

基于 HGM-UNet 的烧结混合料粒度分割研究

杨园明^a, 张淑卿^a, 刘小杰^b

(华北理工大学 a. 电气工程学院; b. 冶金与能源学院, 河北 唐山 063210)

摘要: 针对当前烧结混合料粒度检测方法存在的图像边缘模糊、多尺度特征提取不充分带来的精度低以及现有模型庞大等问题, 本文提出一种基于 HGM-UNet 网络的烧结混合料粒度检测模型。该模型采用 Ghost 卷积, 通过引入轻量化卷积核和稀疏特征图表示, 有效降低计算复杂度和内存消耗; 通过 Haar 小波下采样模块改进 UNet 编码器部分, 充分提取多尺度特征, 提高了模型的精度; 引入 MSCA 注意力机制, 提升边界识别和结构细节的精确度; 加入边界加权交叉熵损失函数更好地学习和保留目标物体的边界信息, 提高烧结混合料粒度的分割精度。建立烧结混合料数据集并进行对比验证, 结果表明: 该模型比传统 UNet 网络的 mIoU 提升 2.50%、PA 提升 2.58%、Dice 系数提升 2.55%、参数量降低 25.4%。

关键词: 烧结混合料; 粒度检测; 深度学习; UNet; 图像分割

中图分类号: TF046.4; TP31

文献标志码: A

文章编号: 1000-8764(2025)04-0141-10

doi: 10.13403/j.sjqt.2025.04.068

Research on particle size segmentation of sinter mixture based on HGM-UNet

YANG Yuanming^a, ZHANG Shuqing^a, LIU Xiaojie^b

(North China University of Science and Technology a. College of Electrical Engineering;

b. College of Metallurgy and Energy, Tangshan 063210, Hebei, China)

Abstract: In order to solve the problems of image edge blurring, low accuracy caused by insufficient multi-scale feature extraction and large existing models in the current sinter mixture particle size detection methods, a particle size detection model for sinter mixture based on HGM-UNet network is proposed. The model adopts Ghost convolution, which effectively reduces computational complexity and memory consumption by introducing lightweight convolutional kernels and sparse feature graph representation. The UNet encoder part is improved by the Haar wavelet downsampling module, which fully extracts multi-scale features and improves the accuracy of the model. The MSCA attention mechanism is introduced to improve the accuracy of boundary recognition and structural details. The boundary-weighted cross-entropy loss function is added to better learn and retain the boundary information of the target object, and improve the segmentation accuracy of the particle size of the sinter mixture. The sinter mixture data set is established and verified by comparison. The results show that the proposed model is 2.50% higher than the mIoU, 2.58% higher PA, 2.55% higher Dice coefficient, and 25.4% lower parameter quantity than the traditional UNet network.

Key words: sinter mixture; particle size detection; deep learning; Unet; image segmentation

烧结混合料粒度是指铁矿烧结过程中混合料的颗粒大小。在烧结混合料的制备过程中, 粒度的控制至关重要。粒度过大或小都可能导致烧结过程堵塞或者烧结料的流动性不佳, 影响烧结矿

收稿日期: 2024-09-20; 修回日期: 2025-03-11

基金项目: 现代冶金技术教育部重点实验室开放基金资助项目(2024YJKF01)

作者简介: 杨园明(1999—), 男, 硕士研究生, 从事模式识别与智能系统的研究。

通信作者: 张淑卿(1978—), 女, 副教授, 从事复杂系统的建模与控制、机器视觉与图像处理方面的研究。

质量和烧结生产效率^[1]。合适的粒度分布可以提高料层的均匀性,促进原料之间的结合和反应,从而提高烧结矿的强度和耐磨性。烧结混合料粒度分析的传统做法主要依据现场操作人员在配料带沿线采集样本,继而通过筛分、称重操作来评估混合料的粒度分布特性。这种方法存在着速度慢、操作风险高及结果反馈时间较长等问题。同时,生产现场弥漫的高浓度粉尘威胁工人健康。

鉴于人工筛分法面临的一系列挑战,图像处理技术已逐渐成为该领域的研究重点^[2-3]。白志城等^[4]研究了基于图像处理的球团矿粒度检测系统及分割算法,针对图像中噪声多、整体亮度较低的问题,运用滤波、阈值分割以及形态学操作等预处理策略,进一步地设计了一个结合自适应标记的优化分水岭分割算法,以实现球团矿的精确图像分割。张琳琛等^[5]基于优化后的 Canny 算法,提出一种新的工作流程,该流程融合了阈值与图像积分,通过引入距离变换函数以提升形态学操作的效能,进而构建了适用于烧结混合料粒度识别的模型。该模型展现出较高的检测精度,但在面对烧结混合料颗粒黏连和重叠情况时,仍面临过度分割与不足分割的问题。张学锋等^[6]研究了基于图像增强的球团矿粒度检测,该方法针对采集图像亮度低、噪声多等特点,结合 Log 变换来改进多尺度视网膜模型的色彩复原算法进行图像增强,然后通过导向滤波在抑制噪声的同时保持球团边界特征,随后采用结合阈值分割的霍夫变换方法,快速检测出球团矿的粒度分布情况。这些方法在图像处理领域取得了相应进展,但其图像处理容易受到噪声和光照变化的影响,且对复杂场景的适应性略显不足。

近年来,以深度学习为核心的技术在图像处理领域展现出显著优越性,相较于传统方法,其在准确度以及复杂任务处理能力上均有所提升。WU 等^[7]提出一种高效多尺度镶嵌 UNet 算法实现在线测量生球粒度分布。LIU 等^[8]利用深度学习与迁移学习相结合的技术,开发一种先进的煤矿识别系统。该研究引入一种基于卷积神经网络的模型,高效捕获了煤矿图像中的多层次特征,显著提高了复杂背景下煤种的识别精度,实现了混

合煤堆中烟煤、无烟煤及焦炭等煤类的精准识别。FREI 等^[9]建立了一种基于深度学习的颗粒自动检测模型,用于分析烧结或团聚初级粒子的分布特性。该方法经过验证,展现出在自动化识别初级粒子过程中的高效性和稳定性。李艺萌^[10]提出一种利用 UNet++ 网络来检测旋转圆盘造球机静止层的生球粒度分布,实现了生球粒度在线检测,减少了繁琐、耗时的人工筛分操作。

利用深度学习算法对烧结混合料粒度进行检测已成为广泛应用的方向,然而,基于深度学习的图像分割在粒度检测中的效果不尽理想,同时算法参数量较大,对设备的要求也较高。因此,本文提出 HGM-UNet 的烧结混合料粒度检测算法,针对传统网络参数较大、对设备要求高的问题,将 UNet 网络卷积替换为 Ghost 卷积,通过低成本的线性变换生成更多的“幽灵”特征图,解决特征提取冗余的问题,从而提高网络的计算效率;针对烧结混合料图像多尺度特征提取不充分的情况,改进传统 UNet 网络的编码器部分,将最大池化替换为 Haar 小波下采样模块,通过分解图像的低频和低频分量,优化网络的多尺度特征捕获性能;融合 MSCA 注意力机制,采用多层次、多尺度的卷积操作更好地捕捉烧结混合料图像中的细节和全局信息,提升边界识别和结构细节的精确度;针对烧结混合料颗粒边界模糊、影响分割精度的问题,采用边界加权交叉熵损失函数替代交叉熵损失函数,利用其加权机制有效增强图像边缘,提升边界区域的预测精度。

1 UNet 网络

UNet 网络架构最早于 2015 年由 RONNEBERGER 等^[11]提出,主要用于解决医学图像分割问题。这种网络结构在医学影像处理领域取得了突破性进展,并且后来被广泛用于其他领域的图像分割任务,其结构形状相似于 U 而得名。原始 UNet 的基本结构如图 1 所示。

网络编码器阶段通过 3×3 卷积和池化层实现 4 次下采样。解码器阶段通过 3×3 卷积于转置卷积完成上采样,将深层特征图恢复至初始分辨率,最后采用 1×1 卷积调整通道维度匹配分类

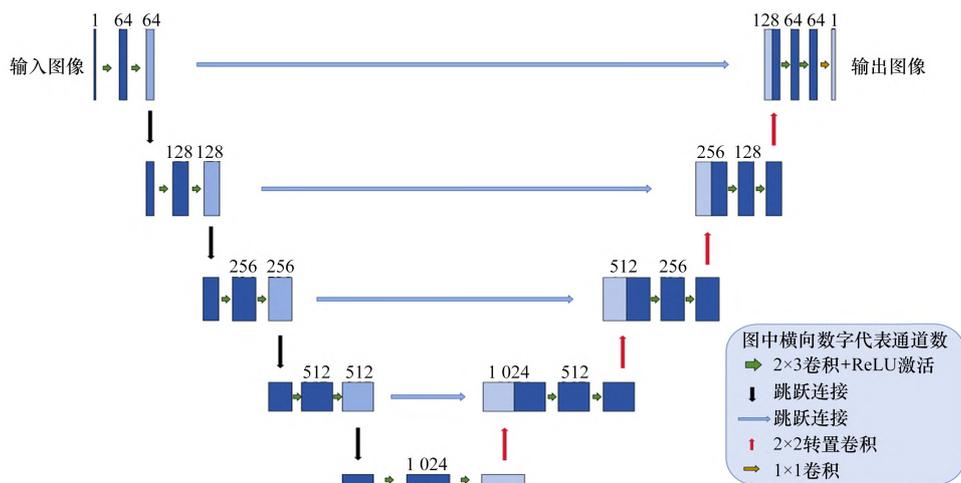
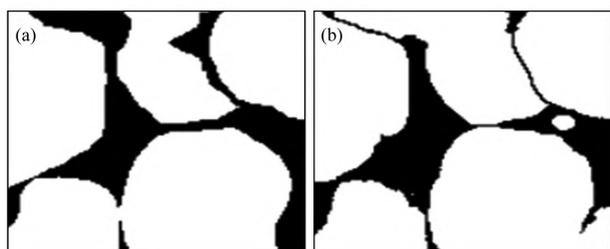


图 1 UNet 网络结构

Fig. 1 UNet network structure

需求^[12-13]。

UNet 网络利用编码器-解码器结构, 通过下采样来提取高级语义信息, 同时通过上采样恢复特征图到原始分辨率, 从而进行精确的像素级分类。这种设计可降低显存使用并扩展感受野。然而, 在特征捕获过程中, 下采样操作会引发局部信息缺失, 尽管跳跃连接能够在一定程度上缓解此问题, 但仍存在语义不匹配的特征融合问题, 这使得 UNet 在图像边界的精确分割上存在局限。特别是在处理复杂边界时, 分割精度可能会受到影响, 如图 2 所示。



(a) 标签; (b) 预测

图 2 UNet 分割结果

Fig. 2 UNet segmentation results

2 HGM-UNet 网络

2.1 Ghost 卷积

UNet 网络中传统卷积的每个特征图都需要进行卷积操作, 这会导致大量的计算和内存消耗, 特别是在处理高分辨率图像或深层网络时。此外, 传统卷积通常使用大量的卷积核, 每个卷积核都

有独立的权重, 导致参数的数量庞大, 这不仅增加模型的训练和推理负担, 也可能影响信息的有效传递。因此引入一种 Ghost 轻量化卷积, 如图 3 所示。

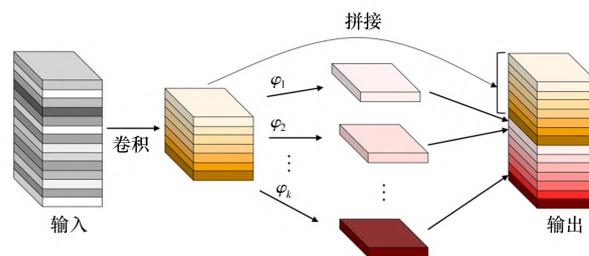


图 3 Ghost 卷积原理

Fig. 3 Schematic diagram of Ghost convolution

(注: $\varphi_1, \varphi_2, \dots, \varphi_k$ 为低成本变换函数, 通常由深度可分离卷积、批量归一化和 ReLU 激活函数按顺序构成)

Ghost 模块是 CNN 网络的一种创新性设计, 其核心思想是利用已有的特征图通过低成本的线性变换生成更多的“幽灵”特征图, 从而提高网络的计算效率^[14]。Ghost 模块主要包括两个关键部分: 首先使用少量卷积、批量归一化和激活函数 ReLU, 将输入图片进行通道数降维, 生成固有特征映射; 其次是对上一步得到的每一个固有特征图, 应用 φ_k 来生成若干新的特征图(即“幽灵”特征图)。

Ghost 卷积模块采用双路径特征合成策略: 首先通过特征压缩层将原始卷积核维度缩减 50%, 实现计算复杂度降低至常规操作的 1/2; 其次构建补充特征生成层, 采用 3×3 或 5×5 的逐通道深

度可分离卷积对初级特征进行非线性增强。通过特征空间的级联融合，最终形成与标准卷积具有等效表征能力的特征映射矩阵，在维持网络提取特征性能的同时减少参数量。

GhostConv 的参数数量公式：

$$P = \frac{n}{s} \times c \times k^2 + (s - 1) \times \frac{n}{s} \times d^2 \quad (1)$$

式中： P 为参数量； n 为批次大小； s 为线性变换次数； c 表示为输入特征图的通道数； k 为深度可分离卷积核大小； $d \times d$ 表示线性运算的卷积核大小。

GhostConv 的计算量公式：

$$F = \frac{n}{s} \times h' \times w' \times c \times k^2 + (s - 1) \times \frac{n}{s} \times h' \times w' \times d^2 \quad (2)$$

式中： F 为计算量； h' 为输出特征图的高度； w' 为输出特征图的宽度。

将 Ghost 卷积模块应用到 UNet 网络中进行烧结混合料的图像分割任务，可有效降低模型参数量与计算开销，并提升特征表达能力。这种模块通过捕获输入特征之间的关联性，有助于提高对图像中纹理、形状和结构等抽象特征的理解，进而提高分割的准确度。

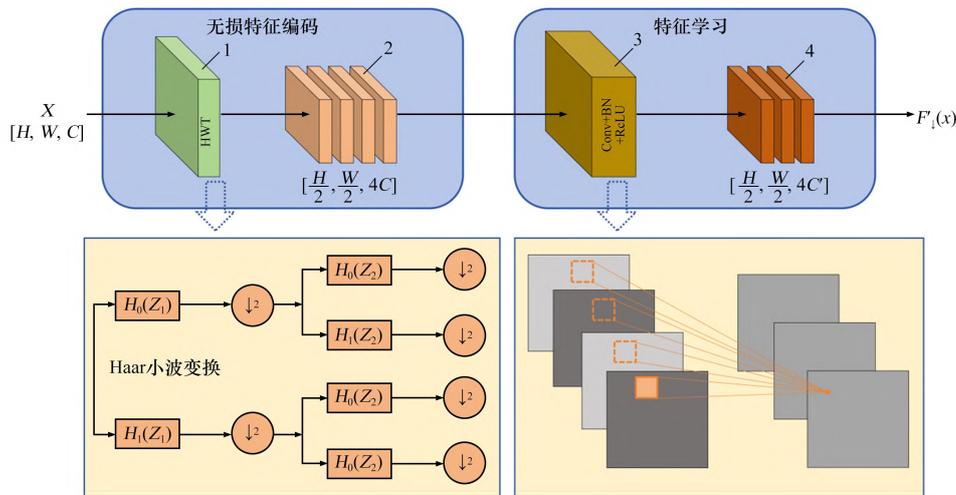
2.2 HWD 下采样模块

在 UNet 网络中，传统的最大池化操作存在一些显著的不足，最大池化仅保留池化窗口中的最

大值，忽略了其他值，这可能导致图像细节和信息丢失。在处理复杂结构和纹理时，这种信息丢失会显著影响模型对细节的捕捉能力。

为解决这一问题，引入一种简洁而高效的池化操作，称为 HWD 小波下采样 (Haar) 模块^[15]。HWD 模块利用 Haar 小波变换将输入图像进行分解，通过提取低频分量来实现下采样，从而保留重要图像信息并减少数据量，其工作原理如图 4 所示。图 4 中，无损编码功能表示分辨率为 $H \times W$ 、通道数为 C 的图像通过 Haar 小波变换分解的过程； H_0 表示低通分解滤波器； H_1 表示高通分解滤波器； \downarrow_2 表示对近似分量和细节分量进行下采样操作。通过下采样生成 4 个分量：近似分量(A)以及水平(H)、垂直(V)、对角线(D)方向上的细节分量(高频)。每个分量的尺寸为 $H/2 \times W/2$ ，即空间分辨率降为原图的 1/4，而特征图的通道数扩展为原来的 4 倍。这意味着，Haar 小波变换实现了空间维度的部分信息向通道维度的无损编码。

将 UNet 网络中传统的下采样替换为 Haar 小波下采样模块，能够显著提升特征捕获性能和分割精度。具体来说，Haar 小波变换通过分解图像的低频和低频分量，优化网络对多尺度特征的捕获能力，从而提取出更多关键信息。同时，这种方法还能有效减少计算复杂度，因为 Haar 小波下采样保留了更多低频信息，提升了网络训练和推理的效率。



1—Haar 小波变换；2—下采样操作；3—Conv + BN + ReLU；4—下采样操作。

图 4 HWD 下采样原理

Fig. 4 Schematic diagram of HWD downsampling

2.3 MSCA 注意力模块

传统的 UNet 网络虽然在编码器和解码器之间建立了连接,但它对不同尺度的特征处理相对固定,无法动态调整特征的权重。这可能导致在处理不同尺度的特征时,模型对某些尺度的信息关注不足,从而影响分割效果。此外,传统 UNet 无法充分利用图像中的上下文信息,这会导致在处理复杂场景或边界模糊的对象时效果不佳。

为解决这些问题,引用 MSCA 注意力机制。MSCA^[16](multi-scale context aggregation)注意力模块是 SegNeXt 架构中的一个关键组件,它通过高效编码多尺度空间信息和捕获上下文关系,显著提升语义分割任务的性能,如图 5 所示。

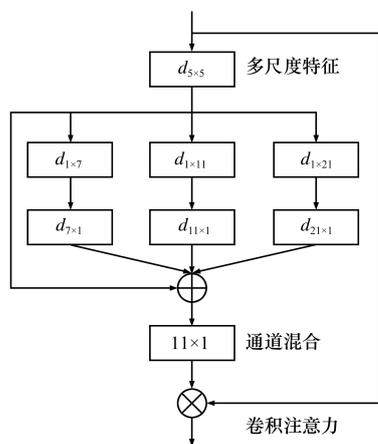


图 5 MSCA 注意力机制

Fig. 5 MSCA Attention Mechanism

MSCA 由三个协同模块组成:深度卷积负责局部信息聚合,使用 5×5 、 1×7 、 1×11 、 1×21 等不同尺度的卷积核(分别表示为 $d_{5 \times 5}$ 、 $d_{1 \times 7}$ 、 $d_{1 \times 11}$ 、 $d_{1 \times 21}$)进行卷积,从输入特征中提取出不同尺度的局部信息;多分支深度条带卷积提取多尺度上下文信息; 1×1 逐点卷积建立不同通道的联系。注意力的权重直接采用 1×1 卷积,用于调整 MSCA 输入的权重分布。

在 UNet 网络中加入 MSCA 多尺度注意力模块,其多层次、多尺度的卷积操作(如 5×5 、 1×7 和 7×1 等)能更好地捕捉烧结混合料图像中的细节和全局信息,提升边界识别和结构细节的精确度;通过加权融合不同卷积输出,有效关注重要区域,抑制背景干扰,提高分割准确性;深度条带卷积在一定程度上减少参数和计算量,从而确

保分割任务的高效性。

2.4 损失函数

在传统的 UNet 网络中,交叉熵损失作为常用的损失函数,用于度量事件集或给定随机变量的两个概率分布之间的差异性。交叉熵损失在分割任务中,对每个像素类的预测概率进行独立评估,然后求取全部像素的平均值,其计算方法如下。

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (3)$$

式中: L 为传统交叉熵损失; y_i 为第 i 个样本的真实标签; \hat{y}_i 为模型预测该样本为正类的概率; N 为样本数量。

但在烧结混合料的图像分割任务中,面对图像前景和背景像素比例失衡的情况,传统的交叉熵损失可能对少数类别像素的训练效果不佳,使预测偏向于背景,导致小样本学习获得的重要特征未被充分利用,进而降低分割性能;另外,烧结混合料的图像通常涉及复杂的物质结构、不规则或模糊的边界等情况。为解决这些问题,现有研究发展了若干改进方法,如采用边界加权交叉熵损失函数,它在普通的交叉熵损失函数的基础上,引入了对边界区域的加权机制,从而更好地处理边界细节和类别不平衡问题。其计算方法如下。

$$L_w = -\frac{1}{N} \sum_{i=1}^N W_i [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (4)$$

式中: L_w 为边界加权交叉熵损失函数; W_i 为根据样本 i 预测与真实标签之间的差异计算出的权重。

边界加权交叉熵损失函数通过权重 W_i 来强调边界区域。这些权重根据像素到边界的距离来定义权重,距离越小,权重越大。通过加权机制,边界加权交叉熵损失函数可以更好地捕捉图像中的边界细节,提高分割精度。并且,加权机制能有效缓解类别不平衡问题,使得模型在边界区域的预测更加准确。

2.5 HGM-UNet 网络结构

HGM-UNet 网络结构如图 6 所示。改进编码器是改进网络的核心部分,主要由 Ghost 卷积和 MSCA 注意力组成的 GM 模块以及 HWD 下采样模块组成。GM 模块结构如图 7 所示。

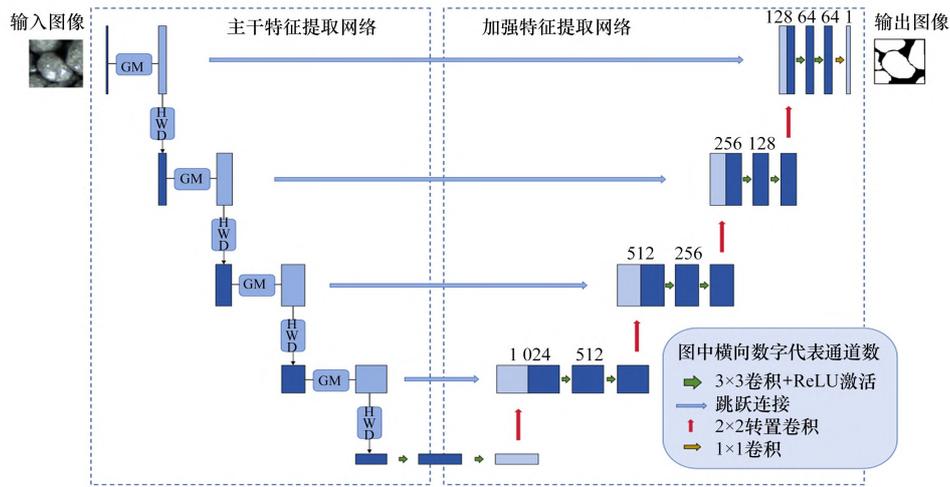


图 6 HGM-UNet 网络结构

Fig. 6 HGM-UNet network structure diagram



图 7 GM 模块结构

Fig. 7 GM module structure

在 GM 模块中用 Ghost 卷积替换原始卷积，在分割精度变化不大的情况下，通过有效降低模型的参数量从而提高运算速率。在两个 Ghost 卷积后融合 MSCA 注意力模块，能更好地捕捉烧结混合料图像中的细节和全局信息，提升边界识别和结构细节的精确度^[17]。

3 试验结果与讨论

3.1 试验数据与处理

3.1.1 数据集

通过柔性薄板与条形凹槽组合设计物料托盘，模拟传送带混合料的分布状态，并选用 500 万像素级工业相机作为采集设备。采集图像过程中，将相机镜头与烧结混合料的距离设定为 150 mm，在试验台两侧外加 25 cm × 25 cm 的面光源设备，以保证光线稳定。试验采集 60 张烧结混合料图像，每张图片大小为 1 024 × 1 024，如图 8 所示。

鉴于网络训练阶段对 GPU 内存的需求，以便更加充分、便捷地对图像进行标签制作以及更加直观地对比不同算法的分割细节，将采集的烧结混合料图像分割为 128 × 128 的图像共 3 840 张。采用麻省理工学院开发的在线 JavaScript 图像标注工具，进行打标签操作。Labelme 操作过程如图 9 所示。



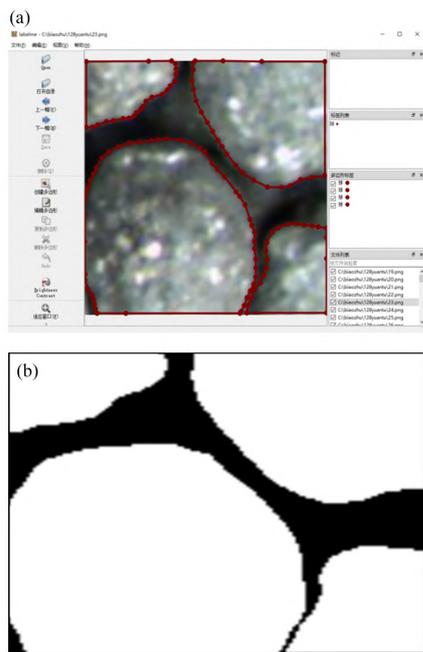
图 8 烧结混合料

Fig. 8 Sinter mixture

Labelme 允许用户创建自定义标注任务并执行图像标注，标注后的图像与相应的 json 文件保存在同一文件夹中。随后，执行批量 json_to_dataset 操作，将这些标注数据转化为完整的烧结混合料图像数据集。在二值掩膜图中，背景标记为黑色（灰度值为 0），烧结混合料区域被手动标注为白色（灰度值为 255），以实现类别区分。数据集被划分为测试集和训练集，分别包含 768、3 072 张图像。

3.1.2 计算环境

试验在 Linux Ubuntu 环境下进行，硬件配置包括 NVIDIA GeForce RTX 3090 显卡(24 GB 显存)和 Intel Xeon Platinum 8255C 处理器(12 核，主频 2.50 GHz)。软件环境采用 PyTorch 1.10.0 深度学习框架，配合 CUDA 11.3 加速库，编程语言为 Python3.9。试验设置中，每个模型的训练周期为



(a) 标注界面; (b) 处理结果

图9 Labelme 操作过程

Fig. 9 Labelme operation process

200 个 epoch, 批量大小为 32, 采用随机梯度下降 (SGD) 优化器, 设置学习率从 0.01 逐步衰减至 0.000 1。

3.2 评估函数

3.2.1 mIoU

mIoU (mean Intersection over Union) 是语义分割任务中常用的评估指标, 为预测分割结果与实际标签的交集与并集的比值的平均值。计算方法如下。

$$\sigma_{\text{mIoU}} = \frac{1}{K} \sum_{x=0}^K \frac{p_{xx}}{\sum_{y=0}^K p_{xy} + \sum_{y=0}^K p_{yx} - p_{xx}} \quad (5)$$

式中: σ_{mIoU} 为 mIoU 评估指标; K 为预测类别数; x 表示真实值; y 表示预测值; p_{xx} 表示将 x 预测为 x , 即真阳性 (TP); p_{yx} 表示将 x 预测为 y , 即 FN (假阴性); p_{xy} 表示将 y 预测为 x , 即 FP (假阳性)。

3.2.2 PA

PA (pixel accuracy) 指标衡量的是被正确分类的像素数量占该类别总像素数量的比例。PA 值越高, 表明模型在像素级别上的分割精度越高, 分割效果越优。计算方法如下。

$$\sigma_{\text{PA}} = \frac{n_{\text{TP}} + n_{\text{TN}}}{n_{\text{TP}} + n_{\text{TP}} + n_{\text{FP}} + n_{\text{FN}}} \quad (6)$$

式中: σ_{PA} 为 PA 评估指标; n_{TP} 、 n_{TN} 分别表示正确

分类为前景、背景的像素数; n_{FP} 、 n_{FN} 分别表示错误分类为前景、背景的像素数。

3.2.3 Dice

Dice (dice similarity coefficient) 是一种用于评估图像分割结果与真标签之间相似度的指标。在 UNet 网络等深度学习图像分割模型的估中, Dice 系数常被用来衡量模型在分割任务中的准确性和效果, Dice 越高, 表示分割精度越高。计算方法如下。

$$\sigma_{\text{Dice}} = \frac{2|A \cap B|}{|A| + |B|} \quad (7)$$

式中: σ_{Dice} 为 Dice 评估指标; $|A|$ 和 $|B|$ 分别表示预测值像素集合和真实值像素集合。

3.3 消融试验

为全面证明 HGM-UNet 的改进效果, 分别对 Ghost 卷积模块、HWD 下采样模块、MSCA 注意力模块和边界加权交叉熵损失函数进行消融试验。试验结果如表 1 所示。由表 1 可知, 相较于传统的 UNet, 加入 Ghost 卷积模块后, 模型在有效降低参数量的同时可维持分割精确度; 融入 HWD 下采样后能够有效捕捉多尺度特征, 增强图像细节特征的提取能力, 优化分割模型的准确性; 同时引入 MSCA 注意力模块通过高效编码多尺度空间信息和捕获上下文关系, 显著提升语义分割任务的性能; 引入边界加权交叉熵损失函数, 通过对边界区域赋予更高的权重强化对边界区域的学习, 提高边界的检测精度。试验进一步验证 HGM-UNet 网络的有效性。

表 1 消融试验结果

Table 1 Results of ablation experiments

试验方案	$\sigma_{\text{mIoU}} / \%$	$\sigma_{\text{Dice}} / \%$	$\sigma_{\text{PA}} / \%$	模型参数量/ 10^6 个
UNet 网络	88.66	90.34	90.87	13.40
Ghost 卷积模块	88.73	90.46	90.91	6.73
HWD 下采样模块	90.74	91.56	92.43	16.68
MSCA 注意力模块	90.83	91.16	92.21	14.14
边界加权交叉熵损失函数	89.12	90.60	91.23	13.40
HGM-UNet	91.16	92.89	93.45	10.00

3.4 对比试验

为验证 HGM-UNet 网络在烧结混合料分割任

务的有效性,采用 UNet、UNet++ 和 TransUNet 作为对比网络。所有对比网络与 HGM-UNet 使用相同的试验环境与训练策略。通过均交并比 (mIoU)、Dice 系数、像素精度 (PA) 以及模型参数量四个关键指标,对烧结混合料的分割性能进行综合评估与对比分析。试验结果如表 2 所示。由表 2 可见, HGM-UNet 在烧结混合料任务中达到 91.16% 的 mIoU、92.89% 的 Dice 和 93.45% 的 PA。对比其他网络,除了 mIoU 值略低于 TransUNet,其他指标均达到最好的效果。对比传统的 UNet,新模型的 mIoU 提升 2.50%、Dice 提升 2.55% 以及 PA 提升 2.58%。最重要的是, Ghost 卷积和 Haar 小波下采样的融入能够保留更多的图像细节,同时有效地将网络参数量降低了 25.4%,显著提高了计算性能和模型运行速度。试验结果表明, HGM-UNet 网络在烧结混合料分割任务中展现出优越的性能。

表 2 对比试验结果

Table 2 Comparative experimental results

模型名称	$\sigma_{mIoU}/\%$	$\sigma_{Dice}/\%$	$\sigma_{PA}/\%$	模型参数量/ 10^6 个
UNet	88.66	90.34	90.87	13.40
UNet++	90.29	91.68	92.23	31.04
TransUNet	91.32	91.75	92.30	64.28
HGM-UNet	91.16	92.89	93.45	10.00

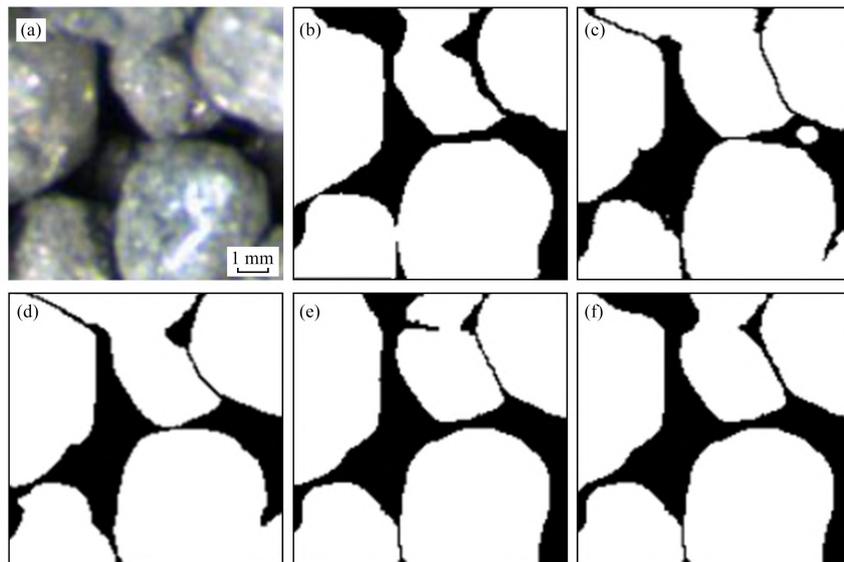
3.5 分割效果对比

为了直观对比 HGM-UNet 的分割性能,随机选取一组烧结混合料图像,分别在 Unet、Unet++、TransUNet 以及 HGM-UNet 模型上进行测试。不同算法的分割结果如图 10 所示。通过对比不同网络模型的分割结果,可以直观观察到各模型在训练后的性能差异,其中 UNet 虽然结构简单易于调试,但无法捕捉足够的复杂轮廓细节的信息,分割准确率相对较低。UNet++ 与 TransUNet 网络模型相较传统的 UNet 网络得到有效改善,能够更好地捕捉图像全局以及细节信息,分割准确率得到提升,但其复杂的网络结构带来较大的参数量,需求的计算成本较高。与其他模型相比, HGM-UNet 生成的分割结果在轮廓和细节上与真实标签更为接近,展现了较高的分割精度。

3.6 误差分析

轮廓检测算法从 HGM-UNet 网络中输出的分割图像提取颗粒的轮廓,然后使用轮廓的最小外接圆测量尺寸^[18]。为满足实际测量需求,选择一个圆形作为参考对象,通过计算像素值与参考对象的比例关系,从而推导出烧结混合料颗粒的实际面积。具体步骤如图 11 所示,计算方法如下^[19]。

$$S = A \times \frac{S_1}{A_1} \quad (8)$$



(a) 原图; (b) 真实标签; (c) Unet 分割结果; (d) Unet++ 分割结果; (e) TransUNet 分割结果; (f) HGM-UNet 分割结果

图 10 不同算法的分割结果

Fig. 10 Segmentation results of different algorithms

式中: S 、 S_1 分别表示颗粒的实际面积和像素值; A 、 A_1 分别表示参照物的实际面积和像素值。

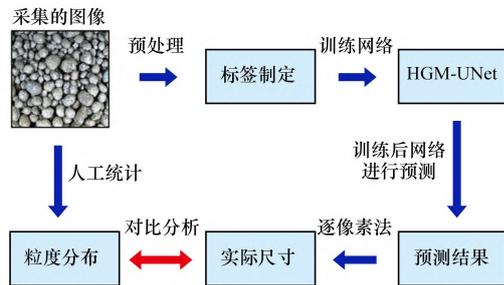


图 11 粒度检测流程

Fig. 11 Particle size inspection process

根据烧结混合料的粒度检测标准,其粒度范围为 0.1 ~ 10 mm,其中大部分分布在 5 ~ 8 mm,少数分布在 0 ~ 3 mm。将人工测量值与改进方法的结果进行比较,试验结果如表 3 所示。由表 3 可以看出,试验检测的最大误差为 4.75%,这证明 HGM-UNet 网络粒度检测算法在烧结混合料分析中具备较高的精度和稳定性,能够有效满足生产工艺的标准要求^[20-23]。

表 3 烧结混合料粒度统计结果

Table 3 Particle size statistical results of sinter mixture

图像编号	人工统计/mm	算法统计/mm	误差/%
1	5.56	5.66	1.80
2	4.98	5.10	2.41
3	6.47	6.38	1.39
4	5.72	5.91	3.32
5	6.09	5.97	1.97
6	5.88	5.97	1.53
7	6.31	6.01	4.75
8	5.92	6.00	1.35
9	4.73	4.78	1.06
10	6.15	6.03	1.95

4 结论

(1) HGM-UNet 网络的编码器部分通过融合 Haar 小波下采样模块,更加充分地提取多尺度特征,从而提高烧结混合料粒度检测精度,同时使用 Ghost 卷积替换传统的卷积,通过引入轻量化的卷积核和稀疏特征图表示,显著减少了计算复杂性和内存占用;同时,通过多次试验优化,将

MSCA 注意力机制集成到最佳位置,增强网络对目标边界识别和结构细节的准确性;引入边界加权交叉熵损失函数可以更好捕捉图像中的边界细节。

(2) 基于自建数据集进行了试验验证与性能对比,结合消融试验验证了各改进模块的有效性。试验结果表明,HGM-UNet 模型在 PA、Dice 和 mIoU 三项评价指标上均优于当前主流图像分割模型。HGM-UNet 网络在具有较高分割精度的同时还降低了计算量和参数量。改进的算法已经取得了一定进展,未来的研究除了扩充数据集之外,还应开发一个可视化系统,以实现烧结混合料粒度的在线检测。

参考文献:

- [1] 王海风,裴元东,张春霞,等. 中国钢铁工业烧结/球团工序绿色发展工程科技战略及对策[J]. 钢铁, 2016,51(1):1-7.
WANG Haifeng, PEI Yuandong, ZHANG Chunxia, et al. Green development of sintering/pellet procedure in China iron and steel industry[J]. Iron and Steel, 2016, 51(1): 1-7.
- [2] DE MORAIS OLIVEIRA V, DOMINGUES A L A, BAGATINI M C, et al. Granulation behavior of an iron ore sintering mixture containing high grade pellet feed with different specific surface[J]. ISIJ International, 2020, 60(11): 2376-2384.
- [3] ZHU D Q, SHI B J, PAN J, et al. Effect of pre-briquetting on the granulation of sinter mixture containing high proportion of specularite concentrate[J]. Powder Technology, 2018, 331: 250-257.
- [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; 72.
BAU Zhicheng, WEI Ziheng, 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; 72.
- [5] 张琳琛,刘颂,李福民,等. 基于改进 Canny 算子的烧结混合料粒度检测方法[J]. 烧结球团, 2022, 47(3): 15-24.
ZHANG Linchen, LIU Song, LI Fumin, et al. Method for particle size detection of sinter mixture based on

- improved Canny operator[J]. Sintering and Pelletizing, 2022, 47(3):15-24.
- [6] 张学锋, 祝忠阳, 黄永鹤, 等. 基于图像增强的球团粒度检测方法[J]. 烧结球团, 2024, 49(3):81-88.
ZHANG Xuefeng, ZHU Zhongyang, HUANG Yonghe, et al. Pellets particle size detection method based on image enhancement[J]. Sintering and Pelletizing, 2024, 49(3):81-88.
- [7] WU X, LIU X Y, DUAN J X. Online size distribution measurement of dense iron green pellets using an efficient and multiscale nested U-Net method[J]. Powder Technology, 2021, 387:584-600.
- [8] LIU Y, ZHANG Z L, LIU X, et al. Deep learning-based image classification for online multi-coal and multi-class sorting[J]. Computers & Geosciences, 2021, 157:104922.
- [9] FREI M, KRUIS F E. Image-based size analysis of agglomerated and partially sintered particles via convolutional neural networks [J]. Powder Technology, 2020, 360:324-336.
- [10] 李艺萌. 基于图像处理的生球粒度检测及造球加水量控制[D]. 包头:内蒙古科技大学, 2022.
LI Yimeng. Particle size detection of green ball based on image processing and pelletizing water addition control [D]. Baotou: Inner Mongolia University of Science & Technology, 2022.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-Assisted Intervention; MICCAI 2015. Cham: Springer, 2015:234-241.
- [12] 项辉宇, 黄恩浩, 冷崇杰, 等. 基于图像处理与深度学习的苹果检测分级[J]. 食品安全导刊, 2022(22):48-53.
XIANG Huiyu, HUANG Enhao, LENG Chongjie, et al. Apple detection and classification based on image processing and deep learning[J]. China Food Safety Magazine, 2022(22):48-53.
- [13] 李江昀, 杨志方, 郑俊锋, 等. 深度学习技术在钢铁工业中的应用[J]. 钢铁, 2021, 56(9):43-49.
LI Jiangyun, YANG Zhifang, ZHENG Junfeng, et al. Applications of iron and steel industry with deep learning technologies[J]. Iron and Steel, 2021, 56(9):43-49.
- [14] HAN K, WANG Y H, TIAN Q, et al. GhostNet: More features from cheap operations [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020:1577-1586.
- [15] XU G P, LIAO W T, ZHANG X, et al. Haar wavelet downsampling: A simple but effective downsampling module for semantic segmentation[J]. Pattern Recognition, 2023, 143:109819.
- [16] GUO M H, LU C Z, HOU Q B, et al. SegNeXt: Rethinking convolutional attention design for semantic segmentation[EB/OL]. (2022-09-18) [2024-05-20]. <https://arxiv.org/abs/2209.08575>.
- [17] 张兴志, 彭柯鑫, 彭子洋, 等. 基于改进 UNet 的结直肠腺体细胞分割算法[J]. 电子设计工程, 2025, 33(2):42-46.
ZHANG Xingzhi, PENG Kexin, PENG Ziyang, et al. Colorectal cancer glandular cell segmentation algorithm based on improved UNet[J]. Electronic Design Engineering, 2025, 33(2):42-46.
- [18] 张新天. 图像识别技术在炼铁原燃料粒度检测中的应用[J]. 现代冶金, 2019, 47(5):55-59.
ZHANG Xintian. Application of image recognition technology in particle size detection of ironmaking raw fuel[J]. Modern Metallurgy, 2019, 47(5):55-59.
- [19] 刘颂, 张振, 赵军, 等. 基于 Unet 网络的烧结混合料粒度检测模型[J]. 烧结球团, 2024, 49(2):8-16; 98.
LIU Song, ZHANG Zhen, ZHAO Jun, et al. Particle size detection model of sintering compound based on Unet network[J]. Sintering and Pelletizing, 2024, 49(2):8-16; 98.
- [20] 王海东, 邱冠周, 黄圣生. 烧结过程控制技术的发展[J]. 矿冶工程, 1999, 19(3):3-6.
WANG Haidong, QIU Guanzhou, HUANG Shengsheng. Advances in control techniques for sintering process[J]. Mining and Metallurgical Engineering, 1999, 19(3):3-6.
- [21] 朱忠平, 姜涛, 黄柱成, 等. 粒度对高铁三水铝石型铝土矿烧结性能和烧结矿显微结构的影响[J]. 矿冶工程, 2009, 29(2):50-54.
ZHU Zhongping, JIANG Tao, HUANG Zhucheng, et al. Effects of grain size on sintering properties of high iron trihydrate bauxite and sinter microstructure[J]. Mining and Metallurgical Engineering, 2009, 29(2):50-54.

(下转第 177 页)

recirculation on the premixed oxy-methane flames in atmospheric condition[J]. *Energy*,2015,89:845-857.

- [15] GÓMEZ M A, PATIÑO D, COMESAÑA R, et al. CFD simulation of a solar radiation absorber[J]. *International Journal of Heat and Mass Transfer*,2013,57(1):231-240.

- [16] OROOJI Y, JAVADI M, KARIMI-MALEH H, et al. Numerical and experimental investigation of natural gas injection effects on NO_x reburning at the rotary cement kiln exhaust[J]. *Process Safety and Environmental Protection*,2021,151:290-298.

(上接第140页)

- [17] 黄浩,吴中贤,乔波,等.拜耳法赤泥磁选铁精矿浮选脱钛研究[J]. *矿冶工程*,2024,44(5):41-45;50.
HUANG Hao, WU Zhongxian, QIAO Bo, et al. Study on titanium removal by flotation from magnetic iron concentrate of Bayer red mud[J]. *Mining and Metallurgical Engineering*,2024,44(5):41-45;50.
- [18] 杨卓,冯博,李文涛,等.铁精矿选矿除杂试验研究[J]. *工程建设*,2024,56(12):16-23.
YANG Zhuo, FENG Bo, LI Wentao, et al. Experimental

study on impurity removal from iron concentrate[J]. *Engineering Construction*,2024,56(12):16-23.

- [19] 武春涛,韩明,赵礼兵,等.承德某钒钛磁铁矿提铁降钛试验研究[J]. *现代矿业*,2025,41(6):164-167.
WU Chuntao, HAN Ming, ZHAO Libing, et al. Experimental study on iron enrichment and titanium reduction of vanadium-titanium magnetite concentrate in Chengde[J]. *Modern Mining*,2025,41(6):164-167.

(上接第150页)

- [22] 丁成义,常仁德,郭胜兰,等.烧结过程智能控制及烧结冶金性能预测研究现状[J]. *钢铁*,2024,59(4):42-56.
DING Chengyi, CHANG Rende, GUO Shenglan, et al. Research status of intelligent control of sintering process and prediction of metallurgical properties of sinter[J].

Iron and Steel,2024,59(4):42-56.

- [23] 朱德庆,李晓波,潘建,等.镜铁矿粉在铁矿烧结混合料中的制粒行为[J]. *钢铁*,2015,50(7):8-14.
ZHU Deqing, LI Xiaobo, PAN Jian, et al. Investigation of granulation behaviors of specularite fines in ferrous sinter mixture[J]. *Iron and Steel*,2015,50(7):8-14.

江苏省(沙钢)钢铁研究院介绍

江苏省(沙钢)钢铁研究院成立于2007年6月,是江苏省重点研发机构、高新技术企业,主要从事先进钢铁材料和工艺技术的研发与服务。研究院坚持以“国内领先、世界一流”为建设目标,拥有2.3万m²的研发大楼及中试工场,致力开发出高端、先进的钢铁材料和绿色的钢铁生产工艺,并力图减少废弃物排放以及降低能源消耗,以实现沙钢及江苏省钢铁工业的持续发展。沙钢研究院下设七个研究室、一个分析测试中心、一个中试场所以及一个管理部门,涵盖钢铁生产全流程,以及热轧板带材、棒线材、冷轧和超薄带产品。研发方向包括低碳化、先进钢铁材料开发、先进钢铁工艺开发和工艺优化、智能化、环保资源等。研究院每年开展项目约300项,先后承担各级政府项目30余项。通过开展各类研发项目,研究院形成了一系列自主创新知识产权成果,获授权专利765件(其中发明专利634件、国际专利9件),发表论文785篇,先后承担各级政府项目29项,其中国家项目5项,省级项目11项,荣获国家级科技奖二等奖1项、省部级科技奖一等奖10项、二等奖9项。通过科技创新,研究院有力支撑了企业的技术进步和转型升级,每年研发创效超8亿元。