

基于改进的 YOLOv8 的铝合金熔体夹杂物自动分割与 K 模质量智能评价系统

樊攀, 郎玉玲, 刘书基, 魏晨光, 韦春营

(中信戴卡股份有限公司, 河北秦皇岛 066011)

摘要: 铝合金熔体中氧化物夹杂的精确识别与量化评估是提升铸件性能的关键。针对传统K模法(K-mold)人工检测存在的主观性强、效率低且微小夹杂易漏检等问题, 提出一种基于改进YOLOv8的K模质量智能评价系统。首先, 构建了涵盖多尺度夹杂物的金相数据集; 其次, 在YOLOv8s-seg网络中引入P2微小目标检测层, 显著增强了对 $<100\ \mu\text{m}$ 一级夹杂物的特征提取能力; 在此基础上, 建立了基于形态学参数的自动量化与Q值评分模型。试验结果表明, 该系统在保证高精度的同时, 检测效率较人工提升50%, 质量判定结果与资深质检员的一致性达92%。该系统实现了熔体质量的“端到端”智能评估, 为生产过程的在线质量控制提供了可靠的技术支撑。

关键词: 夹杂物图像识别; YOLOv8; 目标分割; 熔体质量评价

中图分类号: TG146.21 **文献标识码:** A **文章编号:** 1001-4977 (2026) 05-0506-07

DOI: 10.27014/j.cnki.zhuzao.2026.0068

Automatic Segmentation of Inclusion and K-Mold Quality Intelligent Evaluation System of Aluminium Alloy Melt Based on the Improved YOLOv8

FAN Pan, LANG Yu-ling, LIU Shu-ji, WEI Chen-guang, WEI Chun-ying

(CITIC Dicastal Co., Ltd., Qinhuangdao 066011, Hebei, China)

Abstract: The precise identification and quantitative evaluation of oxide inclusions in aluminum alloy melt are critical for improving the performances of castings. Addressing the limitations of highly subjective, low efficiency and easy missed detection of micro-inclusion existed in traditional K-mold manual inspection, the K-mold Quality Intelligent Evaluation System was proposed based on an improved YOLOv8. Firstly, a metallographic dataset covering multi-scale inclusions was constructed; secondly, a P2 micro-target detection layer was integrated into the YOLOv8s-seg network to significantly enhance the feature extraction ability for grade 1($<100\ \mu\text{m}$)inclusions; furthermore, an automatic quantization and Q-value scoring model based on morphological parameters was established. The test results showed that compared with manual detection, the detection efficiency of the system was improved by 50% while maintaining high accuracy, and the consistency rate of quality judgement result with senior inspectors reached 92%. This system realized an "end-to-end" intelligent assessment of melt quality, providing robust technical support for online quality control in production.

Key words: inclusion recognition; YOLOv8; object segmentation; melt quality evaluation

在“双碳”目标与节能环保理念的驱动下, 汽车轻量化已成为全球汽车工业发展的必然趋势^[1]。铝合金凭借其优异的比强度与耐腐蚀性, 成为替代传统钢铁材料、实现车身与零部件轻量化的关键材料^[2-6]。然而, 铝合金铸件的力学性能, 特别是疲劳寿命与延展

性高度依赖于熔体的纯净度。熔体中存在的氧化物夹杂不仅会割裂基体连续性, 更是疲劳裂纹萌生的主要源头。因此, 对熔体中夹杂物的数量、尺寸及分布进行精准评估是制备高性能铝合金的前提。

目前, 工业界广泛采用K模法结合金相显微镜来

收稿日期: 2026-01-27 收到初稿, 2026-03-20 收到修订稿。

作者简介: 樊攀 (1985-), 男, 博士。主要研究方向为铝合金低压、差压铸造工艺仿真和铝合金熔体质量控制。电话: 0335-5816923, E-mail: fanpan@dicastal.com

通信作者: 韦春营, 男, 博士。电话: 0335-5359258, E-mail: weichunying@dicastal.com

引用格式: 樊攀, 郎玉玲, 刘书基, 等. 基于改进的 YOLOv8 的铝合金熔体夹杂物自动分割与 K 模质量智能评价系统 [J]. 铸造, 2026, 75 (5): 506-512.

FAN Pan, LANG Yuling, LIU Shuji, et al. Automatic segmentation of inclusion and K-Mold quality intelligent evaluation system of aluminium alloy melt based on the improved YOLOv8 [J]. Foundry, 2026, 75 (5): 506-512.

检测熔体纯净度。然而，现行的评估流程主要依赖人工在显微镜下识别并测量夹杂物，存在显著局限性。首先，人工检测具有强烈的主观性，不同检测人员对微小或模糊夹杂的判定标准不一；其次，人工测量效率低下，难以满足大规模连续生产的实时反馈需求；最后，传统方法难以对夹杂物数据进行统计分析，无法为熔炼工艺优化提供量化依据。

近年来，以卷积神经网络（CNN）为代表的深度学习技术在工业缺陷检测领域取得了突破性进展^[7-14]。目标检测与实例分割算法（如表1所示^[15]）已成功应用于钢铁表面缺陷和织物瑕疵等场景。然而，将其直

接应用于铝合金K模夹杂物检测仍面临挑战：K模断面中的夹杂物通常尺寸跨度大（从几十微米至几毫米），且一级夹杂物（ $<100\ \mu\text{m}$ ）特征微弱，极易在深层网络下采样过程中丢失信息。针对上述问题，本研究旨在建立一套基于改进YOLOv8的铝合金熔体夹杂物自动分割与质量评价系统，构建包含多尺度夹杂物的K模金相数据集；提出一种改进的YOLOv8s-seg网络，通过增加微小目标检测头（P2层），显著提升对一级微细夹杂物的捕获能力；开发自动化的形态学表征算法与熔体质量评分模块，实现从“图像输入”到“质量报告”的端到端自动化。

表1 实例分割算法
Tab. 1 Instance segmentation algorithm

分类	核心思路	代表性算法	优点	缺点
自上而下	先检测，后分割。首先通过目标检测算法识别出每个实例的边界框，然后在每个边界框内进行语义分割，为每个实例生成掩码	Mask R-CNN; Mask Scoring; R-CNN	1. 精度高，是众多竞赛的基准模型； 2. 思路直观，建立在成熟的目标检测框架上； 3. 能够同时输出检测框、类别和分割掩码	1. 速度慢，无法满足实时需求； 2. 严重依赖检测框的准确性，框不准则分割不准； 3. 对密集、重叠对象的效果一般（NMS（Non-maximum suppression））后处理会抑制重叠框
自下而上	先分割，后分组。首先为每个像素生成特征向量或语义标签，然后通过聚类、度量学习等方法将属于同一个实例的像素分组/区分开来	YOLO; YOLACT++; SOLOv2	1. 设计理念新颖，避免了NMS等复杂后处理； 2. 速度快，更易于实现实时分割； 3. 对密集和重叠目标的处理有潜在优势	1. 精度通常低于自上而下方法； 2. 分组或聚类过程可能比较复杂，难以训练； 3. 边缘细节可能不如两阶段方法精细
新范式	受自然语言处理启发，将图像视为序列，使用查询向量（Query）直接从图像特征中“解码”出对象实例的集合	Mask2Former; QueryInst	1. 端到端，避免了手工设计的后处理（如NMS）； 2. 统一架构，一个模型同时擅长语义、实例和全景分割； 3. 性能强劲，在许多基准上达到了领先	1. 训练资源消耗巨大，需要大量算力和数据； 2. 推理速度通常不是最快，模型相对复杂； 3. 可解释性相对较弱

1 研究方法

1.1 算法介绍

本研究是基于YOLO（You Only Look Once）深度学习算法框架，该算法是一种先进的实时目标检测算法，属于自下而上的范畴^[16]。该算法的核心思想是将目标分割的任务重构为一个单一的回归问题，直接从图像像素出发，到边界框坐标和类别概率的映射。与传统的需要“提议区域”再分类的两阶段检测器不同，YOLO效率更高，是进行高帧率实时处理任务的首选。YOLO模型是基于卷积神经网络开发的，自2015年提出以来，经历了从单阶段检测（YOLOv1）到多尺度特征融合（YOLOv3），再到自适应锚框与解耦头设计

（YOLOv6/v8）的演进历程，最后到深度可分离优化（YOLOv11），详见图1。模型的准确性、性能和附加功能随着版本迭代在不断改进。

出于对部署难度、算力成本、维护复杂度和模型精度等综合考虑，本研究决定采用Ultralytics YOLOv8深度学习框架，对K模夹杂物进行目标分割智能识别。YOLOv8的结构示意图如图2所示，该深度学习网络包括三个主要模块：主干网络（Backbone）、颈部网络（Neck）和头部网络（Head）。Backbone模块负责输入图像的特征提取，通过卷积网络、多层级特征金字塔和空间金字塔池化，实现多尺度特征提取。这种类似CSPDarknet^[17]的结构可以有效减少计算量并提高特征提取效率。Neck模块用于实现特征融合和增强。

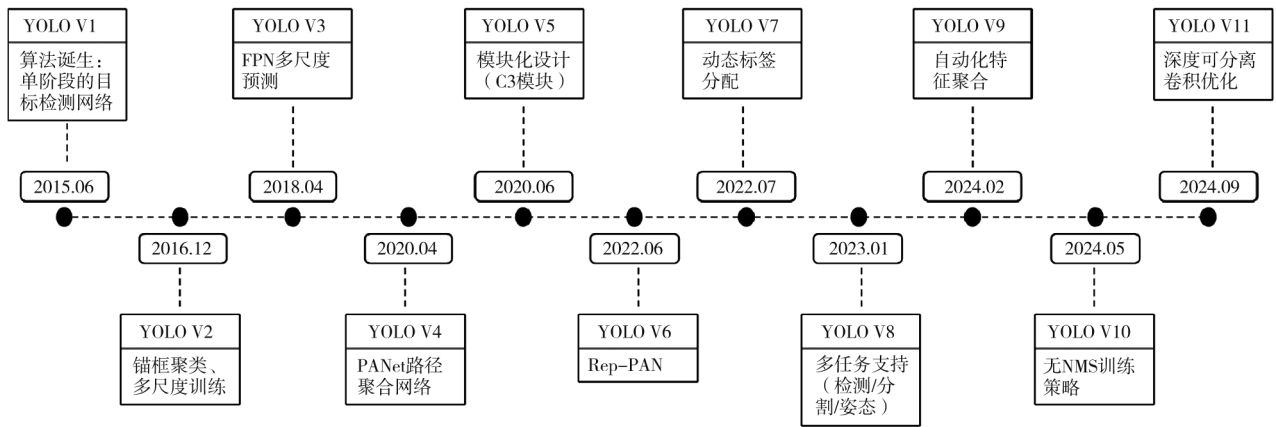


图1 YOLO算法演变
Fig. 1 Evolution of YOLO algorithms

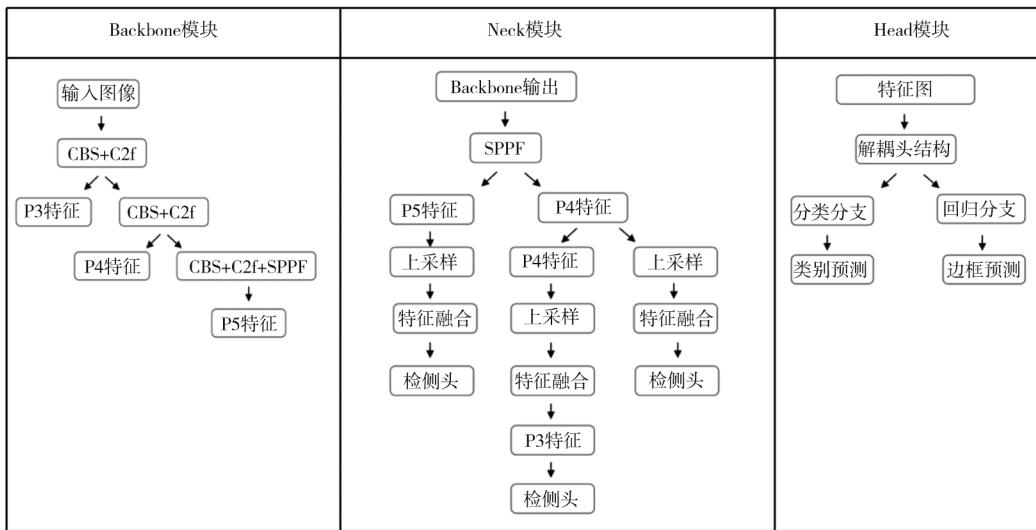


图2 YOLOv8结构示意图
Fig. 2 Schematic diagram of YOLOv8 structure

采用路径聚合网络的思想将高分辨率特征与低层次特征进行融合，提高模型对不同尺度目标的检测能力。Head模块负责对提取到的特征进行分类和边框的回归。

YOLOv8模型对夹杂物图像的分割分为以下几个步骤：

(1) 输入图像预处理：通过几何变换方法随机对图像裁剪、翻转、旋转、平移和镜像以对数据进行扩充，以及通过像素变换方法随机调整图像的对比度、亮度、饱和度、直方图均匀化等对数据进行扩充以模拟不同拍照条件下的图像，提高深度学习模型的性能和鲁棒性；

(2) 特征提取：通过多个卷积层、池化和激活函数等操作，逐步提取图像中的特征信息包含边缘、纹理、颜色等基本特征以及形状和局部结构等更加复杂的模式。

(3) 输出结果：根据提取的特征进行类别识别和

边界框回归并通过非极大值抑制处理以得到最终的目标分割结果。

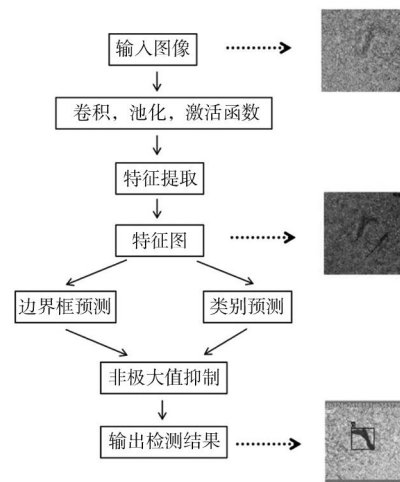


图3 YOLOv8工作流程图
Fig. 3 YOLOv8 workflow chart

1.2 改进 YOLOv8s 增强对小夹杂物识别能力

针对K模断面中一级夹杂物 (<100 μm) 占比高且极易漏检的特点, 对原生YOLOv8结构进行了关键改进, 引入了小目标检测头 (P2 Head)。原生YOLOv8仅输出8倍 (P3)、16倍 (P4) 和32倍 (P5) 下采样的特征图, 导致过于细小的特征在深层网络中丢失。本研究从Backbone的第一层特征 (P2) 引出分支, 构建了一个高分辨率检测头 (160×160特征图), 专门用于捕捉4×4像素以上的微小目标。改进后的YOLOv8s-seg网络结构, Backbone部分没有变化, 只对Neck和Head两部分的结构进行微调以增加小目标检测头。

1.3 模型评价指标

在目标检测中使用 F_1 分数评估模型的精确度, 因为该指标同时兼顾了模型的查准率 (P) 和召回率 (R), 代表的是查准率 (P) 和召回率 (R) 的调和平均数, 数值范围在0到1之间, 越接近1.0, 表明模型在识别正类样本时不仅误判率低, 同时漏检情况也较少, 从而反映出精准率与召回率之间更为均衡和优越的综合性能。其数学表达式为:

$$F_1 = 2 \cdot \frac{P \cdot R}{P + R} \quad (1)$$

查准率的数学含义是所有被判定为正例的样本中, 真实类别为正例的比例, 其数学表达为:

$$P = \frac{TP}{TP + FP} \quad (2)$$

式中: 真阳性 (TP) 表示样本真实类别为正例, 且模型的预测结果也为正例的样本; 假阳性 (FP) 表示样本的真实类别为负例, 但模型预测为正例的样本。而召回率描述了多少正实际样本被模型正确识别到, 其数学表达为:

$$R = \frac{TP}{TP + FN} \quad (3)$$

式中: 假阴性 (FN) 指真实类别为正例, 但模型将其预测为负例的样本。

1.4 技术路线

本研究数据来源于工业生产现场的K模断面金相照片。利用Zeiss SteReo Discovery V8体视显微镜, 在16倍放大倍率下采集断面图像。共构建了包含300张高分辨率金相图像的数据集, 涵盖不同级别全尺寸范围的夹杂物。利用Labelme工具对图像中的夹杂物进行像素级轮廓标注。为防止模型过拟合并不平衡样本分布, 本研究采用马赛克增强 (Mosaic)、随机旋转、镜像翻转及亮度调整等策略对训练集进行扩充。数据集按8:2的比例随机划分为训练集与验证集。其中主机配置13th Gen Intel (R) Core (TM) i7-13700H CPU@2.40GHz, 配备6GB的GPU NVIDIA RTX A1000和16GB的运行内存。开发环境使用 Python (3.9) 和 Pytorch (2.3.1)。图4为本研究工作流程图。

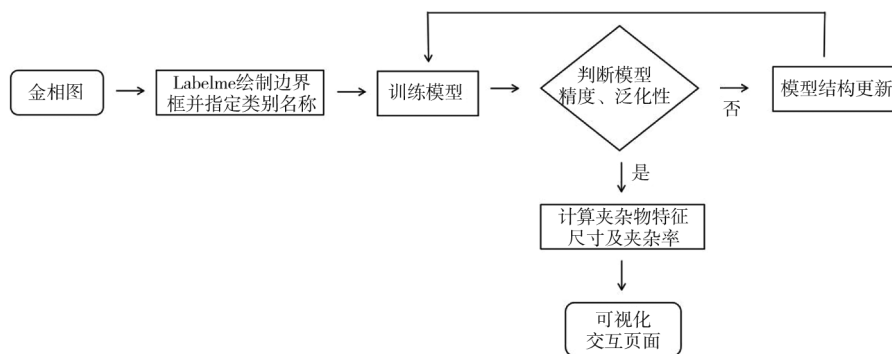


图4 工作流程图

Fig. 4 Workflow diagram

2 结果与讨论

2.1 试验方法与模型参数

本研究以K模法作为铝合金熔体纯净度的基准检测方法, 利用体视显微镜获取高分辨率断面图像。针对每组K模试验, 采集5个断面的金相图像作为模型输入数据。为保证模型训练的有效性与评估的客观性, 依据企业内控标准, 将夹杂物按尺寸划分为5个等级, 覆

盖从A类 (<100 μm) 至E类 (>1 200 μm) 的全尺寸范围 (详见图5)。数据集中各类夹杂物占比分别为: A类35%、B类58%、C类5%、D类1%和E类1%。

在模型训练阶段, 选用YOLOv8s-seg作为基准模型。为模拟复杂的工业现场成像条件并增强模型鲁棒性, 训练过程引入了随机几何变换 (裁剪、旋转和镜像) 及像素增强 (对比度和亮度调整) 策略。训练参数设定如下: 迭代轮次 (Epochs) 为300, 初始学




图5 K模断面照片采集流程及夹杂物尺寸等级分类

Fig. 5 Acquisition workflow of K-mold fracture images and inclusion size grade classification

习率设为0.01，动量参数为0.937。值得注意的是，为充分挖掘模型潜力，本试验未启用早停机制（Early Stopping），以确保模型在全周期内收敛至最优解。

2.2 夹杂物表征方法

为了实现从图像分割到质量评价的跨越，本K模质量智能评价系统定义了两个关键的形态学参数：

(1) 特征面积：由分割掩码（Mask）内所有像素点构成的闭合区域面积，单位换算为平方微米， μm^2 。

(2) 特征长度：定义为闭合轮廓极值点（极北、极南、极东、极西）之间的最大欧氏距离，如式（4）所示。这一算法有效地解决了传统人工测量中取点位置不确定的问题。

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (4)$$

式中： d 为欧式距离， x_1 、 x_2 为两个点的 x 坐标， y_1 、 y_2 为两个点的 y 坐标。

如图6所示，研发的系统能够精确提取不规则夹杂物的轮廓，并自动计算出其特征长度（如示例中的 $719.46 \mu\text{m}$ ），将其准确归类为三级夹杂物。这种自动化表征方式消除了人工测量的视差与主观误差。

2.3 模型精度分析

本研究采用F1分数（F1-Score）作为衡量模型精度的核心指标，该指标综合权衡了查准率（Precision）




图6 夹杂物分割与尺寸表征方法

Fig. 6 Inclusion segmentation and its size characterization method

与召回率（Recall）。综合考虑工业现场对漏检（Recall）和误检（Precision）的容忍度，设定 $F_1 \geq 0.7$ 为模型满足工业应用要求的基准阈值。如果训练完成的模型在验证集上的 F_1 分数低于该预设阈值，说明模型在当前参数设置下尚未达到理想状态，此时可采取多种策略以优化其表现。常见的手段包括增加训练过程中的训练轮次（Epochs）或扩大批次大小（Batch Size）。增加迭代次数能够使模型更充分地学习数据中的潜在特征与复杂模式，而适当增大批次大小则有助于提升梯度估计的稳定性，从而促进模型收敛。试验结果显示，训练轮次对模型性能有显著影响，如表2所示。

表2 模型迭代次数对评价指标的影响

Tab. 2 The impact of epoch numbers on evaluation metrics

项目	训练轮次	F_1 分数	置信度
测试案例1	50	0.61	0.167
测试案例2	150	0.65	0.353
测试案例3	300	0.73	0.337
测试案例4	450	0.71	0.321

随着迭代次数从50增加至300， F_1 分数由0.61显著提升至0.73，同时检测框的平均置信度也由0.167增至0.337。这表明模型对特征的提取能力随训练深度逐步增强。当训练轮次超过300（如450轮）时， F_1 分数波动在0.71左右，未见进一步显著提升。基于计算效率与性能的平衡，确定300轮为最佳训练周期。

在模型训练过程中，随着迭代次数的增加，模型对夹杂物特征的学习更为充分，目标检测的召回率与综合识别能力逐步提升，进而使得 F_1 分数上升。而模型置信度出现一定程度下降，主要原因在于训练后期模型能够识别更多小尺寸、低对比度及边缘特征目标，此类目标本身置信度偏低，同时模型为兼顾检测完整性，会适当降低判定阈值，导致整体置信度水平有所回落。

2.4 模型泛化性分析

针对工业场景中常见的小样本与多尺度问题，本研究对比了YOLOv8s-seg（参数量11.8M）与YOLOv8m-seg（参数量27.3 M）的表现（图7）。虽然m系列模型参数量更大，但在本研究的特定数据集上表现出了一定的过拟合迹象。在测试图像2中，YOLOv8m-seg未能识别出任何目标，出现漏检，而参

数量较小的YOLOv8s-seg则成功识别出3个目标。尽管YOLOv8s-seg泛化性较好，但对于<100 μm的一级微小夹杂物仍存在检出难度。通过引入针对性的P2检测头（改进后的YOLOv8s-p2-seg），模型成功捕获了原模型遗漏的微细特征（图7中图像2与图像3的对比）。这一结果证实，针对K模断口中微小夹杂物的分布特性，优化网络结构比单纯增加网络深度更为有效。

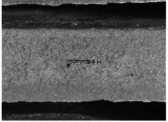
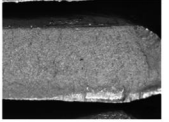
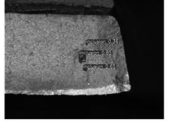
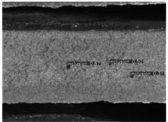
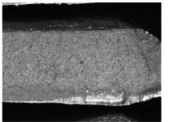
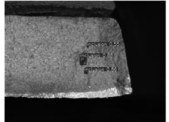
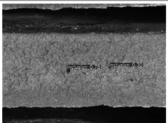
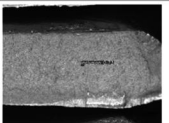
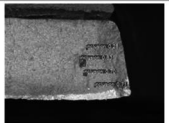
模型	图像1	图像2	图像3
YOLOv8m-seg			
YOLOv8s-seg			
YOLOv8s-p2-seg			

图7 模型结构对其泛化能力的影响

Fig. 7 The impact of model structure on its generalization ability

2.5 熔体质量自动评价

依据行业标准，采用夹杂率（ Q 值）作为熔体纯净度的最终量化指标。该指标通过加权计算不同尺寸夹杂物的影响因子 IF 得出，如式（5）与式（6）所示。其中大尺寸夹杂物被赋予更高的权重（如五级夹杂权重为2），以反映其对熔体质量的综合危害。当 $Q \leq 0.8$ 时，判定熔体质量合格。

$$IF = n_{\text{一级}} \times 0.1 + n_{\text{二级}} \times 0.5 + n_{\text{三级}} \times 1 + n_{\text{四级}} \times 1.5 + n_{\text{五级}} \times 2 \quad (5)$$

$$Q = IF / 5 \quad (6)$$

式中： $n_{\text{一级}}$ 至 $n_{\text{五级}}$ 分别为2.1章节中A类至E类夹杂物的统计个数，一级至五级与A类至E类夹杂物为尺寸等级的对应表述。

2.6 工业场景实测对比

为验证K模质量智能评价系统的实用性，将其应用于13个实际炉次的质量判定，并与资深质检员的人工检测结果进行对比。首先，自动系统显著提升单图检测效率。如图8所示，K模质量智能评价系统可以达到相同的识别精度，但其检测效率较人工相比可提升50%，实现了从“离线事后分析”向“近实时在线评价”的转变。

在13炉次的批量验证结果中（图9），K模质量智能评价系统与人工判定的夹杂率平均计算误差为18%。




图8 单图像人工与K模质量智能评价系统检测结果对比

Fig. 8 Comparison of detection results between manual and K-mold Quality Intelligent Evaluation System for single images

若以夹杂率0.8作为熔体纯净度是否达标的判定阈值，二者在合格性判断上的一致性达到92%，仅在第8炉次出现判定分歧。经复核，该分歧主要是由于人工检测时对边界模糊、尺寸细小的夹杂物存在主观忽略，而算法模型始终保持统一、客观的检出标准。结果表明，所构建的K模质量智能评价系统不仅具备替代人工检测的可行性，还能提供更稳定、更一致的质量判定依据，有利于提升生产过程中质量控制的稳定性与可靠性。




图9 13炉次人工与K模质量智能评价系统检测结果对比

Fig. 9 Comparisons of detection results between manual and K-mold Quality Intelligent Evaluation System for 13 heats

3 结论

(1) 基于实际生产需求, 以K模断面的金相图像数据为基础, 完成了对夹杂物的目标分割任务, 为实现铝合金熔体纯净度的自动化评估提供了数据支持。

(2) 在构建深度学习模型时, 采用YOLOv8s-seg框架有效避免了因模型参数过多而导致的泛化能力下降问题。此外, 针对小尺度夹杂物识别, 提出了一种改进方法, 通过在原有YOLOv8s-seg架构中添加额外

检测头, 显著提升了尺度小于100 μm 的一级夹杂物的识别性能。

(3) 提出的夹杂物尺寸表征方法规范了尺寸计算标准, 提高了尺寸计算的准确性和效率, 减少了人工测量所造成的数据不一致性。在熔体纯净度指标评定方面, K模质量智能评价系统与人工检测的一致性达到92%, 显示出良好的可靠性与实用价值。相较于人工识别, 该系统具有标准化程度高、轮廓识别更精确、夹杂尺寸误差小以及识别效率高等优势。

参考文献:

- [1] 顾翔华. 我国汽车行业运行现状及未来发展趋势 [J]. 中国橡胶, 2010, 26 (24): 4-8.
- [2] 郑晖, 赵曦雅. 汽车轻量化及铝合金在现代汽车生产中的应用 [J]. 锻压技术, 2016, 41 (2): 1-6.
- [3] 马鸣图, 易红亮, 路洪洲, 等. 论汽车轻量化 [J]. 中国工程科学, 2009, 11 (9): 20-27.
- [4] 范子杰, 桂良进, 苏瑞意. 汽车轻量化技术的研究与进展 [J]. 汽车安全与节能学报, 2014 (1): 1-16.
- [5] INGARAO G, LORENZO R DI, MICARI F. Sustainability issues in sheet metal forming processes: an overview [J]. Journal of Cleaner Production, 2011 (19): 337-347.
- [6] 郭玉琴, 朱新峰, 杨艳, 等. 汽车轻量化材料及制造工艺研究现状 [J]. 锻压技术, 2015, 40 (3): 1-6.
- [7] 寇旭鹏, 刘帅君, 麻之润. 基于 Faster-RCNN的钢带缺陷检测方法 [J]. 中国冶金, 2021, 31 (4): 77-83.
- [8] 沈园竣, 马飞跃, 谭廖麟. 人工智能识别在金相检验中的发展现状与展望 [J]. 物理测试, 2024 (3): 59-63.
- [9] 梁印, 朱航宇, 罗林根, 等. 基于深度学习钢中非金属夹杂物图像识别 [J]. 钢铁, 2023, 58 (12): 62-70.
- [10] 宋明明, 门超奇, 谢毓敏, 等. 自动统计在夹杂物分析过程中的应用 [J]. 钢铁研究学报, 2022, 34 (4): 334-340.
- [11] 胡嘉成, 王向阳, 刘晗. 基于深度学习的连铸坯表面缺陷检测 [J]. 上海大学学报 (自然科学版), 2019, 25 (4): 334-340.
- [12] 冀智, 高浩然, 刘国奇, 等. 轻量化YOLOv8的小样本钢板缺陷检测算法 [J]. 计算机工程与应用, 2024, 60 (9): 90-100.
- [13] 廖晓群, 李丹, 徐清训. 基于深度学习的钢板表面缺陷检测研究综述 [J]. 计算机测量与控制, 2025, 33 (7): 1-10.
- [14] 宁安安, 胡安明. 基于改进的Yolov5s钢板表面缺陷检测模型研究 [J]. 软件导刊, 2025, 24 (8): 65-71.
- [15] 苏丽, 孙雨鑫, 苑守正. 基于深度学习的实例分割研究综述 [J]. 智能系统学报, 2022, 17 (1): 16-31.
- [16] JEGHAM N, KOH C Y, ABDELATTI M, et al. YOLO evolution: a comprehensive benchmark and architectural review of YOLOv12, YOLOv11 and their previous versions [EB/OL]. [2024-10-31]. <https://doi.org/10.48550/arXiv.2411.00201>.
- [17] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN [C/OL]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). IEEE: 1571-1580.
- [18] 探索UltraLytics YOLOv8 [EB/OL]. [2023-01-10]. <https://docs.ultralytics.com/zh/models/yolov8/>.