精确率测试结果

Table 2 Recognition precision test results of sintering competition for different input data

输入数据	方法	P/%			平均 P/%
		欠烧(-1)	正常(0)	过烧(1)	
图像+手工设计特征	DS-CEFNet	92.31	96.97	100.00	96.43
图像	DS-CEFNet 图像分支	0	66.67	0	22.22
手工设计特征	DS-CEFNet 数据分支	83.33	86.49	100.00	89.94

表3 不同输入数据完成度识别召回率测试结果

Table 3 Recognition recall test results of sintering competition for different input data

输入数据	方法	R/%			平均 R/%
		欠烧(-1)	正常(0)	过烧(1)	
图像+手工设计特征	DS-CEFNet	100.00	98.47	71.43	89.97
图像	DS-CEFNet 图像分支	0	100.00	0	33.33
手工设计特征	DS-CEFNet 数据分支	41.67	98.47	57.14	65.76

表4 不同输入数据完成度识别 *F*1 测试结果

Table 3 Recognition F1-score test results of sintering competition for different input data

输入数据	方法	F1/%			平均 F1/%
		欠烧(-1)	正常(0)	过烧(1)	
图像+手工设计特征	DS-CEFNet	96.00	97.71	83.33	92.35
图像	DS-CEFNet 图像分支	0	80.00	0	26.67
手工设计特征	DS-CEFNet 数据分支	55.55	92.09	72.73	73.46

由表1~4可知，仅采用图像数据基于传统深度学习方法进行完成度识别十分困难，无法识别出异常完成度，即欠烧和过烧；而仅采用手工设计的特征数据进行完成度识别时，其性能不如融合特征模型，说明融合图像深层特征与手工设计的浅层特征对提升烧结完成度智能识别精确性具有重要作用，本文提出的DS-CEFNet模型能有效实现烧结完成度精准识别。

4 结 论

烧结完成度精准识别是提升烧结过程稳定性和生产效率，降低烧结生产能耗的重要前提。针对烧结完成度难以智能识别的难题，本文提出了基于烧结机尾红外热图像特征的烧结完成度智能识别模型，具体结论如下。

(1) 提出了双阶段关键帧提取方法，有效提取出受扬尘干扰较小、红层清晰完整的关键帧图像。

(2) 设计并提取烧结燃烧层高度占比分布等图像浅层视觉特征，同时基于ResNet50提取出图像深层视觉特征，解决了烧结完成度特征表征问题。

(3) 提出了DS-CEFNet模型，能有效融合图像深层特征和手工设计的浅层特征，实验表明融合深层与浅层视觉特征有利于实现烧结完成度精准识别，最终识别准确率达96.43%。

参考文献:

[1] 徐志豪,张海峰,潘冬. 基于多源信息融合的烧结混合料水分智能在线检测方法[J]. 烧结球团,2022,47(4):18-24;42.
XU Zhihao,ZHANG Haifeng,PAN Dong. Intelligent on-line detection method of sintering mixture moisture based on multi-source information fusion[J]. Sintering and Pelletizing,2022,47(4):18-24;24.

[2] 朱占军,王明侠,王春林. 基于质量预测与统计分析的烧结过程性能监控系统研究[J]. 烧结球团,2016,41(1):7-11.
ZHU Zhanjun, WANG Mingxia, WANG Chunlin. Research on performance monitoring system of sintering process based on quality prediction and statistical

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

analysis [J]. Sintering and Pelletizing, 2016, 41(1): 7 – 11.

[3] 杜胜. 烧结过程多时间尺度工况识别与热状态参数智能控制 [D]. 武汉: 中国地质大学(武汉), 2021.
DU Sheng. Operating mode recognition with multiple time scales and intelligent control of thermal state parameters for sintering process [D]. Wuhan: China University of Geosciences(Wuhan), 2021.

[4] CHEN Xin, CHEN Xiaoxia, WU Min, et al. Modeling and optimization method featuring multiple operating modes for improving carbon efficiency of iron ore sintering process [J]. Control Engineering Practice, 2016, 54: 117 – 128.

[5] HU Jie, WU Min, CHEN Xin, et al. A multilevel prediction model of carbon efficiency based on the differential evolution algorithm for the iron ore sintering process [J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8778 – 8787.

[6] DU Sheng, WU Min, CHEN Luefeng, et al. Operating mode recognition of iron ore sintering process based on the clustering of time series data [J]. Control Engineering Practice, 2020, 96: 104296.

[7] WU Chen, WANG Fubin, CHEN Xianzhong, et al. RGB color decomposition and image feature extraction of flame image in rear of sintering machine [C]//2017 36th Chinese Control Conference(CCC). Dalian: Technical Committee on Control Theory, Chinese Association of Automation(TCCT), 2017: 5460 – 5463.

[8] BULNES F G, USAMENTIAGA R, GARCIA D F, et al. Monitoring sintering burn-through point using infrared thermography [J]. Sensors, 2013, 54: 117 – 128.

[9] JIANG Zhaohui, GUO Yuhao, GUI Weihua, et al. Polymorphic measurement method of FeO content of sinter based on heterogeneous features of infrared thermal images [J]. IEEE Sensors Journal, 2021, 21(10): 12036 – 12047.

[10] PAN Dong, JIANG Zhaohui, GUI Weihua, et al. Influence of dust on temperature measurement using infrared thermal imager [J]. IEEE Sensors Journal, 2020, 20(6): 2911 – 2918.

[11] HE Kaiming, ZHANG Yuxiang, REN Shaoqing, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas: Institute of Electrical and Electronics Engineers(IEEE), 2016: 770 – 778.

[12] LIN Weisi, KUO J C. Perceptual visual quality metrics: A survey [J]. Visual Communication and Image Representation, 2011, 22(4): 297 – 312.

[13] OJALA T, PIETIKAINEN M, MAENPAA T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971 – 987.

[14] AHONEN T, HADID A, PIETIKAINEN M. Face recognition with local binary patterns [C]//2004 European Conference on Computer Vision(ECCV). Prague: European Computer Vision Association(ECVA), 2004: 469 – 481.

[15] FRAZAR R A, GEISLER W S. Local luminance and contrast in natural images [J]. Vision Research, 2006, 46(10): 1585 – 1598.

[16] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks [J]. Science, 2014, 344(6191): 1492 – 1496.

[17] LEE H, JEON J, KIM J, et al. Structure-texture decomposition of images with interval gradient [J]. Computer Graphics Forum, 2017, 36(6): 262 – 274.

[18] CHEN L, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transaction on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834 – 848.

(C)1994-2024 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net