基于 Unet 网络的烧结混合料粒度检测模型

刘 颂[1,3,4]，张 振[2]，赵 军[3]，张炯明[4]，张琳琛[5]，刘小杰[5]，李福民[5]，吕 庆[5]

（1. 唐山学院 人工智能学院，河北 唐山 063000；2. 东北大学 冶金学院，辽宁 沈阳 110819；
3. 唐山钢铁集团有限责任公司，河北 唐山，063000；4. 北京科技大学 冶金新技术国家重点实验室，北京 100083；
5. 华北理工大学 冶金与能源学院，河北 唐山 063017）

摘要：目前烧结生产中混合料粒度主要通过人工检测方式获取，该操作方式不连续，且准确度有待提高，难以确定粒度分布与烧结生产参数之间的定量关系。因此，本文提出一种烧结混合料粒度检测模型，该模型采用 CCD 工业相机和工业光源作为混合料图像的主要采集设备；在图像预处理过程中，使用加权平均法用于图像的灰度化处理；在粒度检测模型构建中，应用 Unet 网络对烧结混合料图像进行分割处理。结果表明：工业光源的使用提高了采集时的亮度，也能在最大程度上降低外界光线的影响，确保烧结混合料图像的稳定性；图像预处理有助于分辨烧结混合料的颗粒特征，在此基础上，使用中值滤波和直方图均衡化更适合表征图像中混合料颗粒的边缘，并将颗粒内部特征模糊化，对噪声及其他不利因素有很好的去除效果；训练好的 Unet 网络分割模型对烧结混合料的分割准确率达到 91% 以上，分割精度误差低于 9%，对混合料图像的分割效果较好。该模型的应用可为烧结生产提供及时、准确的粒度分布数据，有助于提高烧结混合料粒度检测效率，帮助企业提升经济效益和社会效益。

关键词：铁矿；烧结混合料；粒度检测；图像预处理；图像分割；Unet 网络

中图分类号：TF046.4 **文献标识码**：A **文章编号**：1000－8764(2024)02－0008－09

doi：10.13403/j.sjqt.2024.02.018

Particle size detection model of sintering compound based on Unet network

LIU Song[1,3,4], ZHANG Zhen[2], ZHAO Jun[3], ZHANG Jiongming[4], ZHANG Linchen[5], LIU Xiaojie[5], LI Fumin[5], LÜ Qing[5]

(1. College of Artificial Intelligence, Tangshan University, Tangshan 063000, Hebei, China; 2. School of Metallurgy, Northeastern University, Shenyang 110819, Liaoning, China; 3. Tangshan Iron and Steel Group Co., Ltd., Tangshan 063000, Hebei, China; 4. State Key Laboratory of New Technology of Iron and Steel Metallurgy, University of Science and Technology Beijing, Beijing 100083, China; 5. College of Metallurgy and Energy, North China University of Science and Technology, Tangshan 063017, Hebei, China)

Abstract: At present, the particle size of compound in sintering production is mainly obtained by manual inspection, its operation mode is not continuous and accuracy needs to be improved, and it is difficult to determine the quantitative relationship between the particle size distribution and the sintering production parameters. Therefore, a particle size detection model of sintering compound is proposed, which adopts CCD industrial camera and industrial light source as the main acquisition equipment of sintering compound image; in the image pre-processing process, the weighted average method is used for the graying of the image; in the construction of the particle size detection model, the Unet network is applied to

收稿日期：2022－12－07；**修回日期**：2023－01－19

基金项目：唐山市应用基础研究科技计划资助项目(21130233C)；唐山市人才资助项目(B202302007)

作者简介：刘 颂(1990—)，男，博士，讲师，从事铁前大数据分析、冶金智能化等方面的研究。

通信作者：赵 军(1970—)，男，博士，正高级工程师，从事冶金工艺与理论、冶金智能化等方面的研究工作。

the segmentation of the sintering compound image. The results show that the use of industrial light source can improve the brightness when collecting, and also reduce the influence of external light to the greatest extent, so as to ensure the stability of sintering compound image. Image preprocessing is helpful to distinguish the particle characteristics of sintering compound. On this basis, median filtering and histogram equalization are more suitable to characterize the edges of sintering compound particles in the image and blur the internal characteristics of particles, which have a good effect on removing noise and other unfavorable factors. The trained Unet network segmentation model for sintering compound has segmentation accuracy of more than 91% and segmentation accuracy error of less than 9%, which has a good segmentation effect on the compound image. The application of this model can provide timely and accurate particle size distribution data for sintering production, help improve the efficiency of particle size detection of sintering compound, and help enterprises improve economic and social benefits.

Key words: iron ore; sintering compound; particle size detection; image preprocessing; segmentation; Unet network

烧结混合料的粒度分布是影响混料机的转速、制粒水分、料层的透气性以及最后成品烧结矿的破碎筛分指数等参数的重要因素，也是实际生产和试验研究的主要对象。传统烧结混合料粒度检测是通过工人从配料带上对混合料采集取样进行筛分称重，得到混合料的粒度分布结果。这种操作方式统计速度慢，操作过程危险系数高，结果存在滞后性。随着钢铁企业向“智能化”、“绿色化”积极转型，各种智能识别和预测技术在工厂内得到推广和应用。对于烧结工序而言，采用烧结混合料粒度智能检测模型逐渐代替传统人工操作方式，能够极大完善烧结生产智能制造体系，优化工作环境，提高混合料粒度识别效率和生产经济效益[1-2]。

目前，图像识别在烧结混合料的粒度检测领域的应用较少，多集中在生球直径、高炉燃料和矿石类别的区分以及粒度检测中，涉及的技术主要包括传统机器视觉和深度学习等方法。在传统机器视觉方面，覃德波等[3]采用四重增强和高斯滤波方法对造球机的出球图像进行增强和降噪，以霍夫圆检测算法进行生球粒度识别，应用计算机视觉技术开发了一种生球粒度识别系统，提高了铁矿球团制备过程中粒度大小和分布检测的准确性和即时性。白志城等[4]利用 CCD 相机采集到球团矿的颗粒图像，使用滤波、阈值、增强、优化等预处理方案，解决了图像噪声多、色彩暗的问题，随后提出一种基于自适应标记的优化分水岭分割算法，实现了球团矿的图像分割，并得到了球团矿的粒度分布统计结果，为球团矿生产提供便利。曾小信等[5]在视觉检测系统中，融合高斯混合模型的图像分割、边缘提取算法以及最小二乘法的圆周拟合方法，实现了生球粒度的自动识别。BAI 等[6]提出了一种煤炭颗粒检测方法，利用分水岭算法、近邻算法和凸壳法等进行图像分割，并通过合并大小区域来分离相互粘连的颗粒，该方法为快速分析煤炭颗粒的尺寸分布提供了一种新策略。传统的机器视觉技术为颗粒粒度的自动测量提供了一种有效方法，但同样存在一些局限性，比如检测方法的适应性不强，算法模型在进行图像检测时，特征的好坏直接影响着模型的泛化能力；图像特征的提取严重依赖人工判断，但是如何更好地进行特征设计对于人类专家而言并非易事，这导致检测结果也具有一定的主观性[7]。

在深度学习方面，肖成勇等[8]针对铁矿球团边缘分割与检测问题，以 30 张球团图像为基础，建立了含有注意力机制的深度学习模型，分割结果表明此模型比传统的机器视觉模型更加高效准确。LIU 等[9]应用深度学习和迁移学习等技术构建了煤矿识别模型，通过卷积层提取煤矿图像中蕴含的特征，有效解决了混合煤堆中烟煤、无烟煤和焦炭等煤矿的区分问题。FREI 等[10]为了分析团聚、烧结或封闭的初级粒子的分布，提出并测试了一种基于深度学习的自动化初级粒子检测方法。万川等[11]提出了一种基于改进 P-Unet 模型的岩屑颗粒识别方法。该方法基于 Unet 模型结构，采用金字塔池化模型聚合了不同区域的特征信息，并对模型添加了残差网络，达到了提高岩屑颗粒识别准确率、优化模型结构和计算效率等的目标。近年来，随着深度学习算法的快速发展，由于其

强大的自主学习能力，基于该算法构建的图像处理识别模型的泛化能力得到极大提升，模型检测结果的科学性和准确率极大改善[12-13]。

为此，本文以烧结现场采集的多组混合原料为基础，利用实验室搭建的图像采集平台构建混合料粒度图像基础数据集，结合混合料图像的具体特征，对粒度图像进行降噪及预处理；并采用深度学习 Unet 网络算法建立烧结混合料粒度检测模型，实现混合料粒度的准确识别及统计分析，提高烧结混合料粒度的检测频次及效率，为冶金工业提供高效、自动化的烧结混合料粒度检测及预警解决方案。

1 模型构建方法

1.1 模型构建流程

为完善当前烧结生产智能控制体系，本文运用粒度检测领域内的多种方法，并结合烧结混合料自身的具体特征，实现对烧结混合料粒度的检测。烧结混合料粒度检测模型构建流程如图 1 所示。由图 1 可知，应用深度学习模型(Unet 网络)学习图片中的粒度分布特征，从而建立识别模型，达到在混合料图片中快速识别粒度分布的目的。建模主要包括三个步骤：① 采集烧结混合料图像：包括硬件设施准备、混合料图像特征分析和图像预处理；② 建立混合料粒度检测数据集：包括混合料图像背景和颗粒的颜色处理，以及图像标签的设置；③ 建立烧结混合料粒度检测模型：基于处理后的数据集，使用 Unet 网络构建粒度检测模型，识别混合料图像中的粒度分布情况，并与人工统计的粒度分布结果进行对比分析。

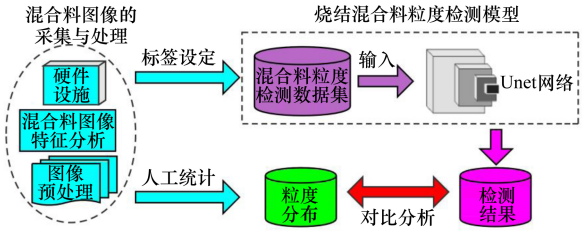


图 1 烧结混合料粒度检测模型构建流程

Fig. 1 Particle size detection model construction process of sinter raw mixture

1.2 图像分析处理与建模

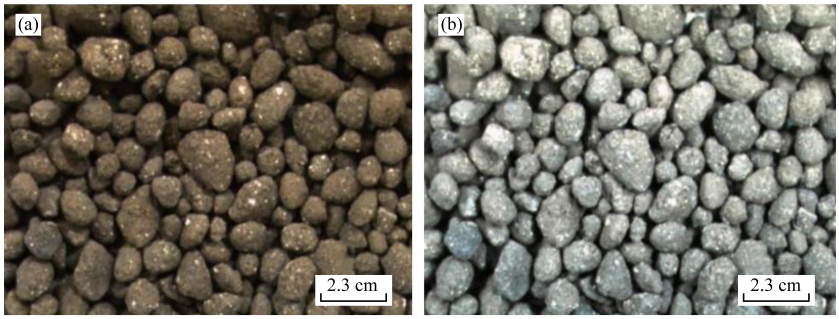
1.2.1 烧结混合料的图像特征

图像特征分析主要包括图像噪声类型和混合料颗粒形状。烧结混合料图像的噪声类型主要有高斯噪声、椒盐噪声(脉冲噪声)，其产生的主要原因是图像获取过程中相机传感器的温度变化，以及图像在传输过程中受到的各种干扰和影响。

使用图像采集设备拍摄到的烧结混合料颗粒图像如图 2 所示。由图 2 可知：烧结混合料的形状大多数近似于椭圆形或圆形；与近似圆形的球团生球相比，烧结混合料中不规则的多边形粒度分布更加突出，同时混合料之间重叠、遮挡，以及相互粘连的现象更加严重，这些都是粒度分割和识别时需要考虑的重点。在最后获取烧结混合料颗粒粒度时，还要确定采用哪种粒度近似形状来拟合并确定大小。

1.2.2 图像预处理

图像预处理是为了提高图像的对比度，突出图像中烧结混合料之间的区别，方便卷积神经网络对混合料图像特征进行学习。此外，经过预处理的图像也会降低网络训练的时间与计算量。



(a) 自然光源；(b) 工业光源。

图 2 烧结混合料图像

Fig. 2 Image of sinter raw mixture

（1）灰度处理。将混合料图像转化为灰度图，如图 3(a)所示。图像灰度转化过程采用三通道加权平均方法，如式(1)所示。

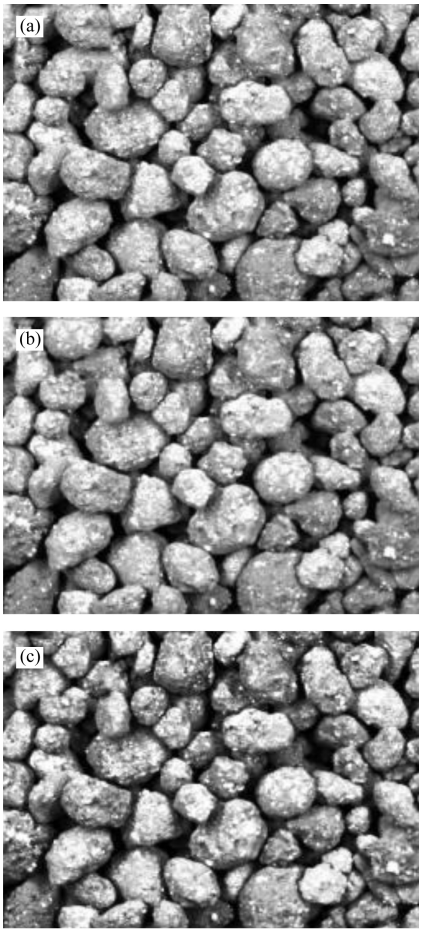
$$Gray(i,j) = rR(i,j) + gG(i,j) + bB(i,j)$$
$$r + g + b = 1 \quad (1)$$

式中：r、g、b 分别为红色、绿色、蓝色通道加权分量，其取值分别为 0.299、0.587 和 0.144；$R(i,j)$、$G(i,j)$、$B(i,j)$ 分别代表像素点的红、绿、蓝三个分量；$Gray(i,j)$ 为像素点的灰度值。

将 r、g 和 b 三个权值设置为上述值的目的是为了更加符合人眼的感光特点；而且，经灰度转化后的图像不仅能够使卷积神经网络输入层的计算量比原来降低三分之一，还能更加清晰地展示混合料颗粒内部和间隙的颜色差异，增强图像携带的混合料颗粒的特征信息。

（2）中值滤波处理。在采集完混合料图像之后，图像中通常会存在噪声点的干扰，这不仅会影响卷积神经网络对混合料颗粒特征的学习，还可能导致算法判断失误，出现过分割的现象。由于中值滤波对脉冲噪声有良好的滤除作用，特别是在滤除噪声的同时，能够保护信号的边缘，使之不被模糊。因此，本文使用中值滤波技术来降低图像中的噪声。滤波处理结果如图 3(b)所示。

（3）直方图均衡化处理。图像采用中值滤波后，虽然降低了噪声，但也降低了上下两层中混合料颗粒亮度的差值，针对这种特殊的颗粒分割特征，本文采用了直方图均衡化方法，增加了图像颗粒与间隙间的对比度，使特征更加明显。直方图均衡化处理结果如图 3(c)所示。



（a）灰度处理；（b）中值滤波处理；（c）直方图均衡化处理。

图 3　图像预处理结果

Fig. 3　Image pre-processing results

1.2.3　Unet 网络结构设计

粒度检测模型以 Unet 网络为基础架构，如图 4 所示。该网络由编码器和解码器两部分网络组成，主要涉及局部感受野、权值共享、卷积层、池化层和全连接层等结构和方法。编码器网络类似于卷积神经网络，包括重复使用的两个 3×3 卷积、线性整流单元(ReLU 激活函数)和一个 2×2 的最大池化层，算法步长设置为 2，用于下采样操作。在编码阶段，每个下采样操作都会使特征通道的数量加倍；最大池化操作则有助于捕获大型输入图像上下文中具有的紧凑特征，使整个编码

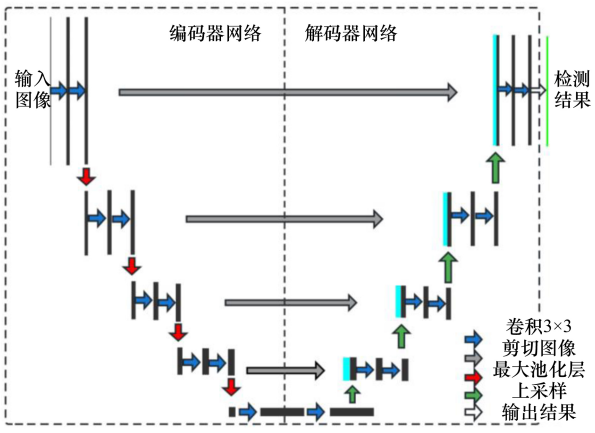


图 4　Unet 网络结构

Fig. 4　Unet network structure

阶段的特征图像被传输到相应的解码阶段并与上采样的特征图像进行融合拼接。在解码阶段的每一步中，特征通道的数量都会减少一半，该算法

将结果与来自编码阶段的特征图像进行融合，最后通过 1 ×1 的卷积层输出卷积层。

2 模型构建步骤

2.1 图像采集设备搭建

图像采集设备如图 5 所示。由图 5 可见，在图像采集过程中，将工业相机镜头与采集目标的距离设定为 150 mm，将工业光源支架与采集目标的距离设定为 120 mm，设置左侧光源向右下方照射，右侧光源向左下方照射。

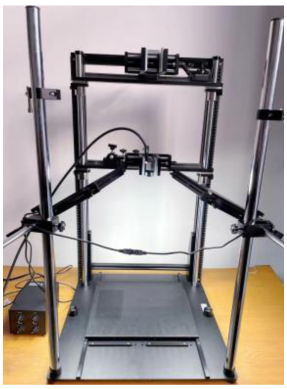


图 5 图像采集设备

Fig. 5 Image acquisition device

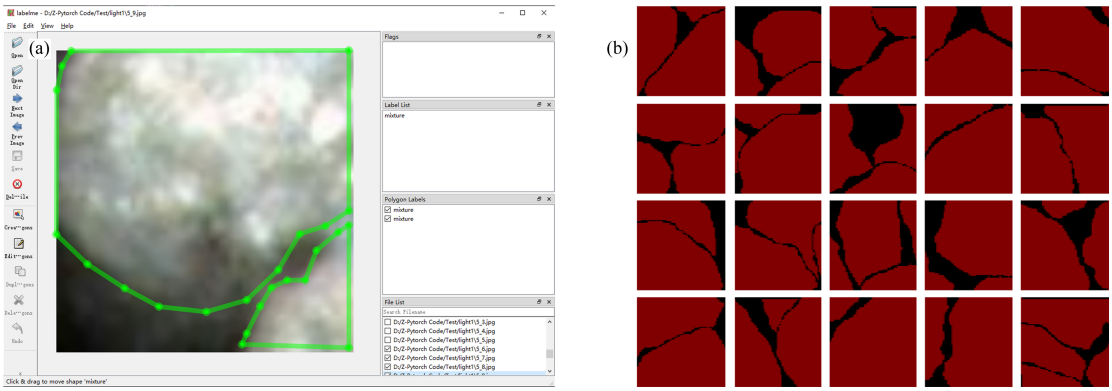
2.2 标签图像与数据集制作

图像数据是机器视觉识别研究中最重要的因素之一。以往的研究通常过于关注于模型或算法本身，事实上，图像数据在视觉任务中的作用至关重要。图像数据集是开展图像识别、目标检测等人工智能任务的基础，构建特定任务的训练数据集是深度学习项目的第一步。本文采用的 Unet 网络是有监督的卷积神经网络算法，这类算法需要在训练中学习带标签的图像样本。

由于烧结混合料颗粒图像中存在需要大量标注的目标信息，本文借助标注工具对烧结混合料图像进行标签标注操作。图像中涉及的一些特征属性可以转化为数字化表达的形式，同时也扩充了数据的特征。卷积神经网络数据集标签的制作，需要对图像进行像素级分类处理，即一个像素点对应一个标签，用来表示烧结混合料颗粒的间隙或内部。

本文采用 Labelme 软件对于图像标签进行标注，使用该软件可以实现创建定制化标注任务或执行图像标注任务。该软件是一个在线的 JavaScript 图像标注工具，由麻省理工大学的计算机科学和人工智能实验室开发。使用 Labelme 标注后的标签图像以及标签数据会生成对应的 JSON 文件，并被储存到当前目录下，之后再进行批量的“json_to_dataset”操作，进而得到烧结混合料图像的数据集。在图像标定过程中，混合料的间隙被标定为黑色，并作为背景；颗粒内部区域则被标记为红色。对于处理后的图像数据集而言，每个目标区域的完整性对之后的卷积神经网络的学习与预测至关重要，所以在使用“json_to_dataset”操作进行批量处理时，该软件会自动将标注线扩大 2 个像素，避免在标注时人为操作的误差而影响图像数据集的质量。使用 Labelme 软件对图像进行标注的界面如图 6(a)所示，使用“json_to_dataset”操作处理后的结果如图 6(b)所示。

对于已经制作好的烧结混合料图像数据集，还需要进行数据集的格式转化，将数据集转化为



(a) 标注界面；(b) 处理结果

图 6 标签图像与数据集制作

Fig. 6 Label image and data set making

网络训练需要的格式。本文采用 VOC 数据集格式，该格式是构建卷积神经网络模型的常用格式。

2.3　模型训练

以预处理后的烧结混合料颗粒图像为基础，选取 1 024 ×768 分辨率的图像样本作为 Unet 网络模型的训练数据。为了使烧结混合料图像数据得到充分的利用，将每张图像样本进行随机分割，将其处理为 64 ×64 尺寸大小的“补丁”(patch)，而不是将整张图像样本输入网络进行训练，这样每张图像样本可以获得(1 024 -64) ×(768 -64) = 675 840 个不同的 patch。依据烧结混合料图像分割的特性，经过分割处理后得到 patch 的绝大部分也都含有混合料的颗粒内部与颗粒间隙等特征，这使得网络对于样本特征能够充分地进行训练和学习。随机选取的部分分割效果如图 7 所示。

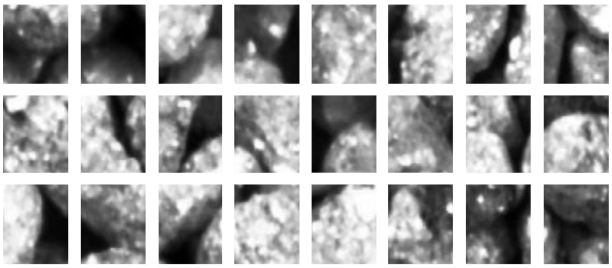


图 7　随机选取的部分图像样本的分割效果

Fig. 7　Segmentation effect of randomly selected partial image samples

本文输入 Unet 网络模型的数据形状为(64,64,64)，输入层经过三次池化操作之后又分别进行三次上采样和三次卷积操作，然后进入全连接层，最后在模型输出层得到的数据形状为(64,64 ×64,2)。Unet 网络模型训练过程在深度学习 Pytorch 框架中进行，网络结构相关参数：样本总数为 1.6×10^6 个；训练次数为 100 次；patch 大小为 64 ×64；批大小为 64。

Unet 网络模型的测试使用了与传统分割模型相同的图像样本，且没有将整张图像样本输入网络进行分割，而是采用滑动窗口的方式遍历整张图像样本得到多个 64 ×64 的 patch 作为输入，最后将每个输出的结果拼接起来，作为图像分割的结果。部分 patch 的分割效果如图 8 所示。

2.4　模型评价

为了对模型的性能进行综合评价，本文采用

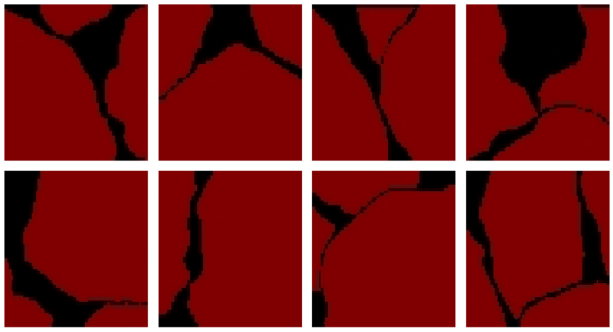


图 8　部分 patch 的分割效果

Fig. 8　Segmentation results of partial patch

分割准确率、分割精度误差和检测时间三个评价指标。

(1) 分割准确率。分割准确率是需要最先评价的指标。只有分割结果达到了相对较高的准确度，才能继续考虑检测时间和稳定性对分割性能的影响。将准确率 ρ_{AR}(%)作为分割准确率评价指标，计算方法如式(2)所示。

$$\rho_{AR}=\frac{N_d}{N_m}\times100\% \tag{2}$$

式中：N_d 为分割结果中检测到的烧结混合料颗粒轮廓数量，个；N_m 为图像中实际的烧结混合料颗粒数量，个。

(2) 分割精度误差。为评定分割的精准程度，从过分割和欠分割两个角度对模型性能进行评价。过分割指的是在分割结果中一个颗粒被分割为多个目标区域，而欠分割指的是在分割结果中多个颗粒被分割为一个区域。过分割和欠分割的情况可以用来反映分割精度。分割精度误差 ρ_{Error}(%)的计算方法如式(3)所示。

$$\rho_{Error}=\frac{N_{US}+N_{OS}}{N_{US}+N_{OS}+N_{CM}}\times100\% \tag{3}$$

式中：N_{OS}为过分割区域数量，个；N_{US}为欠分割区域数量，个；N_{CM}为正确分割区域数量，个。

为了将分割结果进行量化，还要对同一图像进行人工分割，对比人工分割结果与模型分割结果的连通区域面积，如果连通区域面积的误差小于 10% 则被判定为正确的分割区域。

(3) 检测时间。检测时间定义为从图像输入模型到完成分割操作，并输出分割结果的时间，用 T_d 表示。该值越小则表明模型的检测速度越快，反之则越慢。

3 模型分割效果与系统开发

3.1 模型分割效果

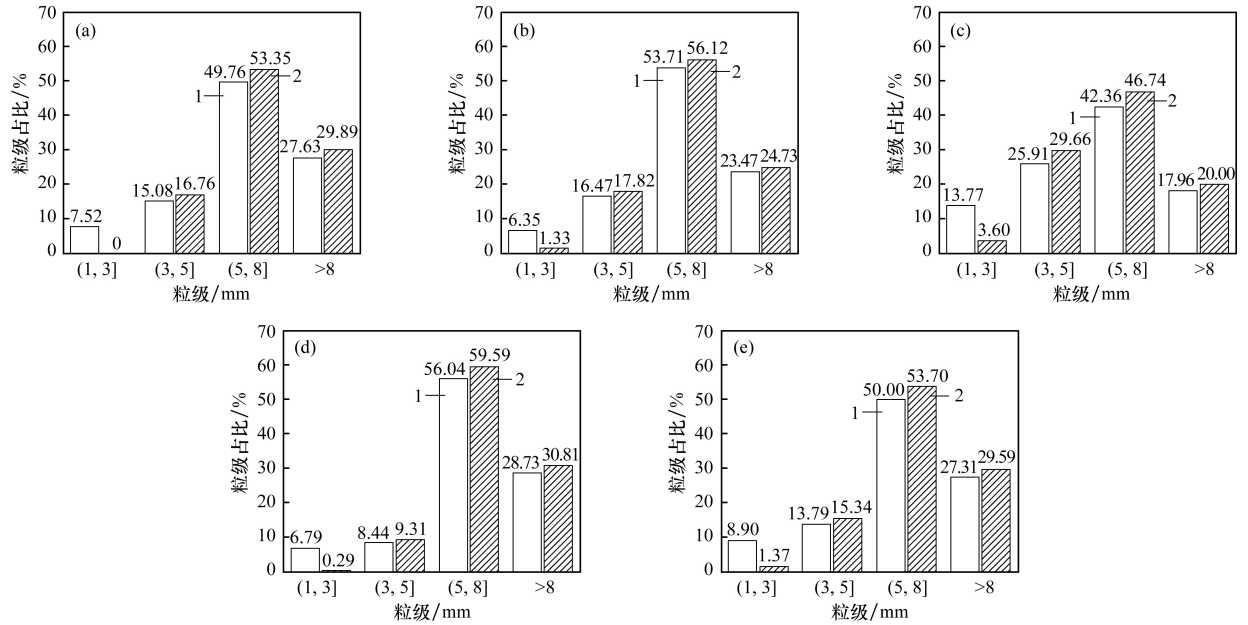
在模型测试过程中，基于人工统计和 Unet 网络模型计算得到的混合料平均粒度以及模型分割性能评价结果如表 1 所示。由表 1 可知，在 5 组测试的平均粒度计算结果中，人工统计结果和 Unet 网络模型计算结果得到的混合料平均粒度都分布在 5.0 ~ 6.5 mm 范围内，两种方式的误差在 0.28 ~ 0.36 mm 以内，平均误差为 5.44%，这表明 Unet 网络模型在平均粒度统计方面与人工统计结果的一致性，证明该模型具有较高的实际应用性；在 5 组测试中，Unet 网络模型的分割准确率平均为 91.16%，单组测试的分割准确率指标最低接近 90%，最高能够达到 92%，表明模型总体上可以实现将 91% 以上的烧结混合料颗粒轮廓精确分割；模型的分割精度误差平均为 8.55%，说明该模型在处理混合料颗粒图像时能够进行区域的正确分割；同时，Unet 网络模型的检测时间平均仅为 0.15 s，可在极短时间内准确识别、分割并输出粒度分布结果，能够极大提升现场检测效率，消除人工统计的滞后性影响。

表 1 人工统计和 Unet 网络模型计算的平均粒度与模型分割评价结果

Table 1 Average granularity and model segmentation evaluation results of manual statistics and Unet network model calculation

测试编号	人工统计结果/mm	算法计算结果/mm	误差/%	模型分割效果		
				ρ_{AR}/%	ρ_{Error}/%	T_d/s
1#	6.26	5.95	4.95	91.36	8.56	0.15
2#	6.09	5.89	3.35	93.70	6.63	0.18
3#	5.66	5.29	6.53	88.61	10.56	0.16
4#	6.42	6.13	4.45	92.03	7.14	0.13
5#	5.48	5.91	7.93	90.11	8.88	0.15
平均值	—	—	—	91.16	8.55	0.15

对 5 组测试的粒度检测结果进行分析，得到每组测试在不同梯度下的混合料粒度统计结果，如图 9 所示。由图 9 可知，在得到的混合料粒度分析结果中，Unet 网络模型与人工统计结果在(1,3] mm 区间内，且差别较大。这是由于小粒级存在噪声多、特征不明显、边缘信息模糊等问题，容易造成模型误检、漏检，导致模型检测效果变差。由于此粒级在混合料中占比较小，在模型的后续优化迭代升级中拟构建此粒级占比修正的专



测试编号：(a) 1#；(b) 2#；(c) 3#；(d) 4#；(e) 5#

1—算法统计；2—人工统计。

图 9 烧结混合料粒度识别测试结果

Fig. 9 Results of particle size identification test of sinter raw mixture

家规则库，以提高模型的检测精度。对于 3 mm 以上区间，算法和人工统计粒级分布的占比相差不大，整体分布趋势接近。在(3,5] mm 和大于 8 mm的区间内，两种方式的粒级分布占比统计结果基本一致，而在粒级分布最多的(5,8] mm 区间内，两种方式得到的粒级占比误差保持在 3% 以下。此结果表明，Unet 网络模型能够精确处理并分割不同粒级区间的混合料，并保持较强稳定性。

3.2　系统开发

基于烧结现场的实际需求，采用 Spring Boot 框架和 Java 编程语言开发烧结混合料粒度分析系统，该系统能够基于获取的混合料粒度图像，实时计算混合料的平均粒度及各个粒度范围的占比情况。烧结混合料粒度分析模块如图 10 所示。当某个粒度范围超过或低于专家设定的理想百分比区间时，该粒度范围会以红色字体标记进行预警提示；此外，该系统还具备历史数据导出功能，能够对历史某段时间分析的混合料粒度数据一键导出至 excel 表格中；同时能够对粒度分布历史数据进行可视化展示。烧结混合料粒度分布历史统计界面如图 11 所示，该界面采用柱状图形式将历史混合料粒度数据进行展示，并支持指定时间范围内粒度组成数据筛选及统计功能，可直观地表征当前混合料粒度的组成情况及变化规律。

4　结　论

（1）以实验室获取的烧结混合料颗粒图像为基础，采用 Unet 网络算法建立了一种智能化的烧结混合料粒度检测模型，该模型能够完成混合料粒度分布的及时、准确检测及预警，提高了烧结混合料粒度检测频次及效率，对优化烧结生产具有重要的指导意义。

（2）针对烧结混合料图像存在噪声、粒度形状不规则以及颗粒间重叠的问题，应用图像灰度转化、中值滤波和直方图均衡化等处理方式，提高了图像特征的表征能力；借助 Labelme 图像标注工具，完成了烧结混合料图像颗粒与间隙的标定，得到了用于模型训练的数据集。

（3）混合料粒度检测模型的测试及评估表明，该模型对混合料粒度分割的准确率达到 91% 以上；其在平均粒度及不同粒级区间的检测能力方面，与人工统计结果基本一致，特别是对大于 3 mm 粒级的分析能力，模型检测误差能控制在 3% 以下。

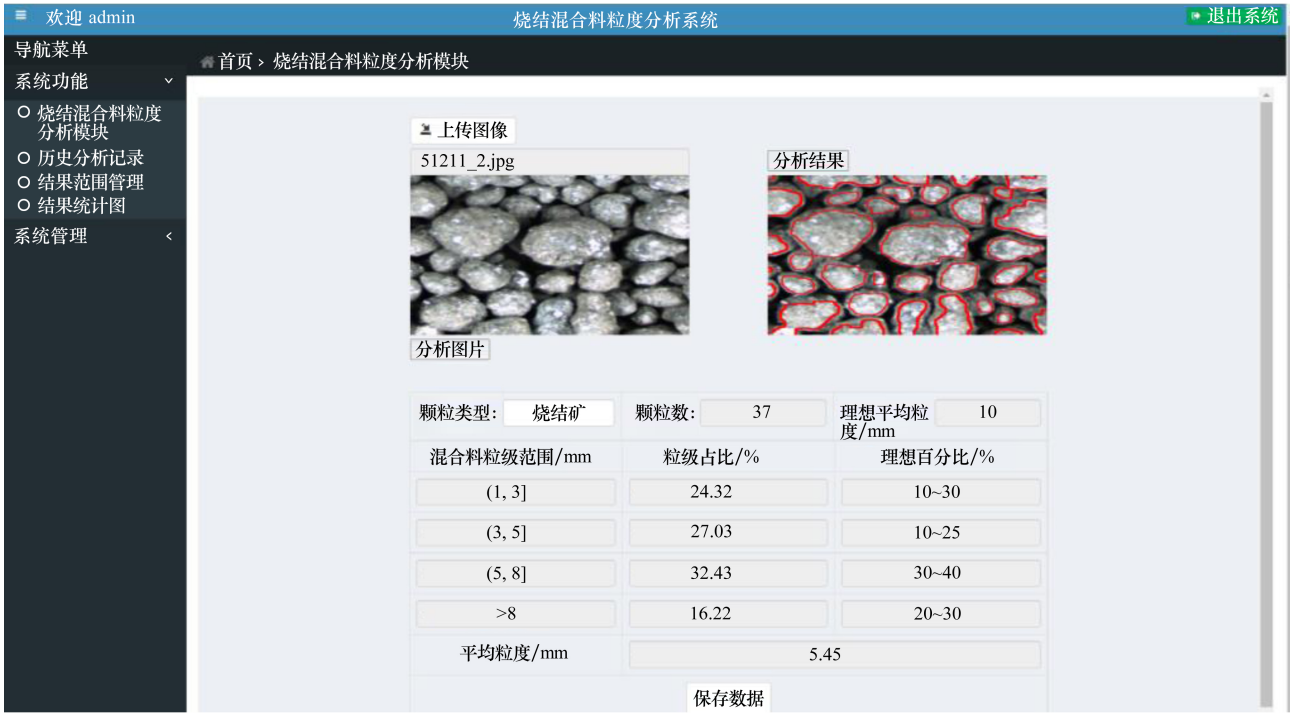
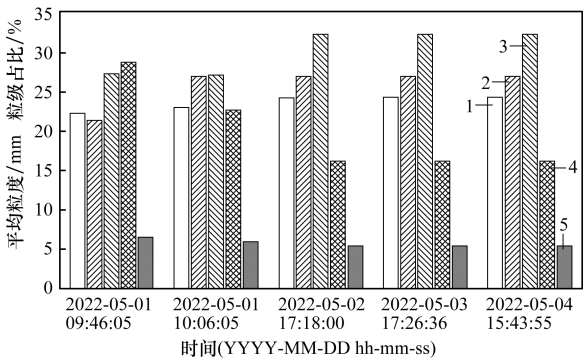


图 10　烧结混合料粒度分析界面

Fig. 10　Interface for particle size analysis of sintered mixes



粒度范围/mm：1—(1,3]；2—(3,5]；3—(5,8]；4—>8；5—平均粒度。

图11 粒度分布历史统计界面

Fig. 11 Granularity distribution history statistical interface

参考文献：

[1] 李毅仁,李铁克. 基于大数据的钢铁智能制造体系架构[J]. 冶金自动化,2021,45(2):1-8.
LI Yiren, LI Tieke. Architecture based on big data for iron and steel intelligent manufacturing systems[J]. Metallurgical Industry Automation, Metallurgical Industry Automation,2021,45(2):1-8.

[2] 刘辰. 国务院印发《新一代人工智能发展规划》:构筑我国人工智能发展先发优势[J]. 中国科技产业,2017(8):78-79.
LIU Chen. The state council issued the development plan for the new generation of artificial intelligence: Build the first-mover advantage of artificial intelligence development in China[J]. China's Science and Technology Industry,2017(8):78-79.

[3] 覃德波,陈天宇,余正伟,等. 基于图像增强的生球粒度识别方法研究[J]. 烧结球团,2021,46(6):82-88.
QIN Debo, CHEN Tianyu, YU Zhengwei, et al. Research on recognition method of fresh pellets particle size based on image enhancement[J]. Sintering and Pelletizing, 2021,46(6):82-88.

[4] 白志城,魏子赫,谢文卓,等. 基于图像处理的球团矿粒度检测系统及分割算法研究[J]. 烧结球团,2021,46(5):41-46.
BAI Zhicheng, WEI Zihe, XIE Wenzhuo, et al. Research on pellet particle size measurement system and segmentation algorithm based on image processing[J]. Sintering and Pelletizing,2021,46(5):41-46.

[5] 曾小信,李宗平,邱立运. 造球机生球的视觉检测算法与系统设计[J]. 冶金自动化,2021,45(3):95-100.
ZENG Xiaoxin, LI Zongping, QIU Liyun. Design of vision detection algorithm and system for green pellet of pelletizer[J]. Metallurgical Industry Automation, 2021, 45(3):95-100.

[6] BAI F Y, FAN M Q, YANG H L, et al. Image segmentation method for coal particle size distribution analysis[J]. Particuology,2021,56:163-170.

[7] 王聃,柴秀娟. 机器学习在植物病害识别研究中的应用[J]. 中国农机化学报,2019,40(9):171-180.
WANG Ran, CAI Xiujuan. Application of machine learning in plant disease identification studies[J]. Journal of Chinese Agricultural Mechaization, 2019, 40(9):171-180.

[8] 肖成勇,李擎,王莉,等. 基于CBAM-Unet的铁矿球团边缘分割实验方法[J]. 烧结球团,2022,47(2):8-15;23.
XIAO Chengyong, LI Qing, WANG Li, et al. Edge segmentation experimental method of iron ore pellets based on CBAM-Unet, Sintering and Pelletizing, 2022, 47(2):8-15;23.

[9] LIU Y, ZHANG Z L, LIU X, et al. Deep learning-based image classification for online multi-coal and multi-class sorting[J]. Computers and Geosciences, 2021, 157: 104922.

[10] FREI M, KRUIS F E. Image-based size analysis of agglomerated and partially sintered particles via convolutional neural networks[J]. Powder Technology, 2020,360:324.

[11] 万川,王正勇,何海波,等. 基于改进P-Unet模型的岩屑颗粒识别[J]. 信息技术与网络安全,2020,39(11):56-61.
WAN Chuan, WANG Zhengyong, HE Haibo, et al. Identification of cuttings particle based on improved P-Unet model[J]. Artificial Intelligence and Security, 2020,39(11):56-61.

[12] 叶飞强,蒋朝辉,周昊,等. 基于多层特征融合Unet高炉炉料矿石图像分割[C]//2020中国自动化大会论文集. 上海:中国自动化学会,2020:789-794.
YE Feiqiang, JIANG Chaohui, ZHOU Hao, et al. Blast furnace material image segmentation based on multi-layer feature fusion Unet[C]//CAC2020. Shanghai: Chinese Association of Automation,2020:789-794.

(下转第98页)

与生产实践[J]. 矿产综合利用,2012(5):57 – 59.
ZHONG Yi, HU Chengfan. On-line recovery technology and practice of iron mineral from the tailings in Daye iron mine[J]. Multipurpose Utilization of Mineral Resources, 2012(5):57 – 59.

[9] 李冰,唐彪,马振. 铁尾矿资源综合利用状况探讨[J]. 内蒙古煤炭经济,2023(18):28 – 30.
LI Bing, TANG Biao, MA Zhen. Discussion on comprehensive utilization of iron tailings resources[J]. Inner Mongolia Coal Economy,2023(18):28 – 30.

[10] 孙建恒,陈若妤,袁敬. 大体积铁尾矿粉混凝土水化热试验研究及数值模拟[J]. 山东农业大学学报(自然科学版),2023,54(3):440 – 446.
SUN Jianheng, CHEN Ruoyu, YUAN Jing. Tailings concrete experimental study and numerical simulation on hydration heat of large-volume iron tailings concrete [J]. Journal of Shandong Agricultural University (Natural Science Edition),2023,54(3):440 – 446.

[11] 吴丽萍,王军. 铁尾矿粉 – 硅粉矿物掺合料对混凝土性能的影响[J]. 矿产综合利用,2023(2):184 – 190.
WU Liping, WANG Jun. Effect of iron tailings powder-silica powder mineral admixture on concrete performance [J]. Multipurpose Utilization of Mineral Resources,2023(2):184 – 190.

[12] LIU X,XU H,LI B,et al. Investigation of the mechanical properties of iron tailings concrete subjected to dry-wet cycle and negative temperature [J]. Materials, 2023, 16(13):4602.

[13] 王艳艳,朱月雷,丁益,等. 铁尾矿砂替代率对混凝土性能的影响[J]. 安徽建筑,2023,30(9):102 – 103;109.
WANG Yanyan, ZHU Yuelei, DING Yi, et al. Effect of iron tailings sand replacement rate on concrete performance [J]. Anhui Architecture, 2023, 30(9): 102 – 103;109.

[14] 李莉. 铁尾矿微粉在硅酸盐胶凝体系中的作用及机理研究[D]. 北京:北京建筑大学,2017.
LI Li. Study on the effect and mechanism of iron tailings powder in silicate gel system[D]. Beijing: Beijing University of Civil Engineering and Architecture,2017.

(上接第16页)

[13] 周昊,蒋朝辉,叶飞强,等. 基于图像多元特征的高炉物料料种识别[C]//2020中国自动化大会论文集. 上海:中国自动化学会,2020:806 – 811.
ZHOU Hao, JIANG Chaohui, YE Feiqiang, et al. Recognition of blast furnace materials based on image multi-feature[C]//CAC2020. Shanghai:Chinese Association of Automation,2020:806 – 811.

(上接第30页)

[7] 臧保文,罗双华. 提高FeO对烧结矿质量的研究[J]. 山西冶金,2021,42(2):10 – 11;33.
ZANG Baowen, LUO Shuanghua. A study on improving FeO quality of sinter by increasing carbon allocation[J]. Shanxi Metallurgy,2021,42(2):10 – 11;33.

[8] 陆洋,张薇. 氧化钙活性对固相烧结反应的影响[J]. 无机盐工业,2012,44(7):16 – 18.
LU Yang, ZHANG Wei. Influence of activity of calcium oxide on solid state sintering reaction[J]. Inorganic Chemicals Industry,2012,44(7):16 – 18.

[9] 吴宏亮,罗云飞,周江虹,等. 富氧协同烟气循环对烧结矿质量指标和CO排放的影响[J]. 中南大学学报(自然科学版),2022,53(4):1179 – 1188.
WU Hongliang, LUO Yunfei, ZHOU Jianghong, et al. Influence of oxygen enrichment and flue gas circulation on quality index of sinter and CO emissions[J]. Journal of Central South University (Science and Technology), 2022,53(4):1179 – 1188.

(上接第89页)

[14] 王聪兵. 难选氧化锌矿硫化焙烧 – 浮选理论与技术研究[D]. 昆明:昆明理工大学,2019.
WANG Congbing. Theoretical and technological research on sulphide roasting-flotation of difficult-to-select zinc oxide ores[D]. Kunming:Kunming University of Science and Technology,2019.

[15] LIU R, ZHAI Q, WANG C, et al. Optimizing the crystalline state of Cu slag by Na_2CO_3 to improve Cu recovery by flotation[J]. Minerals,2020,10(9):820.