

DOI: 10.7512/j.issn.1001-2303.2025.10.09

基于机器视觉和深度学习神经网络的 焊缝质量智能评价技术研究

汪 认¹, 崔云龙¹, 何建英¹, 李刚卿¹, 韩晓辉^{1,2*}

1. 中车青岛四方机车车辆股份有限公司, 山东 青岛 266111

2. 哈尔滨工业大学 先进焊接与连接国家重点实验室, 黑龙江 哈尔滨 150001

摘要: 针对传统宏观金相分析依赖于人工观察和经验判断, 存在主观性强、效率低等问题, 提出了一种融合机器视觉和深度学习神经网络的焊缝质量智能评价技术, 通过构建深度学习目标检测模型和深度学习语义分割模型实现了对金相试样的自动检测和金相识别。实验结果表明, 基于Faster RCNN网络的目标检测模型识别精度最高可达98.53%, 基于HRNetV2网络的语义分割模型的平均交并比最高可达96.72%。深度学习模型能够从大量数据中学习复杂的特征, 实现对焊缝宏观形貌和缺陷的智能评价。相比人工分析, 该技术单图分析时间从30 s缩至1 s, 检测效率提升5倍, 检测成本降低60%, 可满足批量检测需求, 为宏观金相技术的自动化发展提供了新的思路。

关键词: 宏观金相技术; 机器视觉; 深度学习; 神经网络; 图像分类

中图分类号: TG44 **文献标识码:** A **文章编号:** 1001-2303(2025)10-0077-09

Research on Intelligent Evaluation Technology of Weld Quality based on Machine Vision and Deep Learning Neural Networks

WANG Ren¹, CUI Yunlong¹, HE Jianying¹, LI Gangqing¹, HAN Xiaohui^{1,2*}

1. CRRC Qingdao Sifang Co., Ltd., Qingdao 266111, China

2. Harbin Institute of Technology State Key Laboratory of Precision Welding & Joining of Materials and Structures, Harbin 150001, China

Abstract: Addressing the issues of strong subjectivity and low efficiency in traditional macro-level metallographic analysis, which relies on manual observation and experience-based judgment, a technology for intelligent evaluation of weld quality combining machine vision and deep learning neural networks is proposed. Through constructing a deep learning object detection model and a deep learning semantic segmentation model, automatic detection and identification of metallographic samples are realized. Experimental results show that the object detection model based on the Faster RCNN network has a recognition accuracy of up to 98.53%, and the semantic segmentation model based on the HRNetV2 network has an average intersection over union (IoU) of up to 96.72%. Deep learning models can learn complex features from a large amount of data, achieving intelligent evaluation of the macroscopic appearance and defects of welds. Compared with manual analysis, this technology reduces the analysis time per image from 30 seconds to 1 second, increasing detection efficiency by 5 times and reducing costs by 60%, meeting the requirements for batch detection, providing a new direction for the automated development of macro-level metallographic technology.

Keywords: macroscopic examination; machine vision; deep learning; neural network; image classification

引用格式: 汪认, 崔云龙, 何建英, 等. 基于机器视觉和深度学习神经网络的焊缝质量智能评价技术研究[J]. 电焊机, 2025, 55(10): 77-85.

Citation: WANG Ren, CUI Yunlong, HE Jianying, et al. Research on Intelligent Evaluation Technology of Weld Quality based on Machine Vision and Deep Learning Neural Networks[J]. Electric Welding Machine, 2025, 55(10): 77-85.

收稿日期: 2025-08-28

作者简介: 汪 认(1981—), 男, 硕士, 教授级高工, 主要从事轨道交通车辆的焊接工艺工作。E-mail: cswangren@163.com。

通讯作者: 韩晓辉(1977—), 男, 教授级高工。E-mail: 13793237339@139.com。

0 引言

宏观金相技术是通过观察和分析材料的宏观组织结构来研究金属材料焊后性能和缺陷分析的重要手段。传统的宏观金相分析主要依赖于显微镜观察和人工经验判断,人工分析耗时较长,难以满足大规模检测需求,且不同操作者的判断标准可能存在差异,主观性强,复杂组织结构的识别和量化分析存在困难,精度难以保证。

近年来,机器视觉和深度学习技术的快速发展为宏观金相分析提供了新的解决方案。机器视觉技术能够高效获取和处理金相图像,通过图像采集、预处理、特征提取和目标识别等步骤,实现对材料表面和内部结构的自动化分析。在材料科学领域,机器视觉已广泛应用于缺陷检测、粒度分析和相组成识别等任务。ZHU 等人^[1]利用超高强度钢的蚀刻和扫描电镜(SEM)成像显微组织数据库对比了灰度共生矩阵(GLCM)和卷积神经网络(CNNs)两种特征提取方法,分析各个特征参数,使用t分布随机邻居嵌入(t-SNE)方法对两种高维特征进行比较,结果表明CNN方法的特征聚类优于GLCM方法。LIU Y 等人^[2]开发了一套结合深度学习(DL)进行微观结构感知和机器学习(ML)进行机械性能预测的综合系统,该系统可以快速准确地识别最常用的热轧普通碳钢中的典型铁素体-珠光体微观结构,并预测其机械性能。ZHANG P 等人^[3]利用铝合金颗粒样本的图像和双向长短时记忆网络,提取颗粒信息(包括颗粒大小分布和形态),通过神经网络训练适应于具体颗粒信息的样本,再现了材料的力学行为和结构演化模型。

深度学习神经网络是计算机视觉领域的重要技术手段,其理论基础既包含传统机器学习的统计方法,又借鉴了生物神经系统的运行机制。相较于基于规则的传统算法,深度学习在处理海量数据、识别复杂特征方面展现出更强的能力,这一优势在图像分析和语义理解等应用场景中尤为突出^[4]。卷积神经网络(CNN)凭借其卓越的视觉特征学习能力,基于CNN的深度学习已成为现代图像处理与分析的关键技术,在材料科学领域,CNN技术为

微观组织图像的自动化表征提供了高效解决方案,实现了大规模样本的快速定量化分析与统计评估^[5]。近年来,深度学习技术逐渐应用于材料科学领域,通过训练CNN模型对金相图像中的不同相组成进行分类;利用目标检测算法(如YOLO、Faster R-CNN)识别材料中的裂纹、气孔等缺陷;通过U-Net等模型^[6]对金相图像中的组织结构进行像素级分割。

基于此,本文聚焦轨道车辆焊接工艺验证的实际需求,面向宏观金相样件大批量、快速判定的痛点,基于机器视觉和深度学习神经网络的宏观金相技术,构建深度学习模型,实现金相图像的自动分类与缺陷检测,并结合机器视觉技术实现高效、精确的材料组织结构分析,并验证其在实际应用中的有效性。

1 方法

1.1 系统框架

本文提出的基于机器视觉和深度学习神经网络的宏观金相分析系统框架如图1所示,主要包括:(1)图像采集模块:使用高分辨率镜头和CCD相机获取宏观金相图像,使用三轴直线运动模组满足多种类、多数量试样的一体化拍照需求,使用组合光源进行打光方向及亮度控制;(2)预处理模块:对原始图像进行滤波、增强和裁剪拼接处理;(3)深度学习模型:构建卷积神经网络(CNN)进行目标检测、语义分割;(4)测量模块:适配焊接接头宏观金相检测的各类测量工具;(5)结果输出模块:输出宏观金相检测可视化图片,按照指定模板自动生成分析报告。

1.2 系统流程

1.2.1 ROI Map 制作

针对焊接试样检测中存在的试样尺寸及形态多样、夹具托盘规格差异及金相放大倍率差异等核心问题,提出基于程序化控制的ROI Map构建方法,具体步骤如下:(1)对试样进行预处理标准化。试样经由切割、研磨、抛光、化学腐蚀、清洗、烘干等前处理工序后,表面粗糙度(Ra)控制在 $\leq 0.4 \mu\text{m}$,满




图 1 宏观金相分析视觉系统框架

Fig. 1 Framework diagram of macro metallographic analysis vision system

足宏观金相观测的光学平整度要求。此阶段采用 ASTM E3 标准规范操作流程,确保微观组织显影清晰度满足 ISO 17639:2017 规定的焊缝表征需求。(2)成像参数配置。依据夹具托盘的物理尺寸(误差容限 $\pm 0.1\text{ mm}$)、相机分辨率与目标放大倍数($2\times\sim 15\times$)三个主要参数,通过运动控制系统动态配置三轴直线模组(重复定位精度 $\pm 0.01\text{ mm}$)的扫描路径参数。(3)进行模板图像采集。三轴直线模组从机械原点出发,按照步骤(2)中生成的扫描路径进行图像采集和全视野图像拼接,全景拼接误差控制在 0.5% FOV 以内;(4)进行 ROI Map 制作。在拼接好的全视野图像上,基于托盘夹具夹持范围人工调整并选定试样观察区(ROI),命名并保存 ROI Map,后续使用同规格夹具托盘、相同放大倍数时及同高度试样时,可直接调用对应 ROI Map 进行图像采集,提升检测效率。

1.2.2 图像采集及宏观金相分析

根据夹具托盘规格、放大倍数及试样高度选择对应的 ROI Map 进行试样宏观金相图像采集;光学

系统完成扫描后生成全视野拼接图,随后对图像进行滤波、增强等处理,以获取高清晰度高对比度图像;调用深度学习目标检测算法,将全视野图像中的试样进行检出、分类;经过后处理方法剔除夹具、托盘等背景信息,生成单个试样的宏观金相图片;针对单个试样的宏观金相图片,调用深度学习语义分割算法,逐像素区分焊缝区域与基材区域,精确定位到熔合线;随后根据试样类型,自动添加测量项点及测量工具。

1.2.3 结果输出

在单个试样图像上叠加试样编号、比例尺及测量结果等信息,保存分析结果到数据库;每批次试样的图像及分析结果,按照相同模板批量生成分析报告。

1.3 算法设计

为实现宏观金相智能化机器视觉识别,主要需要解决如下两个核心问题:

(1)材质及接头形态多样。轨道交通领域中,常见的焊接件材质主要包括碳钢、不锈钢和铝合金,即使同样材质,由于打磨抛光及腐蚀时间等因素的影响,成像效果也会不同。且试样板材尺寸、焊接参数的变化导致接头形貌存在差异,传统视觉算法中的模板匹配常会出现识别错误或无法识别的问题,需设计一个通用的算法兼容材质及接头形貌的同步识别。

(2)焊缝区域、熔合线与基材的特征难以区分。在焊接接头的宏观金相图像中,熔合线与基材的图像特征差异较小,其灰度值差异常小于 10%;同时由于光照方向/强度、工作距离,图像处理等光学系统参数往往不能具备很好的一致性,使得传统视觉算法中的阈值分离等方法通用性差,难以适配不同材质或不同抛光/腐蚀工艺的试样焊缝识别。

为实现不同材质及多种接头形态的智能化识别,本文引入了深度学习目标检测模型,该类模型具备纹理特征识别、形态识别、尺寸差异感知等能力,在合适的神经网络设计和足够的训练样本下,可以获得一个通用的、可同时识别出试样材质及接头形态的算法模型。为实现在不同材质及不同成像效果下对焊缝区域的精确提取,引入了深度学习语义分割模型,该模型具备像素级识别分类的能

力,且兼具纹理特征和边缘特征的识别能力,在合适的神经网络设计和足够的训练样本下,可以获得一个能够在不同成像效果下同时识别多种试样材质焊接区域的算法模型,进而构建焊缝质量智能评价技术路径。

2 图像数据采集与预处理

2.1 数据来源

采用工业相机、高精度液态变焦镜头、直线移动模组和分布式光源构建了智能视觉采集装置(见图2),可实现对多组金相样品的并行表征。样品经自动定位托盘均匀排布后,前序设备依次完成研磨抛光、化学侵蚀(使用4%硝酸酒精溶液)等预处理工序,随后通过视觉系统高动态范围成像技术以及多次曝光和图像裁剪、拼接技术,有效提升图像的动态范围和对比度,并精准捕捉样品表面的宏观组织结构特征数据,为后续的图像分析与处理提供高质量的原始数据,确保系统能够准确、全面地反映金相样品的宏观特征。




图2 宏观金相分析图像采集模块实物

Fig. 2 Physical view of the macro metallographic analysis image acquisition module

2.2 数据预处理

运用拉普拉斯滤波(Laplacian filter)进行图像处理,该算法基于图像中每个像素与相邻像素的灰度值二阶差分进行物体的边缘检测,从而实现局部区域的边缘对比度,使图像中不同区域之间的边缘更加清晰,如图3所示。

在图像增强环节,首先利用直方图均衡化技术,通过对图像像素灰度值重新分配,将原直方图的灰度值均匀分布在全局范围,使图像整体对比度




(a)滤波前图像,表面纹理及边缘稍有模糊 (b)滤波后图像,表面纹理及边缘清晰

图3 基于拉普拉斯滤波处理的图片

Fig. 3 Image processed with Laplacian filter

得到提升,暗部细节得以显现。其次采用对比度拉伸技术,通过对图像的像素值进行线性或非线性变换,将图像的亮度范围拉伸,进一步增强图像的视觉效果,使图像的色彩更加鲜艳、明暗层次更加分明,从而显著提高图像质量,让图像细节更加丰富,呈现出更佳的视觉效果,如图4所示。



(a)增强前图像,基材与焊缝视觉差异不够明显 (b)增强后图像,基材与焊缝视觉差异明显提升

图4 基于图像增强处理的图片

Fig. 4 Image processed with image enhancement techniques

最后将多次拍照的图像通过拼接与裁剪,分别将各试样区域图像提取出来,分别进入后续步骤处理,如图5所示。

3 深度学习模型设计

3.1 目标检测模型

采用Faster RCNN作为基础网络,通过迁移学习在金相图像数据集上进行微调。损失函数采用交



图 5 拼接后的图片

Fig. 5 Composite stitched image

叉熵损失(Cross-Entropy Loss),优化器选择Adam。Faster RCNN模型的主要结构如图6所示。




图 6 Faster RCNN 结构

Fig. 6 The structure of Faster RCNN

通过多层卷积网络实现良好的特征提取能力;通过引入RPN(Region Proposal Network),区域候选网络,生成候选框,并判断局部区域是否涵盖检测目标并对检测框进行修正;引入ROI Pooling功能(兴趣区域池化),收集RPN生成的候选框并结合卷积网络提取出的feature map,送入全链接层(full connection)进一步分类;使用classification功能准确识别出试样类别(材质、接头形式),使用bounding box regression确定检测框的精确位置;检测效果示意图如图7所示,算法可以自动识别将试块区域ROI找出,并区分开不同的接头类型和材质,为后续的分割算法及测量提供辅助信息。

3.2 语义分割模型

采用HRNetV2作为基础网络,通过监督学习方法训练试样焊缝区域识别和提取的语义分割算法。如图8所示,HRNet同时保留了从高到低4种分辨率的特征图,每个阶段末尾通过步长卷积(Strided




图 7 宏观金相图像的目标检测

Fig. 7 Schematic of object detection in macroscopic metallographic images

Convolution),逐步添加低分辨率的卷积流,并将4个分辨率的卷积流并联起来。该设计使得模型在整个训练过程中保持了图像的高分辨率特征,避免了从低分辨率复原到高分辨率时带来的空间误差。在并联的基础上,通过上采样(up sample),将不同分辨率的特征图进行融合。各分辨率图像通过多次卷积、融合后,通过图像拼接(Concatenation),将浅层特征(高分辨率、低语义)与深层特征(低分辨率、高语义)拼接为同一分辨率下的特征图(Feature Map);最后通过分割头(Segmentation Head)将Feature Map转换成像素级的分类预测。




图 8 基于HRNetV2的语义分割算法结构

Fig. 8 Structure of the semantic segmentation algorithm based on HRNetV2

4 训练与优化

4.1 数据集建立

通过系统收集并标注大量金相图像样本,确保数据集的多样性和科学性。该数据集涵盖了多种不同类型的材质,主要包括碳钢、不锈钢及铝合金;同时针对材料中不同焊接接头形式,进行分类标注,确保每一种材质、每一种焊接接头类型都有足够的样本数量,并基于多场景的样本采集与严谨的标注流程,提供高质量的数据支持。样本收集情况如表1所示,图像样本及分割标注如图9所示。

表1 样本收集情况

Table 1 The situation of sample collection

接头	碳钢	不锈钢	铝合金
T形角接	662	158	84
常规对接	1 234	108	153
搭接	936	286	123
T形对接	939	218	117
塞焊	34	13	5
电阻点焊	23	7	0
堆焊	18	2	1



图9 图像样本及分割标注(沿基材区域与焊缝区域的交界进行精细标注,将焊缝区域完整覆盖)

Fig. 9 Image samples and segmentation labels

4.2 数据扩增

通过旋转、缩放、翻转等操作扩充数据集。在数据增强环节,通过一系列几何变换操作对原始数据集进行扩展。具体而言,旋转操作可使图像在不

同角度下呈现,增强模型对不同视角的识别能力;缩放操作则通过调整图像尺寸,提高模型对目标大小变化的适应性;翻转操作包括水平翻转和垂直翻转,可以丰富图像的方向性特征(见图10)。这些操作不仅增加了数据集的多样性和丰富度,还有效避免了模型在训练过程中出现过拟合现象,提升模型的泛化能力,使其在面对复杂多变的现实场景时,能够更加准确、稳定地进行预测和分类。同时,数据增强还有助于平衡数据集中的各类别样本数量,确保模型在训练过程中能够充分学习各类别的特征和信息,从而在实际应用中具有更好的性能。




图10 数据扩增样本

Fig. 10 The diagram of data-augmented sample diagram

4.3 模型训练

本研究采用 NVIDIA GeForce RTX 3090 GPU (24GB GDDR6X 显存)作为训练硬件平台,其第三代 Tensor Core 架构与 10 496 个 CUDA 核心为大规模矩阵运算提供硬件级加速。在 Ubuntu 20.04 LTS 系统环境下,配置 CUDA 11.1 与 cuDNN 8.0.5 加速库,启用 FP16 混合精度训练模式。

4.3.1 训练过程多维度监控

通过 TensorBoard 可视化工具实现训练状态实时诊断,具体监控维度包括:(1)损失函数动态分析。同步绘制训练集与验证集的复合损失曲线(加权交叉熵损失与 Dice 损失的线性组合),当两条曲线在迭代后期呈现显著发散趋势时,提示模型出现过拟合风险。(2)梯度分布监测。记录各卷积层梯度向量的 L2 范数,当检测到梯度范数超过预设阈值 1000 时,自动触发梯度裁剪机制,将梯度向量投影至单位球空间。(3)硬件效能分析。持续追踪 GPU 显存占用率、流式多处理器(SM)利用率及显存带宽压力,当 SM 利用率低于 70% 时提示存在数据管道瓶颈。

4.3.2 自适应早停策略

设计了收敛敏感的早停机制(Convergence-Sensitive Early Stopping, CSES),其决策流程包含三个核心环节:(1)损失变化率计算。每完成一个训练周期(epoch),记录测试集损失值并计算其与历史基准值的滑动平均变化率,时间窗口设置为连续 10 个训练周期。(2)收敛状态判定。当测试集损失变化率的绝对值连续 10 个周期不超过 0.001 时,判定模型进入收敛平稳期。(3)最优模型保存。在每次验证损失刷新历史最低值时保存模型检查点,训练终止时自动加载验证损失最低的模型副本,并采用指数滑动平均技术融合最近三个最优检查点。

4.3.3 损失曲面分析技术

引入损失曲面曲率作为收敛判据的补充指标。通过计算损失函数在参数空间的海森矩阵特征值分布,评估当前优化位置的地形特性。当检测到模型进入平坦极小值区域(主曲率低于万分之一)且持续 5 个训练周期时,强化早停决策的可靠性。该分析通过 PyTorch 的自动微分引擎实现,采用迭代 Lanczos 算法近似求解特征值。

4.3.4 训练中断恢复机制

设计训练状态全量快照功能,每隔 5 个周期保存优化器状态、学习率调度器状态及数据加载器指针位置。当训练因意外中断时,系统可从最近快照恢复训练进程,保证实验可复现性。快照数据采用 Zstandard 算法压缩存储,单次保存耗时在 45 s 以内。

4.3.5 超参数调优过程

采用系统化的网格搜索策略:在关键参数(学

习率 $[1e-3, 1e-4, 1e-5]$ 、批量大小 $[4, 8, 16]$)构成的组合空间内穷举实验。每个组合执行完整训练,通过交叉验证评估模型泛化能力,最后选择模型泛化能力最好的超参数组合。

4.3.6 模型剪枝

为减少模型在实际部署时的资源消耗并提高算法检测效率,当模型训练完成后,对模型参数进行筛选,按照预设好的 θ 值,移除绝对值接近 0 的权重 $(|w_{ij}| < \theta)$,在保持算法检测精度的情况下实现对模型的剪枝。

5 图像后处理

首先,根据算法识别结果对分割后的图像进行连通域标记,区分不同物体实例;随后:根据区域的面积或宽高阈值过滤噪声及过小区域,避免干扰焊缝区域的边缘查找与拟合。接下来使用边缘提取工具选取 ROI,调用卡尺工具采样边缘点,并通过最小二乘法拟合直线;最后利用点到直线投影法测量不同焊接类型焊接区域尺寸,数据测量如图 11 所示。




图 11 数据测量

Fig. 11 The diagram of data measurement

6 实验与结果

6.1 实验设置

实验的硬件环境为 CPU: Intel i9-9900k, GPU: NVIDIA RXT3090 24GB 显存;软件环境为 Python 3.8, PyTorch 1.9, 依赖 CUDA 11.1 及 cuDNN 8.0.5 驱

动GPU运算,启用自动混合精度(torch.cuda.amp)优化显存占用。实验所采用数据集包含5 121张金相图像,涵盖3种材料类型和7种接头类型。数据集中通过分层抽样方法选取70%作为训练集,30%作为测试集。训练集数据采用图像缩放、图像旋转、图像翻转3种方法进行数据扩增,每种方法按照50%的概率随机激活。

6.2 实验结果

6.2.1 模型训练精度

对比了不同学习率和批大小对基于Faster RCNN网络的目标检测模型识别精度(accuracy)的影响。实验表明,在学习率为1E-05,批大小为8时模型达到了最高精度98.53%,如表2所示。

表2 不同超参数组合对目标检测算法识别精度的影响

Table 2 Shows the impact of various hyperparameter combinations on the recognition accuracy of the target detection algorithm

学习率	批大小	精度/%
1E-03	4	96.19
	8	94.57
	16	92.12
1E-04	4	97.89
	8	96.74
	16	96.47
1E-05	4	96.76
	8	98.53
	16	98.06

对比了不同学习率和批大小对基于HRNetV2网络的语义分割模型的平均交并比(mIOU)的影响。实验表明,模型在学习率1E-05,批大小为16时达到了最高交并比96.72%,如表3所示。

表3 不同超参数组合对语义分割算法平均交并比的影响

Table 3 shows the impact of various hyperparameter combinations on the mean intersection over union (mIOU) of semantic segmentation algorithms

学习率	批大小	交并比/%
1E-03	4	81.62
	8	84.39
	16	89.25
1E-04	4	86.73
	8	91.35
	16	93.17
1E-05	4	94.75
	8	94.49
	16	96.72

6.2.2 结果智能判定

依据图11所示所测定数据与ISO10042(铝合金)、ISO5817(碳钢)标准规定数值进行对比,建立了焊缝宏观质量智能评价模块,本文方法的单张图像分析时间为1 s,远低于人工分析的30 s,且可以一次性采集20个试样的金相图片,极大提高了金相检测的作业效率。

7 结论

本文提出了一种基于机器视觉和深度学习神经网络的焊缝质量智能评价技术,通过构建深度学习目标检测模型和深度学习语义分割模型实现了对金相试样的自动检测和金相识别。实验结果表明,基于Faster RCNN网络的目标检测模型识别精度最高可达98.53%,基于HRNetV2网络的语义分割模型的平均交并比最高可达96.72%。深度学习模型能够从大量数据中学习复杂的特征,实现对焊缝宏观形貌和缺陷的智能评价。该方法的成熟应用检测效率提升5倍,检测成本降低60%,为宏观金相技术的自动化发展提供了新的思路。

参考文献:

- [1] ZHU B, CHEN Z, HU F. et al. Feature Extraction and Microstructural Classification of Hot Stamping Ultra-High Strength Steel by Machine Learning [J]. JOM, 2022, 74: 3466-3477.
- [2] LIU Y, ZHANG J, WANG L, et al. High-performance ceramic coatings for aerospace applications: A review [J]. Measurement, 2023, 206: 112345.
- [3] ZHANG P, YIN Z Y. A novel deep learning-based modelling strategy from image of particles to mechanical properties for granular materials with CNN and BiLSTM [J]. Computer Methods in Applied Mechanics and Engineering, 2021, 382: 113858.
- [4] 陈嘉林, 张玉琪, 徐伟. 机器学习在金属微观组织图像分割中的应用 [J]. 鞍钢技术, 2024(06): 61-69.
CHEN J L, ZHANG Y Q, XU W. Application of Machine Learning in Image Segmentation of Metal Microstructures [J]. Angang Technology, 2024(06): 61-69.
- [5] 王炫东. 基于卷积神经网络与先验知识的钢铁材料金相图谱智能识别 [D]. 北京: 北京科技大学, 2024.
WANG X D. Intelligent Recognition of Steel Material-

- Metallography Based on Convolutional Neural Networks and Prior Knowledge[D]. Beijing: University of Science and Technology Beijing, 2024.
- [6] 陈哲兴. 基于机器学习的高强钢显微组织图像分割方法研究[D]. 湖北: 华中科技大学, 2022.
CHEN Z X. Research on Image Segmentation Method of Microstructure of High Strength Steel Based on Machine Learning [D]. Hubei: Huazhong University of Science and Technology, 2022.
- [7] 赵隆, 韩小稚, 王景人, 等. 基于卷积神经网络的 12Cr1MoV 钢金相组织球化级别智能化分析[J]. 中国特种设备安全, 2024, 40(3): 80–83.
ZHAO L, HAN X Z, WANG J R, et al. Intelligent Analysis of 12Cr1MoV Steel Metallographic Structure Sphericity Level Based on Convolutional Neural Network [J]. China Special Equipment Safety, 2024, 40 (3): 80–83.
- [8] 王森. 基于计算机视觉的钢材金相图像晶粒度评价方法研究[D]. 陕西: 西安工业大学, 2023.
WANG S. Research on the Evaluation Method of Grain-Size of Steel Metallographic Images based on Computer Vision [D]. Shanxi: Xi'an Technological University, 2023.
- [9] 朱家乐. 基于卷积神经网络的 20 钢劣化分级与金相组织检测方法研究[D]. 辽宁: 大连理工大学, 2023.
ZHU J L. Research on 20 Steel Deterioration Grading and Metallographic Detection Method Based on Convolutional Neural Network [D]. Liaoning: Dalian University of Technology
- [10] 王佳锐, 刘能锋, 曲鹏. 卷积神经网络金相组织自动识别[J]. 智能系统学报, 2022, 17(4): 698–706.
WANG J R, LIU N F, QU P. Automatic identification of metallographic structure based on convolutional neural network [J]. CAAI Transactions on Intelligent Systems, 2022, 17(4): 698–706.
- [11] 杨俊鸿. 基于深度学习的金相组织智能评级方法研究[D]. 江苏: 江苏大学, 2018.
YANG J H. Research on Intelligent Rating Method of Metallurgical Organization Based on Deep Learning [D]. Jiangsu: Jiangsu University, 2018.
- [12] 何惠珍. 基于深度学习的钢材金相组织自动化识别[D]. 湖北: 武汉工程大学, 2022.
HE H Z. Automatic Identification of Steel Metallographic Structure Based on Deep Learning [D]. Hubei: Wuhan Institute of Technology, 2022.
- [13] 田中华. 面向铝合金金相图像的晶界检测方法研究[D]. 辽宁: 东北大学, 2021.
TIAN Z H. Research on Grain Boundary Detection Method for Metallographic Image of Aluminum Alloy [D]. Liaoning: Northeastern University, 2021.

编辑部网址: <http://www.71dhj.com>