

DOI: 10.7512/j.issn.1001-2303.2026.10.03

基于DDPM数据驱动的电厂焊缝影像缺陷检测方法

火旭鑫¹, 单秉昆¹, 赵巍^{2*}

1. 中广核苍南核电有限公司, 浙江 温州 325800

2. 沈阳派得林科技有限责任公司, 辽宁 沈阳 110004

摘要: 针对核电厂焊缝射线图像中样本获取受限、跨场景成像差异显著以及缺陷形态与尺度多样等难题, 提出一种面向核电焊缝射线检测的场景迁移缺陷识别方法。首先, 利用去噪扩散概率模型在多场景焊缝数据上进行预训练, 并结合目标场景数据进行迭代微调构建目标风格生成集, 以缓解样本少和域偏差对模型训练的不利影响; 其次, 设计共享主干与特征金字塔网络颈部的多分支检测结构, 将基于锚框和无锚框的预测机制进行互补融合, 在保持通用特征表达能力的同时增强对核电场景重点缺陷的适配性; 最后, 在推理阶段引入自适应窗宽窗位增强、宽向重叠分块推理及结果融合策略, 以适配长条形、高分辨率焊缝射线图像的工程应用需求。与主流单阶段检测模型相比, 在交并比(IoU)阈值为0.5时, 多场景下模型平均精度(mAP@0.5)提升约1.9~5.8个百分点。该方法在核电厂场景下达到了94.1%的缺陷检出率和3.7%的定量偏差率, 与专业人员评定水平基本持平, 且评片效率提升约12倍, 符合辅助评定的实际工程需求。

关键词: 核电焊接; 射线检测; 焊缝缺陷识别; 去噪扩散概率模型; 场景迁移

中图分类号: TP391.4 文献标识码: A 文章编号: 1001-2303(2026)10-0019-12

Research on Intelligent Identification Method for Weld Defects in Nuclear Power Plants based on Scene Migration

HUO Xuxin¹, SHAN Bingkun¹, ZHAO Wei^{2*}

1. CGN CangNan Nuclear Power Co., Ltd., Wenzhou 325800, China

2. Shenyang Paidelin Technology Co., Ltd., Shenyang 110004, China

Abstract: To address the challenges of limited sample acquisition, significant cross-scene imaging differences, and diverse defect shapes and scales in nuclear power plant weld radiographic images, a scene transfer defect recognition method for nuclear power plant weld radiographic inspection is proposed. Firstly, a denoising diffusion probabilistic model is pre-trained on multi-scene weld data and iteratively fine-tuned with the target scene data to construct a target style generation set, thereby alleviating the adverse impact of domain deviation and limited samples on model training. Secondly, a multi-branch detection structure with a shared backbone and feature pyramid network neck is designed, which fuses anchor-based and anchor-free prediction mechanisms, to enhance the adaptability to key defects in nuclear power plant scenes while maintaining the general feature expression ability. Finally, in the inference stage, adaptive window width and window level enhancement, wide-directional overlapping block inference, and result fusion strategies are introduced to meet the application requirements of long, high-resolution weld radiographic images. Compared with mainstream single-stage detection models, the proposed method achieves an improvement of 1.9 to 5.8 percentage in mean Average Precision at IoU threshold 0.5 (mAP@0.5) in multi-scenario condition. The method attains the defect detection rate of 94.1% and the quantitative deviation rate of 3.7% in the nuclear power plant scenario, which are comparable to the evaluation level of professional inspectors.

收稿日期: 2026-03-29 修回日期: 2026-04-30

作者简介: 火旭鑫(1993—),男,学士,工程师,主要从事核电厂机械设备无损检验、民用核安全设备射线检验等研究。E-mail: 444123970@qq.com。

通讯作者: 赵巍(1991—),男,硕士,工程师,主要从事无损检测智能化等相关研究。E-mail: 1542685065@qq.com。

Moreover, the film evaluation efficiency is improved by 12 times, meeting the practical engineering requirements for assisted evaluation.

Keywords: nuclear power welding; radiographic testing; weld defect identification; denoising diffusion probabilistic model; scene transfer

引用格式: 火旭鑫, 单秉昆, 赵巍. 基于 DDPM 数据驱动的电厂焊缝影像缺陷检测方法[J]. 电焊机, 2026, 56(10): 19–30.

Citation: HUO Xuxin, SHAN Bingkun, ZHAO Wei. Research on Intelligent Identification Method for Weld Defects in Nuclear Power Plants based on Scene Migration[J]. Electric Welding Machine, 2026, 56(10): 19–30.

0 引言

核电厂管道系统、压力容器及关键设备的焊接接头长期处于高温、高压及复杂服役环境中,焊缝内部缺陷(如未焊透、未熔合、裂纹、气孔等)若未能及时识别与处置,可能对结构完整性与运行安全产生不利影响。射线检测能够直观反映焊缝内部缺陷的形态、尺寸与分布,是焊缝无损检测中应用广泛且工程依赖度较高的手段之一^[1–3]。随着底片数字化与智能化判读需求提升,面向核电焊缝射线图像的缺陷智能识别,已成为提升检测效率、降低人工成本并支撑一致性判读的重要方向^[4–6]。

现有深度学习检测方法在一般工业射线缺陷场景中已取得进展^[7–9],但在核电厂场景落地仍面临两类核心问题。(1)目标场景数据稀缺与域偏差并存。核电厂真实缺陷样本往往规模有限,且受生产与管理约束难以形成可支撑深度学习模型训练的充足数据;与此同时,长输管线或其他工业场景虽可获得相对丰富的数据,但其成像背景纹理、曝光与扫描条件、缺陷表观分布与核电场景存在差异,直接迁移训练容易导致泛化不足^[10–12]。(2)缺陷形态多样且尺度跨度大,单一检测头适配能力受限。焊缝缺陷既包含细长、弱对比度的裂纹类目标,也包含局部灰度突变或形态不规则的未焊透、未熔合类目标;在复杂焊缝结构背景下,采用单一预测机制往往难以同时兼顾不同形态缺陷的定位稳定性与分类鲁棒性,易出现漏检、误检或定位偏差^[13]。

围绕问题(1),国内外研究多从迁移学习、域自适应与数据增强等路径缓解小样本跨场景带来的性能退化。一类方法是通过预训练与微调提升特征可迁移性,但射线图像与自然图像在纹理统计与成像噪声上存在显著差异,单纯依赖通用预训练特

征可能出现目标域召回不足。另一类是域对齐方法,其尝试在特征层或输出层缩小源和目标分布差距,但在弱对比缺陷与强背景纹理共存时,域对齐过程易受到背景伪相关的干扰,导致对小目标与弱边界目标的判别能力提升有限。相较之下,生成式数据增强能够从数据侧补足目标域表观变化空间,尤其是扩散模型在高保真细节建模与可控生成方面的优势,为构建“贴近核电场景表观分布”的训练样本提供了可行思路^[14–15]。

围绕问题(2),针对多尺度与复杂形态缺陷的检测需求,已有工作通过多尺度特征融合、注意力增强、改进检测头等方式提升小目标与弱边界缺陷的响应能力。然而,核电焊缝射线图像中缺陷纹理与焊缝结构纹理耦合紧密,单一预测头往往在“细长裂纹、小尺度气孔、不规则未熔合、未焊透”等多类型目标之间难以同时兼顾,易在定位稳定性与分类鲁棒性之间产生权衡。为此,多分支互补结构将不同预测机制并行组合,通过差异化建模提升对复杂形态目标的适配性,已成为提高检测鲁棒性的一个重要方向,但其引入的推理开销与大分辨率长焊缝图像的工程部署需求之间需要合理平衡。

基于上述问题,本文提出一套面向核电焊缝射线图像的“场景生成迁移—多分支互补检测—工程化推理”方法框架:首先利用去噪扩散概率模型(Denoising Diffusion Probabilistic Model, DDPM)构建跨场景缺陷数据生成与迁移机制,通过“预训练—微调—生成—筛选—再微调”的闭环迭代,生成更贴近核电场景表观特征的训练数据;随后设计共享主干与特征金字塔(Feature Pyramid Networks, FPN)颈部的多分支检测模型,将基于锚框(anchor-based)检测分割头与无锚框(anchor-free)检测头并行组合,实现对缺陷形态与尺度差异的互补建模;

在推理阶段进一步引入自适应窗宽窗位预处理与宽向重叠分块推理策略,并结合阈值控制与非极大值抑制(Non-Maximum Suppression, NMS)完成跨子图结果融合,从而提升长焊缝图像的有效信息表达与检测覆盖。本文的主要工作与创新点可概括为以下三方面:

(1)构建了基于 DDPM 的场景迁移数据生成闭环流程,将非核电场景数据逐步迁移至更接近核电场景的缺陷表观分布,为小样本条件下的模型训练提供数据支撑。

(2)设计了共享主干的多分支缺陷检测结构,将基于锚框的检测分割头与无锚框检测头进行互补融合,并采用分阶段训练策略来提高模型的场景适配能力。

(3)提出了面向焊缝射线图像的工程化推理策略,包括自适应窗宽窗位增强、宽向重叠分块推理、以及后处理去冗余策略,以适配核电厂高分辨率射线图像的实际检测需求。

1 关键技术与实现

1.1 总体框架与流程

整体框架由训练链路和推理链路两部分构成。核心思想是在训练阶段通过扩散生成模型将非核电场景数据向核电场景表观特征迁移,以缓解数据不足与分布偏移;在推理阶段通过自适应图像增强与分块推理策略提升长焊缝射线图像的有效信息表达与检测覆盖率,从而实现核电场景下缺陷识别的稳定输出。模型整体训练流程如图 1 所示。

训练流程如下:基于跨场景的基础训练集 D_0 对扩散模型进行预训练,随后结合与核电厂成像特征更接近的设备装置场景训练集 D_1 进行逐轮微调,得到可生成目标风格缺陷样本的扩散模型。经图像生成、人工筛选、微调的闭环迭代后,形成与核电厂焊缝背景纹理及缺陷表观更贴合的生成数据集 D_3 。在缺陷检测模型训练阶段,将 D_0 与 D_3 融合构建训练集 D_4 ,用于训练通用缺陷分支,以学习跨场景的缺陷共性特征。随后冻结共享主干网络参数,并分别对场景适配分支与核电关注缺陷分支进行训练,使各分支在共享特征基础上形成互补能力。这种




图 1 核电厂焊缝缺陷检测模型训练流程

Fig. 1 Training flowchart of weld defect detection model for nuclear power plants

分阶段训练策略能够在数据分布存在迁移偏差时降低过拟合风险,并提高对核电场景重点缺陷的检出能力。

为便于后续描述,设输入射线图像为 $I \in \mathbf{R}^{H \times W}$,检测模型输出为缺陷候选集合 $B = \{(b_k, c_k, s_k)\}_{k=1}^K$,其中 H 、 W 分别代表图像的高度和宽度, b_k 为第 k 个缺陷的边界框, c_k 为类别标签, s_k 为置信度分数。多分支结构的训练目标是在共享主干特征 F 的基础上,使不同头部对不同形态与尺度的缺陷具有更强的适配性,从而提升整体识别的鲁棒性。

推理阶段首先对输入图像执行自适应预处理,以增强焊缝有效区域的对比度并抑制无效灰度区间对模型特征提取的干扰;随后针对焊缝射线图像常见的长宽比特征,采用沿宽度方向的重叠裁剪策略将 I 切分为若干子图 $\{I_j\}_{j=1}^n$,并将子图缩放至模型推理分辨率 $l \times l$ 。各子图分别输入多分支检测模型,获得三路预测结果;针对不同分支、不同类别设置置信度阈值 $\tau_{m,c}$ (其中 m 表示分支索引, c 表示类别),保留满足 $s_k \geq \tau_{m,c}$ 的候选框。随后将子图坐标系下的检测结果按裁剪位置参数映射回原图坐标系,

形成全图候选集合 $\tilde{B}$ 。最后采用NMS去除冗余框, NMS的交并比阈值记为 η (本文取 $\eta=0.6$), 得到最终检测输出 B^* 。上述流程在保证长焊缝图像覆盖的同时, 能够有效降低重复检测与边界碎片化现象, 并提升推理结果的可解释性与工程可用性。

1.2 基于DDPM的缺陷数据场景迁移

为缓解核电厂场景下焊缝缺陷数据稀缺造成的模型泛化不足, 采用去噪扩散概率模型构建跨场景缺陷数据迁移机制, 通过生成模型学习非核电场景缺陷的结构先验, 并在与核电场景更相近的数据上逐步微调, 使生成样本在缺陷形态与背景纹理层面向目标场景靠拢。数据集设置为基础训练集 D_0 (约 1.6×10^5 张, 经离线增强形成)、设备装置场景子集 D_1 (约 3.0×10^4 张)、闭环迭代后形成目标风格生成集 D_3 (约 9.0×10^3 张, 含离线增强)。迭代微调轮数设置为3轮。本文所采用的DDPM模型训练和采样过程示意图如图2所示。




图2 DDPM模型训练和采样过程

Fig. 2 Training and sampling process of the DDPM model

设清洁样本(真实射线图像或其裁剪块)为 x_0 , 前向扩散过程在 T 步内逐步向样本注入高斯噪声, 得到带噪样本 $x_t (t=1, 2, \dots, T)$ 。噪声调度 $\{\beta_t\}_{t=1}^T$ 为线性序列, 定义 $\alpha_t = 1 - \beta_t$, 及累乘系数 $\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$, 则前向过程的条件分布可写为:

$$q(x_t|x_{t-1}) = N(x_t; \sqrt{\alpha_t} x_{t-1}, \beta_t I) \quad (1)$$

并可将 x_t 直接表示为关于 x_0 的闭式形式:

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \varepsilon, \quad \varepsilon \sim N(0, I) \quad (2)$$

在训练阶段, 采用以U-Net为骨干并引入注意力模块的噪声预测网络 $\varepsilon_\theta(\cdot)$, 输入为 (x_t, t) , 输出为噪

声估计 $\hat{\varepsilon}$ 。训练目标采用均方误差形式的噪声回归损失:

$$L(\theta) = E_{x_0, \varepsilon, t} [\|\varepsilon - \varepsilon_\theta(x_t, t)\|_2^2] \quad (3)$$

式中 t 在 $\{1, \dots, T\}$ 上均匀采样。扩散模型通过学习反向过程 $p_\theta(x_{t-1}|x_t)$ 逐步去噪生成样本。采样从标准高斯噪声初始化:

$$x_T \sim N(0, I) \quad (4)$$

在 $t = T, T-1, \dots, 1$ 的反向迭代中, 构造:

$$p_\theta(x_{t-1}|x_t) = N(x_{t-1}; \mu_\theta(x_t, t), \sigma_t^2 I) \quad (5)$$

其中均值项由噪声预测给出:

$$\mu_\theta(x_t, t) = \frac{1}{\sqrt{\alpha_t}} (x_t - \frac{\beta_t}{\sqrt{1 - \alpha_t}} \varepsilon_\theta(x_t, t)) \quad (6)$$

式中 σ_t^2 为与噪声调度相关的方差项。经由上述反向方程可得到生成样本 x_0 , 其统计分布在模型容量与训练数据约束下逐步逼近目标数据分布。

仅依赖 D_0 训练的生成模型容易生成“跨场景混合风格”样本, 导致背景纹理与核电厂成像特征存在偏差。本文使用生成闭环策略实现渐进式场景迁移, 步骤概括如下:

(1) 预训练: 在 D_0 上训练 DDPM, 使其学习焊缝射线图像的一般结构与缺陷形态先验。

(2) 第一次微调: 在 D_1 上微调, 使模型向设备装置场景分布收敛。

(3) 生成与筛选: 基于微调模型生成候选样本集合 $\hat{D}$, 由工程人员对样本进行人工审核, 保留与目标场景一致性更高的样本, 形成筛选集 D_{sel} 。

(4) 构建 D_2 并再微调: 将 D_{sel} 与 D_1 合并得到 D_2 , 并对模型再次微调。

(5) 重复迭代: 按上述流程重复3轮, 最终生成并标注形成 D_3 。

为降低主观性并增强可复现性, 人工筛选规则以可操作条目形式给出, 包括背景纹理一致性、焊缝结构合理性、灰度分布匹配、缺陷形态可信度、可标注性与类别清晰度、多样性约束等。本文的生成闭环机制旨在不扩大真实核电样本暴露面的前提下, 提升训练数据对目标场景的覆盖度与代表性, 为后续多分支缺陷检测模型提供更稳定的训练支撑。

1.3 多分支缺陷检测模型

在完成基于DDPM的缺陷数据场景迁移后, 进

一步构建面向核电厂焊缝射线图像的多分支缺陷检测模型,以充分利用跨场景数据的共性信息并兼顾目标场景中重点缺陷的识别需求。模型总体采用共享主干特征提取、FPN 颈部多尺度融合和三分

支检测头并行预测的结构,其中共享主干与颈部负责学习可迁移的通用表征,三条检测分支分别对不同检测目标与不同预测机制进行专门化优化,从而形成互补。模型结构如图 3 所示。




图 3 核电厂领域焊缝缺陷检测模型结构

Fig. 3 Structural diagram of weld defect detection model in nuclear power plant field

若共享主干网络记为 $f_{bb}(\cdot)$, 则其输出多层特征集合为:

$$\{F^{(s)}\}_{s \in S} = f_{bb}(\cdot) \quad (7)$$

式中 s 表示尺度层级索引, S 为参与特征融合的层集合。颈部采用基于特征金字塔网络的多尺度融合结构 $f_{fpn}(\cdot)$, 输出融合特征为:

$$\{P^{(s)}\}_{s \in S} = f_{fpn}(\{F^{(s)}\}_{s \in S}) \quad (8)$$

在此基础上, 设置了三个并行的检测分支头 $h_m(\cdot) (m \in \{1, 2, 3\})$, 分别输出候选框集合 B_m 。对于第 m 个分支, 其预测结果可表示为:

$$B_m = h_m(\{P^{(s)}\}_{s \in S}) = \{(b_{m,k}, c_{m,k}, s_{m,k}, \pi_{m,k})\}_{k=1}^{K_{m,k}} \quad (9)$$

式中 $b_{m,k}$ 为边界框参数(中心点与宽高或角点坐标), $c_{m,k}$ 为类别, $s_{m,k}$ 为置信度, $\pi_{m,k}$ 表示可选的像素级掩膜(仅对具备分割头的分支输出)。

为提升特征提取效率并改善梯度传播, 在 YOLOv5 分支中将原有 C3 模块替换为更轻量的 C2F 模块, 实现更充分的特征复用与跨层连接, 提升对细小缺陷纹理的表达能。

分支 1 是通用缺陷分支, 面向全部 9 类缺陷, 采用 anchor-based 的检测分割头, 在多尺度特征图上对预设锚框进行分类与回归, 并同时输出掩膜以提升对边缘细长或形态不规则缺陷的定位精度。该分支使用由 D_0 与生成集 D_3 融合得到的训练集 D_1 进行训练。

分支 2 是迁移适配分支, 其采用 anchor-free 预测机制, 通过对候选点进行分类与边界框回归来完成检测。与 anchor-based 机制相比, anchor-free 分支对目标长宽比变化较大、尺度跨度较大的缺陷具有更强的自适应性, 可在一定程度上缓解锚框设置与真实缺陷几何分布不匹配带来的定位偏差。该分支以“场景迁移适配”为主要目标, 在冻结共享主干参数的前提下训练, 使其在保持通用特征的同时强化对目标场景表现的适配能力。

分支 3 是核电重点缺陷分支。核电厂场景中部分重点关注缺陷具有更强的场景特异性与检出敏感性。为此, 分支 3 在结构上与分支 1 保持一致

(anchor-based 检测分割头+C2F),但训练数据与训练目标聚焦于核电场景重点4类缺陷。训练集 D_s 从设备装置子集 D_1 与生成集 D_3 中筛选获得,并对样本量较少的类别进行离线过采样以缓解类别不平衡,使分支3在少数类与重点类上获得更高的召回倾向,从而降低漏检风险。

为避免多分支同时训练造成的梯度干扰并降低小样本条件下的过拟合风险,采用分阶段训练策略,即首先训练通用分支。使用训练集 D_3 端到端训练共享主干、FPN 颈部与分支1头部,使模型获得稳定的通用特征抽取能力;其次,冻结共享主干进行分支适配。固定共享主干参数,仅更新分支2、分支3及其必要的颈部和头部参数,分别在对应训练集上训练,以形成互补的检测偏置与专门化能力。

针对 anchor-based 的分支1与分支3,本文采用 k-means 对训练集中缺陷标注框的宽高进行聚类,得到 $n_a=9$ 个初始锚框 $\{(w_i, h_i)\}_{i=1}^{n_a}$ 。为更贴合检测任务习惯,采用基于交并比的距离度量:

$$d((w, h), (w', h')) = 1 - \text{IoU}((w, h), (w', h')) \quad (10)$$

式中 $\text{IoU}(\cdot)$ 表示由宽高定义的矩形在同一中心对齐条件下的交并比。聚类得到的锚框用于初始化检测头,使预测更贴近真实缺陷尺寸分布,提升收敛速度与定位精度。

对含分割头的分支采用由定位损失、掩膜损失、置信度损失与分类损失加权的总损失:

$$L_{\text{tot}} = \omega_1 L_{\text{loc}} + \omega_2 L_{\text{mask}} + \omega_3 L_{\text{conf}} + \omega_4 L_{\text{cls}} \quad (11)$$

式中 L_{loc} 为边界框回归损失,本文采用基于 Complete IoU 的形式; L_{mask} 与 L_{conf} 采用二元交叉熵损失; L_{cls} 为多分类交叉熵损失。

对 anchor-free 的分支2,采用位置回归与分类损失的加权组合:

$$L_{\text{tot}} = \omega_1 L_{\text{loc}} + \omega_2 L_{\text{cls}} \quad (12)$$

考虑不同分支的优化稳定性差异,分支1与分支2采用 Adam 优化器以加速收敛,分支3采用 SGD 优化器以提升泛化稳定性。

1.4 面向射线图像的推理策略

核电焊缝射线图像通常具有灰度动态范围受限、背景结构复杂、焊缝有效区域占比不稳定以及长条形大分辨率图像等特点。为提升推理阶段的有效信息表达与全幅覆盖,本文在推理端引入自适应

窗宽窗位预处理、宽向重叠分块推理、分支阈值控制与几何映射与NMS抑制冗余的工程化策略。

以8位灰度为例,则像素值取值范围为 $[0, 255]$,首先统计灰度直方图 $H(g)$:

$$H(g) = \sum_{x=1}^W \sum_{y=1}^H \sigma(I(x, y) - g), g \in \{0, 1, \dots, 255\} \quad (13)$$

式中 $\sigma(\cdot)$ 为 Kronecker 函数。记非零频数灰度集合为:

$$G = \{g \mid H(g) > 0\} \quad (14)$$

对 G 中按灰度升序排列的相邻灰度 g_i, g_{i+1} 计算差值 $T_i = g_{i+1} - g_i$ 。当 $T_i < T_0$ 时将对应灰度段合并为同一区间,对合并后的每个灰度区间 $[a, b]$ 计算区间宽度 $S = b - a$ 与区间频数和 $N_{ab} = \sum_{g=a}^b H(g)$ 。若区间满足:

$$S > S_0, N_{ab} > C_0 \cdot (W \cdot H) \quad (15)$$

则将该区间视为“有效内容候选区间”,其中 $S_0 = 14, C_0 = 0.16$ 。对候选区间按 N_{ab} 降序排序,取频数最大的区间 $[V_a, V_b]$ 作为自适应窗宽窗位的估计结果。对应的窗宽 V_{ww} 与窗位 V_{wl} 分别为:

$$V_{\text{ww}} = V_b - V_a, V_{\text{wl}} = \left\lfloor \frac{V_a + V_b}{2} \right\rfloor \quad (16)$$

最后对图像进行窗宽窗位映射并归一化,得到预处理图像 $\tilde{I}$:

$$\tilde{I}(x, y) = \frac{I(x, y) - V_a}{V_b - V_a} \quad (17)$$

并将 $\tilde{I}$ 截断至 $[0, 1]$ 以抑制极端灰度对后续特征提取的干扰。该自适应策略可使焊缝有效区域对比度增强,同时减少不同底片曝光、扫描条件差异造成的输入分布漂移。

因焊缝射线图像常呈现“长条形大分辨率”结构,直接缩放至固定输入可能导致细小缺陷被压缩。为此,采用沿宽度方向的重叠裁剪策略:设预处理后图像 $\tilde{I}$ 的尺寸为 $h \times w$,以步长 $\Delta = h(1 - \rho)$ 在宽度方向滑动裁剪得到 j 个子图 $\{I_j\}_{j=1}^j$,其中重复率 $\rho = 1/8$ 。每个子图尺寸为 $h \times h$,并缩放至 640×640 输入检测模型。对第 j 个子图得到的检测框 $b_{m,k}^{(j)}$ (子图坐标系),通过裁剪起点偏移量与缩放比例映射回原图坐标系,形成全图候选集合 $\tilde{B}$ 。

多分支输出在类别敏感性与误报倾向上存在

差异。为使系统在工程上更可控,对每个分支、每个类别设置独立置信度阈值 $\tau_{m,c}$ 。对分支 m 的候选集合 $\tilde{B}$,保留满足 $s_{m,k} \geq \tau_{m,c,k}$ 的检测结果。阈值筛选后的多分支结果合并为 $\tilde{B}$,并采用NMS去除冗余框;对任意两个候选框 b_i, b_j ,若其交并比 $IoU(b_i, b_j) \geq \eta$,则抑制置信度较低者。

2 数据集与实验设置

2.1 训练数据集构成

基础训练数据主要来源于长输管线场景及部分设备装置场景的数字化射线底片,该类数据在成像分辨率、焊缝结构形态及缺陷类型上具有较好的多样性,可为模型学习通用缺陷表征提供支撑。在此基础上,首先对去噪扩散概率模型进行预训练,并选取成像特征与核电厂射线条件更为接近的设备装置子集进行迭代微调,逐步引导生成模型向目标场景风格收敛。随后,通过生成迭代闭环流程构建核电场景生成集,用于补充核电场景下难以直接获取的缺陷样本。基础训练数据与核电场景生成集构成了整个缺陷检测训练数据集。

在缺陷检测模型训练阶段,采用分阶段训练策略。首先训练面向多场景的通用检测分支,以学习焊缝缺陷的基础结构与纹理特征;随后在冻结共享主干网络参数的前提下,针对核电场景重点关注的缺陷类型训练专用分支,从而在保持通用表征能力的同时,增强模型对目标场景关键缺陷的识别与定位能力。该训练策略有助于降低小样本条件下直接端到端训练带来的过拟合风险,并提升模型在核电应用场景中的稳定性。

本文缺陷类别体系沿用工程射线判读习惯,共定义9类缺陷,分别为:圆形缺陷(Round Indication, RI)、条形缺陷(Strip Indication, STI)、烧穿(Burn Through, BT)、根部未熔合(Lack of Fusion at Root, LFR)、夹层未熔合(Interlayer Fusion Defect, IFD)、未焊透(Incomplete Penetration, IP)、裂纹(Crack, CR)、内咬边(Internal Undercut, IU)和内凹(Internal Concavity, IC)。表1统计了所有数据中长输管线场景的9类缺陷实例数量及其占比情况,用以反映数

据集类别分布特征。设第 c 类缺陷实例数为 n_c ,总实例数为 $N = \sum_{c=1}^9 n_c$,则该类占比为:

$$p_c = \frac{n_c}{N} \times 100\% \quad (18)$$

表1 长输管线场景9类缺陷数量与占比


Table 1 Number and proportion of 9 types of defects in long-distance pipeline scenarios

类别	代码	数量/个	占比/%
圆形缺陷	RI	34287	35.17
条形缺陷	STI	12764	13.10
烧穿	BT	8931	9.16
根部未熔合	LFR	9856	10.11
夹层未熔合	IFD	3417	3.51
未焊透	IP	4729	4.85
裂纹	CR	11658	11.95
内咬边	IU	5893	6.05
内凹	IC	5947	6.10

图4直观反映了各类缺陷在长输管线场景中的分布差异及典型缺陷示例。由表1、图4可知,数据呈现出典型的长尾分布特性:圆形缺陷(RI)与条形缺陷(STI)样本占比比较高,而夹层未熔合(IFD)、未焊透(IP)等类别样本数量相对有限。该分布特征与工程实际中不同缺陷发生频率不均的客观规律相一致,但同时也会增加模型对少数类缺陷的学习难度与漏检风险。针对这一问题,本文在第2.2节中进一步引入离线与在线数据增强相结合的方式,并配合针对性重采样策略,以缓解类别不平衡对训练稳定性与检测性能的不利影响。

2.2 测试数据集构成

为客观评估本文方法在焊缝射线缺陷检测任务中的性能表现,并避免不同应用场景下数据规模差异对评价结果造成歧义,本文构建了多场景综合测试集与核电厂场景测试集,分别承担定量指标评估与工程适用性验证的不同目的。多场景综合测试集由长输管线及设备装置场景的射线图像构成,共包含4 318张图像、10 512个缺陷实例,覆盖表1中的9类缺陷。核电厂场景测试集来源于核电厂在役检测流程的少量射线底片样本,共180张图像、384个缺陷实例,受数据安全与获取条件限制,其规模不足以支撑mAP等性能指标的统计,因此该测试集仅用于验证模型是否满足核电厂工程



注:半径采用 $\sqrt{count}$ 映射,使扇区面积与缺陷数量近似成正比

图4 长输管线场景下9类焊缝缺陷实例数量分布及示例

Fig. 4 The distribution and examples of 9 types of weld defect instances in long-distance pipeline scenarios

应用的需求,以及展示模型在核电场景中的缺陷检出效果,同时对专业人员与模型的缺陷评定表现进行对比评估。

2.3 评价指标

对多场景综合测试集采用目标检测领域常用的精确率(Precision, P)、召回率(Recall, R)以及平均精度(mean Average Precision, mAP)作为评价指标,用于衡量模型在焊缝缺陷检测任务上的综合性能。

设在给定置信度阈值与匹配准则(IoU 阈值)下,模型预测的真阳性数量为 TP,假阳性为 FP、假阴性为 FN,则:

$$P = \frac{TP}{TP + FP}, R = \frac{TP}{TP + FN} \quad (19)$$

式中 TP 指预测框与真实框匹配且类别正确的检测结果;FP 指预测为缺陷但无法与任何真实缺陷匹配或类别错误的结果;FN 指真实缺陷未被任何预测结果覆盖的情况。

对每一类别 c , 根据不同置信度阈值下的 P - R 曲线计算该类别的平均精度 AP_c 。设类别集合为 C , 则有:

$$mAP = \frac{1}{|C|} \sum_{c \in C} AP_c \quad (20)$$

本文使用 $mAP@0.5$ 与 $mAP@0.5:0.95$, 前者表示 IoU 阈值固定为 0.5 时的 mAP, 后者表示 IoU 阈值从 0.5 到 0.95 (步长 0.05) 取平均的 mAP, 以更严格地衡量定位精度。

在核电厂场景测试集上评估模型不依赖严格

的 IoU 匹配规则, 而是采用更贴近工程实践的判据。模型输出的检测框覆盖了真实缺陷区域, 无论覆盖面积或框数量多少, 都视为该缺陷被成功检出, 以此计算检出率。然后沿缺陷走向对相关检测框计算累计长度, 经像素物理标定换算为毫米单位, 作为缺陷总长度, 与标准答案中的定量长度计算定量偏差率, 评估模型在缺陷定量上的准确性。

通过上述评估体系, 既能够对模型的泛化能力与检测精度进行系统性量化评估, 又从缺陷检出率与定量长度偏差两个维度验证模型在核电场景中的可靠性, 且通过本文方法与专业人员评定结果的对比可清晰评估与专业人员评定水准的差异, 可充分证明所提方法是否满足核电工程对“高检出率”和“合理定量”的核心需求。

2.4 数据标注规范

在数据标注方面, 本文采用具有射线评片经验的无损检测工程师对缺陷进行人工标注。标注内容包括缺陷的边界框, 并在涉及精细轮廓表达的情况下提供像素级掩膜标注。其中, 边界框用于监督目标检测分支, 掩膜用于监督引入分割头的检测分支(分支 1 与分支 3)。为降低不同标注人员之间的主观差异, 标注过程严格遵循统一的缺陷判读准则与边界界定规范, 标注完成后由另一名具有丰富射线评片经验的工程师进行复核与修订, 以尽可能保证标签语义的一致性与可靠性。

考虑到工程数据来源复杂、标注文件规模较大, 本文在模型训练前对全部标签文件进行了系统化的完整性与一致性检查, 包括类别编码合法性、

坐标归一化范围、空标注与异常边界框剔除等,以减少监督噪声对模型收敛过程和性能评估造成的干扰。

2.5 数据增强与采样策略

在类别分布长尾、跨场景成像差异显著的条件下,仅依赖原始训练样本往往会导致模型对高频类别过拟合、对低频类别欠学习,并在目标场景中出现漏检或误检。为提升训练数据多样性并增强模型对扫描噪声、曝光差异、焊缝纹理变化的鲁棒性,本文结合离线增强、在线增强与针对性重采样三类策略。

离线增强在训练前对图像及其标注同步变换,生成扩增样本用于构建 D_0 与 D_3 等训练集。离线增强包括:平移、旋转、裁剪、缩放、亮度和对比度调整以及添加高斯噪声等。对任意原始图像 I 及其标注集合 γ , 离线增强可表示为:

$$(I', \gamma') = \tau(I, \gamma) \quad (21)$$

式中 $\gamma(\cdot)$ 为确定性的几何与灰度变换算子集合。离线增强的优势在于可显式控制不同变换的比例与幅度,并可对 DDPM 生成的样本进行再增强以拓展其形态与背景多样性。

在线增强在训练迭代过程中按概率随机触发,增强模型对输入扰动的鲁棒性。本文采用的在线增强包括:随机裁剪、随机翻转、亮度 and 对比度随机扰动、尺度缩放、平移、轻微旋转及 Mosaic 增强等。在线增强的引入能够有效提升模型对焊缝背景变化与缺陷尺度变化的适应能力,并减少对特定扫描设备纹理与曝光条件的依赖。

对于核电场景重点缺陷分支(分支3)的训练数据集 D_3 , 本文在筛选获得与目标场景更接近的样本后,对样本数量明显偏少的类别采用离线过采样方式进行平衡,以降低漏检风险。设 D_3 中第 c 类样本数为 n_c , 目标平衡样本数为 n^* , 则可对少数类进行重复采样或增强扩增,使其满足 $n_c \rightarrow n^*$ 。该策略的动机是在核电关键部件检测中,重点缺陷的漏检代价显著高于误检代价,适度提高少数类的训练曝光度能提升召回率并增强系统的安全裕度。

2.6 实验环境与训练配置

本文实验在单机环境下完成,计算硬件配置及软件环境如表2所示。为与第1章方法设置保持一

致,本文主要训练参数如表3所示。

表2 试验软硬件配置

Table 2 Test software and hardware configuration

参数	数值/型号
操作系统	Windows 11 x64
CPU	Intel(R) Core(TM)i7-12700F
GPU	NVIDIA GeForce RTX 3090 Ti
派得林第六代工业底片扫描仪	NEU-ZD-VI, 220 V/50 Hz
软件环境	PyTorch 1.11.0+CUDA 11.3+Python 3.9

表3 主要训练参数

Table 3 Main training parameters

模型	名称	数值/型号
DDPM 生成模型	扩散步数 T	4 000
	噪声调度 β_t	线性从 1×10^{-4} 增至 2×10^{-2}
	训练轮数	800
	批次大小	64
	初始学习率	8×10^{-4}
多分支缺陷 检测模型	输入分辨率	640×640
	训练轮数	150
	学习率	余弦退火衰减
	分支1、2优化器	Adam
	分支3优化器	SGD
	anchor-based 初始化	k-means 聚类初始化 $n_a = 9$ 个锚框
	分支1、3综合损失权重	$(w_1, w_2, w_3, w_4) = (0.05, 0.05, 0.7, 0.3)$
推理后处理	NMS 交并比值	$\eta = 0.6$

3 结果与分析

通过上述测试集划分,本文分别从跨场景泛化能力与核电厂场景下工程应用可行性两个层面对所提出方法进行验证。在多场景综合测试集上,对本文方法的分类检测性能进行了统计分析,各类别的检测结果如表4所示。

由表4、图5可以看出,样本数量相对充足且表面形态较为稳定的RI与STI类缺陷检测效果较好,其mAP@0.5分别达到0.851和0.836,表明共享主干网络在多场景数据条件下能够学习到具有一定泛化能力的焊缝缺陷共性特征。

相比之下,BT、IP、CR及IC等实例数量较少或边界特征较弱的缺陷类别,其精确率与召回率均有所下降,且在更严格的mAP@0.5:0.95指标下性能衰减更为明显。这一现象符合焊缝射线检测的工

表4 多场景综合测试集各类别检测指标

Table 4 Multi-scenario comprehensive test set various detection indicators for each category

类别	图像数 /张	实例数 /个	P	R	mAP@ 0.5	mAP@ 0.5:0.95
RI	4 318	5 442	0.857	0.843	0.851	0.628
STI	4 318	2 736	0.841	0.829	0.836	0.609
BT	4 318	312	0.798	0.781	0.791	0.556
LFR	4 318	485	0.809	0.793	0.802	0.568
IFD	4 318	703	0.823	0.807	0.816	0.585
IP	4 318	268	0.784	0.765	0.776	0.541
CR	4 318	193	0.771	0.752	0.763	0.523
IU	4 318	315	0.779	0.761	0.771	0.534
IC	4 318	58	0.743	0.721	0.734	0.492

程实际特征,即小样本类别在训练过程中更易受到背景纹理与成像噪声的影响,同时裂纹、内凹等缺陷往往呈现细长或弱对比特征。

从工程角度分析,mAP@0.5与mAP@0.5:0.95之间的差距反映了模型在精细定位阶段所面临的挑战。在焊缝射线图像中,缺陷边界常与焊缝结构纹理相互叠加,且灰度过渡区域模糊,导致预测框与人工标注边界之间存在不可避免的偏差。此外,本文采用的宽向重叠分块推理策略在提升小目标检出率的同时,也可能在子图拼接边界处放大边界框的轻微偏移。总体而言,表4结果表明,本文提出的方法能够在多类焊缝缺陷上实现稳定检测,并在小样本类别上保持具有工程可用性的性能水平。




图5 各类别缺陷检测性能并列柱状图

Fig. 5 Bar chart showing the performance of defect detection for all categories

为验证本文方法的相对性能水平,选取YOLOv5m、YOLOv8m、YOLOv10m与YOLOv11x作为代表性单阶段检测器基线,在相同训练集与多场景综合测试集设置下进行对比评估,结果如表5、图6所示。可以看出,本文方法在mAP@0.5与mAP@0.5:0.95两项指标上均取得更优结果,其中mAP@

0.5:0.95相较YOLOv11x提升1.5个百分点,召回率提升亦明显。结合表4类别级结果可知,该提升主要来源于对弱对比与小尺度缺陷的检出稳定性增强,表明场景迁移生成与多分支互补建模能够有效缓解跨场景域差异与缺陷形态多样性带来的性能退化。另一方面,由于引入了多分支结构,本文方法的推理速度有所下降,但仍满足离线评片与半在线辅助判读的工程需求。

表5 多场景综合测试集上不同方法整体性能对比

Table 5 Overall performance comparison of different methods on a multi-scenario comprehensive test set

方法	P	R	mAP@ 0.5	mAP@ 0.5:0.95	FPS
YOLOv5m	0.738	0.729	0.735	0.501	72
YOLOv8m	0.751	0.744	0.749	0.518	75
YOLOv10m	0.759	0.753	0.757	0.527	79
YOLOv11x	0.776	0.771	0.774	0.545	56
本文方法	0.801	0.784	0.793	0.560	65




图6 各模型检测性能对比

Fig. 6 Comparison of detection performance of each model

为验证本文各模块设计的有效性,设计消融实验并在多场景综合测试集上进行评估,结果如表6所示。由A与B对比可见,引入DDPM场景迁移后召回率提升更为显著,说明目标风格数据在一定程度上弥补了跨场景成像差异对检出率的不利影响,尤其有助于缓解弱对比缺陷的漏检问题。进一步由B与C对比可知,多分支互补结构在mAP@0.5:0.95指标上带来更稳定的增益,表明其对多尺度与复杂形态缺陷的定位精度与分类鲁棒性具有促进作用。最后,分块推理与融合策略在整体指标上呈现小幅提升,主要体现在高分辨率长焊缝图像中对小目标细节的保留与边缘区域的覆盖增强。总体而言,各模块对性能提升具有叠加贡献,验证了本文方法框架的合理性与工程可用性。

核电厂场景测试集上评估结果如表7所示。由表可知,本文方法在核电厂场景上表现出与专业人

表 6 消融实验结果

Table 6 The results of the ablation experiment

方案	DDPM 迁移	多分支 互补	分块推 理融合	P	R	mAP@ 0.5	mAP@ 0.5:0.95
A	×	×	×	0.769	0.762	0.767	0.531
B	√	×	×	0.778	0.771	0.776	0.540
C	√	√	×	0.788	0.779	0.785	0.549
D	√	√	√	0.801	0.784	0.793	0.560

员相当的缺陷评定水平。在检出率方面,本文方法达到 94.1%,与专业人员的 95.1% 仅相差 1 个百分点,表明基于 DDPM 的场景迁移策略有效缓解了跨场景域偏差对模型泛化能力的不利影响,从工程可行性角度看,该检出率水平已满足核电焊缝辅助评定对高检出率的核心要求,降低人工评定的漏检风险;在定量偏差率方面,本文方法为 3.7%,与人工检测的 3.2% 基本持平,基本不影响焊缝的定量评级。值得注意的是,本文方法在评定效率方面具有显著优势,平均评定时间仅为 2.3 s/张,相比人工检测的 30.7 s/张提升了 12 倍。综合来看,本文方法在保持与专业人工评定相当的检出能力和定量精度的同时,显著提升了评定效率,满足核电场景中辅助工程师评片的工程需求。

表 7 核电厂场景测试集上不同方法性能对比

Table 7 Performance comparison of different methods on nuclear power plant scenario test set

评定方法	图像数量	缺陷实例数量	检出率	定量偏差率	平均评定效率(s/张)
人工评定	180	384	0.951	0.032	30.7
本文方法	180	384	0.941	0.037	2.3

本文提供核电厂场景测试集样例图来直观展示模型在该场景中的检出效果与典型难点。鉴于核电厂射线底片具有一定保密属性,样例图已进行了脱敏处理,仅保留与缺陷判读相关的焊缝区域。不同算法的缺陷检测效果对比如图 7 所示。

4 结论与展望

本文针对数据获取受限、跨场景成像差异且缺陷形态多样的工况,提出了一种面向核电厂焊缝影像的缺陷检测方法。首先,利用 DDPM 模型构建目标风格生成集以缓解跨场景域偏移。其次,构建共享主干与特征金字塔颈部的多分支检测结构,融合




图 7 检测效果

Fig. 7 Detection result visualization

anchor-based 与 anchor-free 机制,采用分阶段训练策略,增强对复杂形态与多尺度缺陷的适配性。最后,引入自适应窗宽窗位增强与宽向重叠分块推理,以满足长条形高分辨率焊缝射线图像的工程部署需求。在包含 9 类缺陷的多场景综合测试集上,与 YOLO 系列主流基线方法相比,本文方法 mAP@0.5 和 mAP@0.5:0.95 分别实现约 1.9~5.8 个百分点与 1.5~5.9 个百分点的提升,召回率提升约 1.3~5.5 个百分点。在核电厂场景下,本文方法在缺陷检出率与定量偏差率方面与专业人工评定保持同等水平,同时在评片效率上显著提升,满足了核电厂工程实践中辅助评片的实际需求。另外,本文方法能够在复杂背景下有效检出弱对比、小尺度及细长形态缺陷,具备一定工程应用潜力。

尽管本文方法在多场景焊缝缺陷检测中表现良好,但仍存在以下局限性:(1)数据长尾分布影响少数类难样本检测稳定性。通过对测试集中失败案例分析发现,某些裂纹和内凹缺陷因轮廓特征弱或形态不规则,易被划伤伪像或焊纹干扰,导致边界定位不准而部分漏检。(2)由于核电厂真实测试

样本获取受限,本文仅使用180张图像,虽从工程适用性角度通过可视化和与专业人员对比分析已能初步验证方法有效性,但为了进一步实现统计显著性的量化评估,测试样本量仍有待提升。

针对上述局限性,后续工作可从这方面展开:

(1)引入生成样本的自动质量评估与筛选机制,结合轻量化域适应或不确定性驱动的重采样策略,提高场景泛化能力与少数类鲁棒性。(2)在确保数据安全的前提下,逐步扩充核电厂场景样本库,构建更具代表性的测试集,增强评估可靠性。

参考文献:

- [1] 兰天宇,高延峰,孙艺瑕.基于CLAHE和改进YOLOv8的焊缝冷阴极X光缺陷检测[J].热加工工艺,2026,55(2):117-124.
LAN T Y,GAO Y F,SUN Y X. Research on Weld Cold Cathode X-ray Defect Detection based on CLAHE and Improved YOLOv8[J].Hot Working Technology,2026,55(2):117-124.
- [2] 杨莉华,赵金宪,李金晓,等.基于AM-TransUNet的X射线图像中铜管钎焊缺陷分割算法[J].焊接学报,2025,46(7):100-106.
YANG L H,ZHAO J X,LI J X,et al. Defect segmentation algorithm for copper pipe soldering in X-ray images based on AM-TransUNet[J]. Transactions of The China Welding Institution,2025,46(7):100-106.
- [3] 邓聪,罗伟坚,李绪丰.人工智能技术在射线检测底片评定系统中的应用[J].无损检测,2022,44(8):65-68.
DENG C,LUO W J,LI X F.Application of artificial intelligence technology in radiographic inspection film evaluation system[J]. Nondestructive Testing,2022,44(8):65-68.
- [4] 王智,李阳,宋卫臣,等.基于深度学习的焊缝缺陷射线检测[J].无损检测,2025,47(10):58-65.
WANG Z,LI Y,SONG W C,et al. Deep learning-based radiographic detection for weld defects[J]. Nondestructive Testing,2025,47(10):58-65.
- [5] 王树森,李萍,黄大伟,等.基于深度学习的焊缝缺陷X射线检测图像识别与增强[J].无损检测,2024,46(6):17-23.
WANG S S,LI P,HUANG D W,et al. Image recognition and enhancement of X-ray detection of weld defects based on deep learning[J]. Nondestructive Testing,2024,46(6):17-23.
- [6] Zhang M,Feng M,Chen C,et al. Weld defect detection: deep learning-based image processing and the mechanisms of defect formation[J]. Archives of Computational Methods in Engineering,2026,33(3):3525-3563.
- [7] Zhang R,Liu D,Bai Q,et al. Research on X-ray weld seam defect detection and size measurement method based on neural network self-optimization[J]. Engineering Applications of Artificial Intelligence,2024,133:108045.
- [8] Zuo F,Liu J,Fu M,et al. An end-to-end intelligent welding defect detection system for low-quality X-ray images with adaptive progressive learning[J]. Expert Systems with Applications,2025,279:127428.
- [9] Lin T Y,Dollár P,Girshick R,et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE conference on computer vision and pattern recognition,2017:2117-2125.
- [10] Xu H,Yan Z H,ji B W,et al. Defect detection in welding radiographic images based on semantic segmentation methods[J]. Measurement,2022,188:110569.
- [11] Wang X,He F,Huang X. A new method for deep learning detection of defects in X-ray images of pressure vessel welds[J]. Scientific Reports,2024,14(1):6312.
- [12] Li B,Ma Z,Qi T,et al. X-ray weld defect detection based on data augmentation and improved YOLO v7[C]//Third International Conference on Advanced Manufacturing Technology and Manufacturing Systems (ICAMTMS 2024),SPIE,2024,13226:444-450.
- [13] Yang K,Liu Y,Zhang S,et al. Surface defect detection of heat sink based on lightweight fully convolutional network[J]. IEEE Transactions on Instrumentation and Measurement,2022,71:1-12.
- [14] 岳忠牧,张喆,吕武,等. De-DDPM: 可控、可迁移的缺陷图像生成方法[J]. 自动化学报,2024,50(8):1539-1549.
YUE Z M,ZHANG Z,LV W,et al. De-DDPM: A controllable and transferable defect image generation method[J]. Acta Automatica Sinica,2024,50(8):1539-1549.
- [15] Xu R,Chiu Y T,Chen T I,et al. Training-Free Industrial Defect Generation with Diffusion Models[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision,2025:24214-24223.