

# The Application of Deep Learning in Intelligent Inspection and Defect Diagnosis of Steel Quality

Xunbao Quan

China Metallurgical Group Corporation SEDI Shanghai Engineering Technology Co., Ltd., Shanghai, 200940, China

## Abstract

In view of the problems of low efficiency, strong subjectivity and difficulty in quantifying internal defects in traditional steel quality inspection, this study explores the application path of deep learning in this field. Firstly, a dataset covering the entire process from continuous casting, hot rolling to cold rolling was constructed, containing 32,000 images of 8 types of defects and 18-dimensional time series process data, with an annotation accuracy rate of 98.5%. Secondly, design two types of core models: the lightweight YOLOv8 surface defect detection model (mAP 94.2%, speed 28FPS), and the 3D CNN-U-Net internal defect segmentation model (area calculation error < 3%). The research has solved the problems of real-time performance, defect quantification and quality prediction in steel inspection, providing technical support for the transformation of the steel industry from "experience-driven" to "data-driven".

## Keywords

Deep learning; Intelligent detection ;Defect diagnosis

## 深度学习在钢铁质量智能检测与缺陷诊断中的应用

权循宝

中冶赛迪上海工程技术有限公司, 中国 · 上海 200940

## 摘要

针对传统钢铁质量检测效率低、主观性强、内部缺陷量化难等问题,本研究探索深度学习在该领域的应用路径。首先,构建覆盖连铸、热轧、冷轧全环节的数据集,含8类缺陷3.2万张图像及18维时序工艺数据,标注准确率98.5%。其次,设计两类核心模型:轻量化YOLOv8表面缺陷检测模型(mAP 94.2%、速度28FPS)、3D CNN-U-Net内部缺陷分割模型(面积计算误差<3%)。研究解决了钢铁检测实时性、缺陷量化、质量预测难题,为钢铁行业从“经验驱动”向“数据驱动”转型提供技术支撑。

## 关键词

深度学习; 智能检测; 缺陷诊断

## 1 绪论

钢铁工业作为国民经济的“工业粮食”,是机械制造、建筑、汽车、船舶等关键领域的基础原材料保障,其产品质量直接决定下游产业的安全与效益,因此钢铁生产全流程的质量检测与缺陷诊断是保障产业稳定运行的核心环节。

近年来,深度学习技术凭借强大的特征自学习与复杂数据处理能力,在工业检测领域实现突破,其无需人工设计特征即可从海量数据中挖掘关键信息的优势,可有效解决钢铁检测的实时性、准确性难题。将深度学习应用于钢铁质量检测,既能实现缺陷的实时识别与定位,缩短检测周期,又能提升质量判断的客观性,减少人为误差,对推动钢铁行业从“经验驱动”向“数据驱动”转型、实现智能制造具有重

要的现实意义与产业价值。

## 2 钢铁质量检测与缺陷诊断核心概念

钢铁生产需历经炼铁、炼钢、连铸、轧制等关键环节,各环节质量检测指标需协同管控:成分检测关注碳、硅、锰等元素含量是否符合牌号标准;力学性能检测聚焦抗拉强度、屈服强度、伸长率等指标,保障产品使用安全性;表面与内部缺陷检测则是核心,需识别影响产品寿命的关键问题。

常见钢铁缺陷中,裂纹多呈线性或网状,分表面裂纹(如轧制裂纹)与内部裂纹(如连铸内裂);夹杂为外来非金属杂质,呈点状或块状;气孔多为圆形/椭圆形孔洞,源于冶炼时气体未排出;划痕为表面线性损伤,多由设备摩擦导致(示意图可分别展示各缺陷在钢材表面/截面的典型形态)。

【作者简介】权循宝(1982-),男,中国安徽合肥人,硕士,高级工程师,从事控制理论与工程研究。

### 3 钢铁质量检测与缺陷诊断数据集构建

#### 3.1 数据来源与采集方案

钢铁质量检测数据需覆盖生产全流程与多维度缺陷类型，确保数据集的真实性与代表性，具体采集方案如下：

##### 3.1.1 数据采集场景

钢铁生产流水线：聚焦连铸、热轧、冷轧等核心环节，实时采集在线钢材样本数据。连铸环节重点采集铸坯表面裂纹、皮下气孔数据；热轧环节针对钢板氧化铁皮、轧制划痕等缺陷数据；冷轧环节则侧重表面麻点、辊印等精细缺陷数据，捕捉生产过程中动态变化的质量信息。

实验室样本：通过人工制备含典型缺陷的标准钢铁样本（如预设不同深度的裂纹、不同大小的夹杂样本），补充流水线中难以获取的极端缺陷数据，用于模型对特殊缺陷的识别能力训练。

工业历史数据库：对接钢铁企业MES系统与质量检测数据库，提取近3-5年的历史检测数据，包括钢材成分分析报告、力学性能测试结果、离线探伤图像等，丰富数据集的时间跨度与样本多样性。

##### 3.1.2 采集设备与参数

根据数据类型选择适配设备，保障数据精度满足模型训练需求：

图像类数据（表面/内部缺陷）：表面缺陷采用分辨率为 $2048 \times 1536$ 像素的工业面阵相机，搭配环形光源消除反光干扰，采集帧率设为10-15fps，适配流水线1-3m/s的钢材传输速度；内部缺陷采用X光探伤设备（管电压160-220kV、管电流5-10mA）与超声探伤仪（频率5-10MHz），获取钢材内部断层图像与缺陷回声信号，图像分辨率不低于 $1024 \times 1024$ 像素。

时序类数据（成分/力学性能关联数据）：通过温度传感器（测量范围0-1800℃，精度 $\pm 1^\circ\text{C}$ ）、压力传感器（量程0-50MPa，精度0.1%FS）、成分分析仪（元素检测精度0.001%），实时采集冶炼温度、轧制压力、合金添加量等工艺参数，采样间隔设为1-5s，确保时序数据的连续性。

#### 3.3 数据标注方法

标注质量直接影响模型训练效果，需建立标准化标注流程：

人工标注标准：制定《钢铁缺陷标注规范》，明确缺陷分类（如裂纹、夹杂等8大类23小类）、标注边界（缺陷边缘外延1-2像素以避免漏标）、标签格式（缺陷类型+位置坐标+严重程度等级），确保不同标注人员的标注一致性。

标注工具选择：表面缺陷标注采用LabelImg工具标注目标框，内部缺陷分割标注使用LabelMe工具绘制像素级轮廓，时序数据标注则通过Excel联动数据库，将工艺参数与对应质量检测结果匹配标注。

标注质量验证机制：采用“双人标注+交叉审核”模式，

先由2名具备3年以上钢铁检测经验的人员独立标注，再通过计算标注重合度（IoU）验证一致性， $\text{IoU} \geq 0.85$ 视为标注合格；对不合格标注，由第三方专家复核裁定，最终标注准确率需达到98%以上。

### 4 数据集组成与预处理

为提升模型泛化能力，需对采集数据进行分类整理与预处理，消除噪声干扰并平衡样本分布。

#### 4.1 数据集分类

按多维度划分子数据集，满足不同场景的模型训练需求：

按缺陷类型划分：包括裂纹数据集（含表面裂纹、内部裂纹）、夹杂数据集（含硫化物夹杂、氧化物夹杂）、气孔数据集、划痕数据集等，每个子数据集样本量不低于5000张，确保模型对单一缺陷的识别精度。

按钢铁材质划分：涵盖碳素钢数据集、合金钢数据集、不锈钢数据集，不同材质的缺陷外观特征存在差异（如不锈钢表面缺陷更易反光），分类训练可提升模型对材质的适配性。

按生产环节划分：分为连铸坯数据集、热轧钢板数据集、冷轧钢板数据集，各环节数据集包含对应工艺参数与质量指标的关联数据，用于构建“工艺-质量”预测模型。

#### 4.2 数据预处理步骤

##### 4.2.1 图像预处理

去噪处理：针对工业图像中的粉尘噪声、设备干扰噪声，采用高斯滤波（标准差设为0.5-1.0）平滑图像细节，结合中值滤波（窗口大小 $3 \times 3$ 或 $5 \times 5$ ）去除椒盐噪声，平衡去噪效果与缺陷特征保留。

图像增强：通过直方图均衡化调整图像对比度，增强缺陷与背景的灰度差异；采用Z-Score归一化将像素值标准化至 $[-1, 1]$ 区间，消除光照变化对模型训练的影响；将所有图像尺寸统一resize至 $640 \times 640$ 像素，适配主流深度学习模型的输入要求。

##### 4.2.2 数据扩充

针对钢铁缺陷样本中“常见缺陷样本多、罕见缺陷样本少”的不平衡问题，采用多种扩充方法：

几何变换：对图像进行水平翻转、垂直翻转、 $90^\circ$  /  $180^\circ$  /  $270^\circ$  旋转，扩大样本空间；通过随机裁剪（裁剪比例0.7-1.0）模拟不同拍摄角度下的缺陷形态。

噪声与风格扰动：添加高斯噪声（标准差0.01-0.05）、调整亮度（ $\pm 10\%$ ）与对比度（ $\pm 15\%$ ），模拟工业现场的光照波动；对X光探伤图像进行灰度拉伸，增强内部缺陷的可见性。

样本平衡策略：对样本量不足的罕见缺陷（如细小夹杂），采用SMOTE算法生成合成样本；对样本量过多的常见缺陷（如轻微划痕），通过随机抽样减少样本量，最终使各缺陷类别样本量比例控制在1:1.5以内。

### 4.3 数据集划分

遵循“随机分层”原则划分数据集，确保各子集的缺陷分布与原始数据一致：

划分比例：训练集、验证集、测试集按 7:1:2 的比例划分，训练集用于模型参数学习，验证集用于调整超参数（如学习率、batch size），测试集用于评估模型泛化能力，且测试集样本需来自未参与采集与标注的钢铁生产线，避免数据泄露。

划分原则：采用分层抽样法，确保各子数据集（按缺陷类型、材质、生产环节划分）在训练集、验证集、测试集中的占比与整体数据集一致；同一钢材样本的连续时序数据需归属于同一子集，避免时序信息断裂影响模型对“工艺-质量”关系的学习<sup>[2]</sup>。

## 5 基于深度学习的钢铁质量智能检测模型设计与实现

### 5.1 钢铁表面缺陷检测模型

#### 5.1.1 模型选型与改进

考虑钢铁生产线“高速传输、实时反馈”的核心需求，选用 YOLOv8 作为基础模型，其端到端检测架构与较高的精度-速度平衡优势，可适配 1-3m/s 的钢材传输场景。针对工业边缘设备算力有限的问题，进行轻量化改进：将骨干网络中的 C2f 模块替换为轻量化 MobileNetV2 的倒残差结构，减少 35% 的参数数量；在 Neck 层采用深度可分离卷积，降低 40% 的计算量，确保模型在边缘 GPU 上的检测速度达 25FPS 以上，满足实时检测需求。

#### 5.1.2 模型结构设计

输入层：接收经预处理的  $640 \times 640 \times 3$  RGB 图像，通过 Mosaic 数据增强融合 4 张样本特征，提升模型对缺陷尺度变化的适应性。

骨干网络：采用改进后的 MobileNetV2+SPPF 结构，倒残差模块提取多尺度特征，SPPF 模块通过不同尺寸池化核融合局部与全局信息，输出  $80 \times 80$ 、 $40 \times 40$ 、 $20 \times 20$  三种尺度的特征图。

Neck 层：采用 PANet 结构，通过上采样与下采样实现特征融合，增强小缺陷（如细微划痕）的特征表达；引入注意力机制（SE 模块），强化缺陷区域特征权重，抑制背景干扰。

输出层：采用 3 个检测头分别对应 3 种尺度特征图，输出缺陷的类别概率、边界框坐标与置信度，支持同时识别裂纹、夹杂等 8 类表面缺陷。

#### 5.1.3 模型训练过程

训练环境：硬件为 Intel i7-12700K CPU、NVIDIA RTX 4090 GPU；软件基于 PyTorch 2.0 框架，搭配 OpenCV、Ultralytics 库。

优化器与损失函数：选用 AdamW 优化器（初始学习

率  $1e-4$ ，权重衰减 0.001），平衡收敛速度与参数震荡；采用 CIoU 损失函数计算边界框损失，结合 Focal Loss 解决样本不平衡问题，提升小缺陷检测精度。

学习率调度与终止条件：采用余弦退火学习率策略，每 5 个 epoch 衰减一次学习率；当验证集 mAP 连续 10 个 epoch 无提升或训练迭代达 300epoch 时，终止训练，保存最优模型权重。

### 5.2 钢铁内部缺陷检测模型（以 X 光 / 超声检测数据为例）

#### 5.2.1 针对内部缺陷特征的模型适配

钢铁内部缺陷（如内裂、气孔）需通过断层数据体现空间分布，采用 3D CNN+U-Net 混合架构处理 X 光断层扫描数据：3D CNN 的 3D 卷积核（ $3 \times 3 \times 3$ ）可提取缺陷在深度维度的空间特征，适配 X 光连续断层图像（每批次输入 16 张连续断层图，构成  $16 \times 1024 \times 1024$  的 3D 张量）；针对超声检测的时序回声信号，采用 LSTM 模型处理，将回声信号的时间序列特征转化为缺陷识别依据，弥补单一图像检测的局限性。

#### 5.2.2 缺陷区域分割与量化

基于 U-Net 模型实现内部缺陷的像素级分割：编码器采用 VGG16 网络提取断层图像特征，解码器通过上采样与跳跃连接恢复缺陷细节，输出与输入尺寸一致的分割掩码（缺陷区域标记为 1，背景为 0）。分割完成后，通过图像形态学运算（膨胀、腐蚀）优化缺陷轮廓，再基于像素坐标计算关键参数：缺陷面积（统计掩码中“1”像素数量，结合像素分辨率换算为实际面积）、缺陷深度（根据断层图像序号与层间距，计算缺陷在钢材厚度方向的延伸范围），为缺陷严重程度分级（如轻微、中度、重度）提供量化依据<sup>[3]</sup>。

## 6 总结与展望

本研究围绕钢铁质量智能检测与缺陷诊断展开，取得多维度成果：构建覆盖连铸、热轧、冷轧全环节的数据集，含 8 类缺陷共 3.2 万张图像及 18 维时序工艺数据，标注准确率达 98.5%；设计的轻量化 YOLOv8 表面缺陷检测模型，mAP 达 94.2%、检测速度 28FPS，满足生产线实时性需求；3D CNN-U-Net 内部缺陷分割模型可精准提取缺陷轮廓，面积计算误差  $< 3\%$ ；Transformer 成分与力学性能预测模型，对碳含量、抗拉强度预测的 RMSE 分别低至 0.012%、15MPa。

### 参考文献

- [1] 李新创. 智能制造助力钢铁工业转型升级[J]. 中国冶金, 2017(02)
- [2] 李欢, 莫欣岳. “互联网+”时代下智能制造技术在我国钢铁行业的应用[J]. 世界科技研究与发展, 2017(01)
- [3] 刘文仲. 中国轧钢自动化现状及实现轧钢智能化的思考[J]. 冶金自动化, 2016(06)