

DOI: 10.19650/j.cnki.cjsi.J2513913

基于 DSG-ResNet34 的聚乙烯燃气管道 电熔焊接缺陷检测*

凌 晓¹, 刘 露¹, 孙宝财², 张正棠², 徐晓刚¹

(1. 兰州理工大学石油化工学院 兰州 730000; 2. 甘肃省特种设备检验检测研究院 兰州 730000)

摘 要: PE 燃气管道的连接质量能直接影响中低压燃气的正常输送, 在电熔焊接时产生的结构畸变、冷焊等缺陷会显著削弱管道的力学性能, 威胁燃气管网的稳定运行。因此, 基于实地采集的 PE 燃气管道电熔焊接缺陷 DR 图像数据集, 提出了基于 DSG-ResNet34 模型的缺陷检测方法, 以实现电熔焊接缺陷进行快速精准地检测。该网络模型由主干网络 CBAM-ResNet34 模块、动态稀疏门控金字塔 DSG-FPN、多尺度检测头 3 个部分组成, 首先通过主干网络 CBAM-ResNet34 结构从通道和空间两个维度提升网络模型对缺陷特征的关注度, 然后通过动态稀疏门控金字塔 DSG-FPN 结构的动态稀疏门控模块、Inception 模块、稀疏连接动态融合多尺度缺陷特征, 有效保留小目标特征、抑制背景噪声, 最后通过多尺度检测头结构将提取到的丰富特征转化为具体的检测结果。DSG-ResNet34 模型的缺陷检测准确率最高可达 95.5%、P2 层精确率最高可达 82.7%、小目标召回率最低为 85.6%、检测速度可达 68 fps、参数量为 22.3×10^6 , 该模型能快速定位识别孔洞、熔融面夹杂、结构畸变、冷焊这 4 类典型电熔焊接缺陷, 检测性能与速度优于其他网络模型。为 PE 管道焊接质量智能化检测提供了高精度解决方案, 对保障燃气管网安全运行具有重要意义。

关键词: 聚乙烯燃气管道; 缺陷检测; 电熔焊接; ResNet34 模型; 特征金字塔

中图分类号: TH49 **文献标识码:** A **国家标准学科分类代码:** 440.55

Defects detection of electric fusion welding of polyethylene gas pipeline based on DSG-ResNet34

Ling Xiao¹, Liu Lu¹, Sun Baocai², Zhang Zhengtang², Xu Xiaogang¹

(1. School of Petrochemical Engineering, Lanzhou University of Technology, Lanzhou 730000, China;

2. Gansu Province Special Equipment Inspection and Testing Institute, Lanzhou 730000, China)

Abstract: The connection quality of PE gas pipelines can directly affect the normal transmission of medium and low-pressure gas. Structural distortion, cold welding and other defects produced by electrofusion welding will significantly weaken the mechanical properties of the pipeline, which will threaten the stable operation of the gas pipeline network. Therefore, based on the DR Image datasets of PE gas pipelines electrofusion welding defects collected on-site, this paper proposes a defect detection method based on the DSG-ResNet34 model to realize rapid and accurate detection of electrofusion welding defects. This network model consists of three parts: the backbone network CBAM-ResNet34 module, the dynamic sparse gating feature pyramid networks DSG-FPN, and the multi-scale detection head. Firstly, the CBAM-ResNet34 structure of backbone network is used to enhance the network model's attention to defect features from two dimensions of channel and space. Then, the DSG-FPN, which integrates a dynamic sparse gating module, an Inception module, and sparse connections, dynamically fuses multi-scale defect features-effectively preserving small-target features while suppressing background noise. Finally, the multi-scale detection head converts the enriched features into precise detection outputs. The DSG-ResNet34 model achieves a defect detection accuracy of up to 95.5%, with a P2 layer precision of 82.7% and a minimum recall rate of 85.6% for small targets. The detection speed reaches 68 fps, and the model contains 22.3 million parameters. This model can quickly

收稿日期: 2025-04-10 Received Date: 2025-04-10

* 基金项目: 国家自然科学基金(52466003)、甘肃省重点研发计划(23YFGA0059)项目资助

locate and identify four typical electrofusion welding defects: holes, fused surface inclusion, structural distortion and cold welding. Both its detection performance and speed outperform existing models. This study provides a high-precision solution for intelligent testing of PE pipeline welding quality, which is of great significance for ensuring the safe operation of gas pipeline network.

Keywords: polyethylene gas pipeline; defect detection; electric fusion; ResNet34 model; feature pyramid networks

0 引 言

随着城镇化进程加快,我国燃气管网规模逐年扩大,聚乙烯(polyethylene, PE)管道的投入量也越来越多,电熔焊接作为 PE 管道的常用连接工艺,其连接质量直接威胁能源供应的稳定性,据统计显示,35%的燃气泄漏事故源于电熔焊接连接界面处^[1-2]。由于温度、压力等因素的影响,在进行电熔焊接时极易在管道连接处产生结构畸变、冷焊等焊接缺陷,焊接缺陷的存在会影响管道的连接质量和使用寿命,还会引发严重的社会公共安全^[1]。目前,针对 PE 管道焊接缺陷检测的研究主要包括无损检测技术和智能检测算法。相控阵超声(phased array ultrasonic testing, PAUT)检测技术、数字射线(digital radiography, DR)检测技术等无损检测技术尽管可以直观地获取管道内部图像,但由于这些技术依赖于人工视觉进行缺陷检测,容易因人为主观性判断、视觉角度偏移等原因造成缺陷判定的偏差,导致缺陷检测的效率低下、漏检率较高,难以满足当代工业化需求^[3];相比之下,智能检测算法通过引入深度学习技术,能够自动提取大量数据中的关键特征,学习识别缺陷与正常区域的差异,实现对缺陷的精准识别与定位,具有高精度、高效率 and 自动化程度高的优势,能有效弥补人工视觉检测技术的不足^[4]。

残差神经网络(residual neural network, ResNet)模型凭借其深度、残差连接和灵活性,在检测任务中受到了学者们的广泛应用。然而,ResNet 模型的深度较大,会导致其参数量与计算量增加,从而影响实时性,并且随着下采样的次数增多还容易出现小目标的细节信息丢失问题,因此许多学者基于 ResNet 模型,采用混合架构的方式针对实时性差、目标尺度差异大、小目标难以检测等问题提出了不少改进方法^[5-7]。Yin 等^[8]在 ResNet34 的残差块中引入深度可分离卷积(depthwise separable convolution, DSConv)替代传统标准卷积,同时嵌入类 Inception 多分支结构,在残差块内并行使用不同尺度的卷积核,捕获电力系统暂态数据的多时间尺度特征,使得改进后的模型能在保持深度的同时实现高效计算;Xu 等^[9]提出了一种基于端到端 FPN-ResNet34 的缺陷检测算法,通过构建一个多尺度特征金字塔,能够更好地融合底层高分辨率特征,从而精准捕捉焊缝图形中的微小缺陷,避免误检、漏检;Chernov 等^[10]在 ResNet34 的卷积层中插入卷积块注意力模块(convolutional block attention module, CBAM),

将声发射(acoustic emission, AE)信号通过长短时记忆神经网络(long short-term memory networks, LSTM)提取的时序特征转换为空间注意力权重,突破了传统多模态融合中“后期拼接(late fusion)”的局限性,实现特征层级的深度融合,有效提高了隐性缺陷检出率;刘述喜等^[11]在 ResNet34 模型通过引入压缩-激励(squeeze-and-excitation, SE)注意力机制与双向门控循环单元,使得模型能通过通道注意力机制动态调整特征图的通道权重,还能更好地处理复杂的数据分布和时间序列信息,有效提高模型的鲁棒性、增强模型在不同工况和噪声条件下的抗干扰能力;Mirza 等^[12]在 ResNet34 后端嵌入多分辨率递归神经网络(multi-scale residual deep neural network, MRNN),结合 LSTM 和门控循环单元(gate recurrent unit, GRU),分别处理不同时间分辨率的数据,解决传统 ResNet 对时序数据建模不足的问题,其在残差块中引入门控单元的方法,能根据输入特征动态调整跳跃连接强度,避免深层网络中的特征退化。

基于上述研究,以 PE 燃气管道电熔焊接缺陷检测为研究对象,提出了一种基于动态稀疏门控的残差网络(dynamic sparse gate ResNet34, DSG-ResNet34)模型的智能检测方法。首先,根据结构畸变、冷焊、孔洞、熔融面夹杂 4 个电熔焊接典型缺陷的 DR 图像特征,构建 1 800 张标注图像的数据集作为网络模型的输入;其次,为保留模型体量与实时性的同时,提升 ResNet34 模型的特征提取效果,增强其检测效果,将原始 ResNet34 模型与 CBAM 模块结合作为主干网络,并设计动态稀疏门控特征金字塔(dynamic sparse gate feature pyramid networks, DSG-FPN)实现多尺度特征的自适应融合,然后融合多级检测头(P2-P5)架构进行优化,最终创新性地构建了一个兼顾精度与效率的轻量化检测模型,利用指数线性单元(exponential linear units, ELU)激活函数进行进一步改进,以改善网络的收敛速度与泛化能力。实验结果表明,所提方法在保持高检测精度的同时,显著提高了实时性和模型的轻量化程度,为工业缺陷检测提供了高精度、高效率的解决方案。

1 基于 ResNet34 模型的改进方法

1.1 DSG-ResNet34 模型

基于 ResNet34 模型依次引入 CBAM 模块、优化金字塔结构、引入检测头、优化激活函数进行改进,最终网络

模型结构如图 1 所示,主要包括 3 个模块:1) 左侧为 DSG-ResNet34 模型的骨干网络结构 CBAM-ResNet34,经过卷积层、批量归一化层、ELU 激活函数、池化层等完成基础的特征提取,加入的 CBAM 模块能有效提升网络模型对缺陷重要特征的关注。2) 中间为对应各阶段层次的特征金字塔 DSG-FPN,通过动态门控模块生成门控权重,控制特征融合过程;Inception 模块进行多尺度卷积操作;稀疏连接减少计算量和内存占用。DSG-FPN 使得网络模型能自适应地融合多尺度特征,有效应对不同类型、不同大小的缺陷检测任务,同时减少冗余计算与内存占用,使模型更加轻量化、推理速度更快。3) 右侧为检测头,由分类和回归两个并行分支组成,将前面模块提取到的丰富特征转化为具体的检测结果,包括缺陷的位置和类别等信息。

1.2 ResNet34 结构改进策略

1) 引入特征注意力机制模块 CBAM

CBAM 模块由通道注意力模块 (channel attention module, CAM) 和空间注意力模块 (spatial attention module, SAM) 串联组成,其核心思想是通过自适应特征校准提升模型表达能力^[13]。其中,通道注意力模块通过计算通道间的相关性来生成通道权重,空间注意力模块通过计算空间位置上的相关性来生成空间权重,两个子模块通过融合操作得到增强后的特征图,更加有效地聚焦于重要特征,提高模型的分类准确率^[14]。

选择将 CBAM 模块放置于 ResNet34 模型的最大池化层和平均池化层前面,这样可以优先对特征图进行通道和空间的注意力加权,有效避免池化操作对重要特征的盲目压缩。CBAM 模块的前置,可以使模型在空间分辨率降低之前,通过 CAM 精准地筛选出与缺陷相关的关键通道特征,然后通过 SAM 调整特征图尺寸以增强对关键区域的注意力,捕捉更细微的空间差异。加入 CBAM 模块后的骨干网络结构如图 1 所示。




图 1 DSG-ResNet34 模型结构

Fig. 1 The structure of DSG-ResNet34 model

如图 1 (a) 中的 CAM 模块所示,输入一个尺寸为 $H \times W \times C$ (H 、 W 和 C 分别表示特征图的高度、宽度和通道

数)的特征图 F ,先进行通道维度的全局最大池化,再进行全局平均池化,分别得到两个 $1 \times 1 \times C$ 的特征图,即一

维矢量,其中,最大池化设置于残差模块之前用于下采样与特征提取,只保留强响应特征,平均池化层则用于最后的特征压缩阶段,反馈特征的每一个像素点;然后,将全局最大池化和全局平均池化的结果,先后送入一个共享的多层感知器(multi-layer perception, MLP)中学习,得到两个 $1 \times 1 \times C$ 的特征图。MLP的第1层神经元个数为 C/r ,激活函数为线性整流(rectified linear unit, ReLU),第2层神经元个数为 C ;最后,将MLP输出的结果进行“加”操作,接着经过逻辑激活函数(Sigmoid)的映射处理,最终得到通道注意力权重矩阵 $\mathbf{M}_c(\mathbf{F})$,该权重矩阵用于对特征图的每个通道进行加权,从而增强重要通道的信息并抑制不重要的通道。计算公式如式(1)所示。其中,MLP中的权值 W_0 和 W_1 间存在权值共享。CAM使得模型能更关注于缺陷区域特征、有效抑制背景噪声,从而避免传统注意力机制带来的计算冗余问题、大幅度提升缺陷检测准确率。

$$\mathbf{M}_c(\mathbf{F}) = \sigma \{ \text{MLP}[\text{AvgPool}(\mathbf{F})] + \text{MLP}[\text{MaxPool}(\mathbf{F})] \} \quad (1)$$

式中: σ 为Sigmoid函数。

如图1(a)中的SAM模块所示,先后通过最大池化和平均池化对一个尺寸为 $H \times W \times C$ 的输入特征图 $\mathbf{F}$ 的通道维度进行压缩操作,输入特征分别在通道维度上进行了最大值和均值采样操作,得到了两个 $H \times W \times 1$ 的二维特征;然后按照通道维度进行拼接,得到特征图尺寸为 $H \times W \times 2$;最后,拼接的特征图先通过卷积操作得到特征图尺寸为 $H \times W \times 1$,接着通过Sigmoid激活函数得到空间注意力权重矩阵 $\mathbf{M}_s(\mathbf{F})$,该权重矩阵用于对特征图的每个位置进行加权,从而增强重要空间区域的信息并抑制不重要的空间区域。计算公式如式(2)所示。SAM可以通过建立不同区域之间的相关性与紧凑性,帮助模型更好地捕捉图像中不同区域的重要性。

$$\mathbf{M}_s(\mathbf{F}) = \sigma \{ \text{Conv}_{7 \times 7} \{ [\text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F})] \} \} \quad (2)$$

式中: $\text{Conv}_{7 \times 7}$ 为空间平均池化特征。

在池化前通过注意力机制筛选重要信息,相当于在信息瓶颈前进行“提纯”,降低无效信息进入下采样阶段的比例,同时其注意力权重通过可学习的参数生成,在反向传播时梯度可作用于特征选择过程,使网络更高效地学习判别性特征,能有效强化小目标缺陷的相关通道,减少池化后的模糊效应,增强小目标和复杂背景的特征表达能力^[15]。通过CBAM模块将空间注意力权重和通道注意力权重进行乘法操作来实现对输入特征图的特征加权,最终得到输出特征图,计算公式如式(3)、(4)所示。

$$\mathbf{F}' = \mathbf{M}_c(\mathbf{F}) \otimes \mathbf{F} \quad (3)$$

$$\mathbf{F}'' = \mathbf{M}_s(\mathbf{F}') \otimes \mathbf{F}' \quad (4)$$

式中: $\mathbf{F}'$ 为通道注意力模块的输出; $\mathbf{F}''$ 为CBAM网络的输出。

2) 优化金字塔结构

在ResNet34模型中引入CBAM机制之后,模型提取的特征图已具备“通道-空间双维度注意力筛选”能力,传统特征金字塔网络(feature pyramid networks, FPN)通过“自顶向下路径+横向连接”融合多尺度特征,大量特征无法有效参与融合、模型参数复杂度提升、特征融合时无法动态适应输入变化等问题更为突出^[16]。门控网络可以根据输入图像内容动态选择性地激活或抑制不同层次的特征,这种动态调整能力使得模型能够更灵活地适应特征融合过程,稀疏连接可以选择性地连接特征图的不同部分,在更好地处理多尺度目标的同时能避免过多的跨尺度信息干扰、减少计算冗余,在Zhu等^[17]提出动态特征金字塔网络(dynamic feature pyramid networks, DyFPN)中,动态门控模块的引入能根据输入图像内容动态决定是否跳过某些卷积层,在保持精度的同时有效减少了计算量,但在该网络中仅支持单尺度门控信号;在赵婷婷等^[18]提出的门控Transformer模型(gated Transformer-XL, GTrXL)中,稀疏连接被引入FPN的不同层次之间,有效降低了模型的复杂度,使模型更聚焦于对关键特征。

因此,结合动态门控机制与稀疏连接,基于FPN建立了DSG-FPN结构。DSG-FPN结构由稀疏连接(sparse connections)、Inception模块、动态稀疏门控模块(dynamic sparse gate module, DSG)组成,可以动态选择性地激活或抑制不同层次的特征,通过动态稀疏门控机制优化特征融合过程,从而提升目标检测的精度与效率。其中,稀疏连接通过在关键特征层之间进行信息传递,有效保留与缺陷检测相关的关键区域特征、减少背景噪声的干扰;Inception模块结构如图1(b)所示,该模块可以通过并行的多尺度卷积操作共享参数,不仅能提取不同尺度的特征,还能减少总的计算量;动态稀疏门控模块结构如图1(c)所示,该模块不仅能通过动态稀疏机制选择性地提取与利用特征,还可以通过门控机制来传递和融合特征,增强不同层次特征之间的交互作用,提升模型在复杂背景下的适应能力。

动态稀疏门控模块是DSG-FPN的核心组件,在数学描述上可分为门控生成和稀疏约束部分,其中,据输入特征动态生成门控权重,这些权重用于控制不同特征的融合程度,将池化后的特征图输入门控网络中后会输出一个 $1 \times 1 \times C$ 的门控权重向量 $\mathbf{G}$,其中每个元素的 G_i 对应于特征图 $\mathbf{F}$ 的第 i 个通道的门控权重,如式(5)所示;稀疏约束部分则是对通过稀疏化处理减少不必要的计算和内存占用,对门控权重 $\mathbf{G}$ 应用正则化后得到 $\mathbf{G}_{reg}$,将 $\mathbf{G}_{reg}$ 中小于某个阈值的元素置为0,得到稀疏化的门控权重

$\mathbf{G}_{sparse}$, 如式(6)、(7)所示;最后使用稀疏化的门控权重 $\mathbf{G}_{sparse}$ 对输入特征图 $\mathbf{F}$ 进行加权融合, 如式(8)、(9)所示。动态稀疏门控模块在多尺度特征融合中, 能根据输入内容动态调整不同层级特征的贡献权重, 确保不同尺度特征的有效融合, 从而保留缺陷区域的关键特征、减少模型参数量和计算量。

$$\mathbf{G} = \sigma(\mathbf{W}_g \times \text{AvgPool}(\mathbf{F}) + b_g)$$

(5)

$$\mathbf{G}_{reg} = \mathbf{G} - \lambda \times \sin(\mathbf{G})$$

(6)

$$\mathbf{G}_{sparse} = \max(\mathbf{G}_{reg}, 0)$$

(7)

$$\mathbf{F}_{weighted} = \mathbf{F} \times \mathbf{G}_{sparse}$$

(8)

$$\mathbf{F}_{fused} = \sum_{i=1}^C \mathbf{F}_{weighted}^i$$

(9)

式中: $\mathbf{G}$ 是门控权重向量; $\mathbf{W}_g$ 是门控网络的权重矩阵; b_g 是偏置项; $\mathbf{G}_{reg}$ 是正则化后的门控权重; λ 是正则化系数; $\mathbf{F}_{weight}$ 是加权后的特征图; $\mathbf{F}_{fused}$ 是最终的融合特征图; i 是第 i 个通道。

3) 引入检测头

为了使 ResNet34 模型能够进行多标签分类预测, 本文提出在 DSG-FPN 结构后面引入 P2、P3、P4、P5 检测头结构, 用于接收来自金字塔网络的特征图并生成目标检测的结果, 包括预测类别概率与预测边界框, 检测头的结构与计算过程如图 1(d) 所示, 首先通过 $\text{Conv}_{1 \times 1}$ 进行通道调整, 然后进入分类与回归的两个分支, 其中分类分支可以预测每个锚框或特征图位置对应的缺陷类别, 分类分支先接入含有批量归一化层与 ELU 层的 $\text{Conv}_{3 \times 3}$ 进行特征提取, 然后再接入 $\text{Conv}_{1 \times 1}$ 将通道数调整为类别数, 最终输出每个缺陷的空间位置的类别及其对应的预测概率; 回归分支则是先接入带批量归一化层与 ELU 层的 $\text{Conv}_{3 \times 3}$ 以提取用于回归的特征, 然后接入 $\text{Conv}_{1 \times 1}$ 对特征图进行回归预测, 输出每个缺陷位置的边界框坐标。

4) 改进激活函数

激活函数是在卷积运算后再进行非线性函数运算, 通过在非线性激活函数的帮助下向网络添加非线性, 其能够实现从输入到输出的非线性映射。常见的激活函数为 Sigmoid 函数、双曲正切 (Tanh) 函数、ReLU 函数和 ELU 函数, 当梯度较大或者较小时, Sigmoid 函数和 Tanh 函数会迅速减小, 容易导致梯度消失的问题, 两者的梯度方差会随着层数增加而减小, 不适用于深层网络; 而 ReLU 函数的梯度在正值区域时为 1, 在负值区域时为 0, 这将使得神经元无法更新; ELU 函数则在负值区域时处于非零状态, 弥补了 ReLU 的不足, 在深层网络中表现则会更加稳定, 尤其在负值区域, 这有助于提高模型的训练效率和泛化能力, 此外, 它的输出值更接近于零均值, 这有助于加速神经网络的训练过程能够帮助网络更快地收敛。因此, 本文选择将 ELU 函数应用到 ResNet34 模型中, 其公式如式(10)所示^[19]。

$$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x \leq 0 \end{cases}$$

(10)

2 实验结果与分析

2.1 数据集构建与处理

采用的数据集为现场实测的 PE 燃气管道电熔焊接缺陷 DR 图像, 获取设备为便携式 DR 成像系统, 确保清晰丰富的内部结构场景输入。数据集中包括 4 个检测目标, 即结构畸变 (structural distortion, SD)、冷焊 (cold welding, CW)、孔洞 (hole, Hole)、熔融面夹杂 (fused surface inclusion, FSI), 各类缺陷样本标注数量与 DR 图像数量的分布情况如表 1 所示, 其中, 训练集、验证集、测试集的比例为 7:2:1。使用图像标注工具 LabelImg 对缺陷的类型与位置进行标注, 数据集格式为 COCO (common objects in context)。部分采集的 DR 图像如图 2 所示。

表 1 数据集分布情况

Table 1 The distribution of the dataset

数据集类别	对象数量/个	SD	Hole	CW	FSI	总计
训练集	样本标注	311	424	316	405	1 456
	DR 图像	281	345	294	340	1 260
验证集	样本标注	93	125	89	130	437
	DR 图像	80	99	84	97	360
测试集	样本标注	43	60	45	57	205
	DR 图像	40	49	42	49	180




图 2 部分采集的电熔焊接缺陷 DR 图像

Fig. 2 The collected partial DR images of welding defects

2.2 实验环境与参数

实验模型所采用的平台配置:Windows 10 Pro 64-bit 操作系统, Intel Xeon Platinum 8375C CPU @ 2.90 GHz 处理器, NVIDIA GeForce RTX 3060 12 GB GDDR6 显卡, 128 GB DDR4 3 200 MHz 内存。本文所有编程和模型训练均采用 Python3.9 编程语言, 通过 PyTorch 框架建立 DSG-ResNet34 模型, 对 PE 燃气管道电熔焊接缺陷数据集进行实验。经过多次训练调试, 将模型各项参数设置为迭代次数 (epoch) 设置为 100, 批大小 (batch size) 为 128, 学习率设置为 0.000 1, 损失函数设置为交叉熵函数, 优化器 Adam 的 Momentum 参数为 0.9, 具体如表 2 所示。

表 2 最佳训练参数表

Table 2 Optimum training parameters	
名称	最佳参数
迭代次数	100 次
Batch_size	128
学习率	0.000 1
损失函数	交叉熵
优化器	Adam

2.3 网络性能评价指标

本文采用准确率 (Accuracy)、各类缺陷的召回率 (Recall)、P2 层检测精度 (Precision_{p2}) 作为 PE 管道电熔

焊接缺陷检测的评估检测性能的指标, 并采用推理速度 (frames per second, FPS) 与模型参数量 (params) 为衡量模型实时性与轻量化的指标, 计算 Accuracy、Recall 和 Precision_{p2} 的公式如式 (11) ~ (13) 所示。对于本次实验, 准确率是指模型正确分类的样本数量占总样本数量的比例, 精确率是指分类为正例中真正例样本的比例, 召回率是指真正例样本占实际正例样本总数的比例, 推理速度则指型每秒可以处理的图像帧数, 本实验则通过这些指标来综合评量模型的性能。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$
 (11)

$$Recall = \frac{TP}{TP + FN}$$
 (12)

$$Precision_{p_2} = \frac{TP_{p_2}}{TP_{p_2} + FP_{p_2}}$$
 (13)

式中: TP、TP_{p2} (true positive) 表示真正例样本的数量; TN (true negative) 表示真反例样本的数量; FP、FP_{p2} (false positive) 表示假正例样本的数量; FN (false negative) 表示假反例样本的数量。

2.4 实验结果与分析

1) DSG-ResNet34 模型训练结果与分析

为突出 DSG-ResNet34 网络模型相对于原始 ResNet34 模型的有效性与优越性, 在相同的实验环境与参数的条件下, 对 ResNet34 模型、DSG-ResNet34 模型进行训练, 训练结果如表 3、图 3 所示。

表 3 网络模型改进前后的训练结果对比

Table 3 The training results comparison of network model before and after improvement

网络模型	Accuracy/%	Recall/%				Precision _{p2} /%	FPS	params
		SD	FSI	CW	Hole			
DSG-ResNet34	95.5	98.1	85.6	98.8	88.3	82.7	68	22.3×10 ⁶
Resnet34	82.2	78.2	23.5	82.3	35.1	53.4	72	21.8×10 ⁶




图 3 网络模型改进前后的 Accuracy 与 Precision_{p2} 变化曲线

Fig. 3 The change Accuracy and Precision_{p2} curves between network model before and after improvement

从表 3、图 3 可以看出,训练开始时 DSG-ResNet34 模型的 Accuracy 与 Precision_{p2} 曲线都呈现上升趋势, Accuracy 在迭代 44 次达 95.5% 且趋于稳定、Precision_{p2} 在迭代 52 次达 82.7% 且趋于稳定,而原 ResNet34 模型 Accuracy 在迭代第 73 次才达到 82.2%、Precision_{p2} 在迭代 89 次达 53.4%,但其曲线的上下波动幅度较大且出现过 0 值,这就说明了改进的模型利用 ELU 函数有效解决了神经元“坏死”的问题,同时利用 CBAM 模块与 DSG-FPN 有效增强模型的多尺度特征提取能力,使得 Accuracy、Precision_{p2} 曲线的波动幅度均减缓,防止过拟合化。DSG-ResNet34 模型提升了原模型的收敛速度、多尺度缺陷检测效果,其 Hole 与 FSI 的 Recall 值也得到显著改善,能更好地处理小目标的特征提取与融合,进一步证明了该模型在小目标检测方面的优势。除此外,DSG-ResNet34 模型 FPS 仅下降 0.4 帧、模型体积仅增加

2.3%,部署成本几乎不变,但其他指标远超原模型,说明 DSG-FPN 结构有效抑制了背景噪声、更加关注于关键特征,在参数量小幅度增加的情况下,显著优化了特征融合效率,表明 DSG-ResNet34 模型的改进模块的计算开销控制得较好。

预测结果可视化对比如图 4 所示,可以发现,原 ResNet34 模型在小目标检测时效果极差,出现了目标误检、漏检的情况,同时在识别结构畸形、冷焊缺陷时出现不同程度的误检和重叠框问题,说明原 ResNet34 模型的特征提取能力与理解能力较差,在检测多尺度和背景复杂的焊接缺陷时容易出现漏检、误检和重复检测的问题;相比之下,本文提出的 DSG-ResNet34 模型在进行多尺度和背景复杂的缺陷检测时的表现更为优越,能精准定位、识别不同尺度和类别的缺陷,从而减少误检、漏检和重叠框问题。




图 4 网络模型改进前后的测试结果可视化对比

Fig. 4 The visual test results comparison of network model before and after improvement

2) CBAM 及结合方式对模型性能的影响

为探索 CBAM 结合方式的性能影响,本文在相同条件下构建了 7 种对比模型,分别是只在最大池化层后引入 CBAM (CBAM_1)、只在最大池化层前引入 CBAM (CBAM_2)、只在平均池化层前引入 CBAM (CBAM_3)、Conv_2x 阶段最后一个残差块后引入 CBAM (CBAM_4)、Conv_3x 阶段最后一个残差块后引入 CBAM (CBAM_5)、每个阶段最后一个残差块后都引入 CBAM (CBAM_6)、

在最大池化层和平均池化层之前都引入 CBAM (CBAM_7),验证结果如表 4 所示。由表 4 可知:CBAM_7 实现了 87.6% 的最高 Accuracy 和 62.4% 的最高 Precision_{p2},效果最差的 CBAM_1 说明了在特征降维后引入 CBAM 无法充分利用原始特征信息,CBAM_2 和 CBAM_3 引入 CBAM 的效果仅次于 CBAM_7,这得益于 CBAM 在最大池化层前能增强对缺陷边缘和纹理特征的捕捉能力、在平均池化层前能有效保留区域整体特征,同时也有验证

表 4 CBAM 不同结合方式的验证结果

Table 4 The validation results of CBAM different combination methods

网络模型	Accuracy/%	Recall/%				Precision _{p2} /%	FPS	params
		SD	FSI	CW	Hole			
Baseline	82.2	78.2	23.5	82.3	35.1	53.4	72	21.8×10 ⁶
+CBAM_1	83.8	80.5	35.2	84.1	57.8	56.6	70	22.0×10 ⁶
+CBAM_2	85.4	83.6	68.1	86.1	70.3	60.0	71	22.0×10 ⁶
+CBAM_3	85.0	81.9	63.3	85.2	68.5	58.8	70	22.0×10 ⁶
+CBAM_4	84.8	81.5	56.7	84.8	67.9	57.9	69	22.1×10 ⁶
+CBAM_5	85.0	82.1	57.9	85.7	68.2	58.8	68	22.2×10 ⁶
+CBAM_6	86.6	84.3	67.2	88.4	72.3	61.8	64	23.2×10 ⁶
+CBAM_7	87.6	86.8	73.0	90.2	74.8	62.4	68	22.0×10 ⁶

明了 CBAM 前置于双池化层协同作用。CBAM_7 的各类缺陷 Recall 值均高于其他模型,且在小目标缺陷上的表现最优、差值最小,是因为 CBAM 的双池化前置能强化小目标特征、精确定位,同时增强浅层和深层特征,使得 FSI 和 Hole 被有效捕捉;Recall 值较次的 CBAM_6 通过从浅层到深层多阶段增强特征,有效保留小目标细节、弥补两个小目标的特征差异,但由于多阶段叠加的参数与通道数,也导致其参数规模与计算量有大幅的增多;在未引入 CBAM 时,小目标特征捕捉提取并不充分,导致 FSI 与 Hole 缺陷的 Recall 差值显著,而在最大池化层后引入 CBAM 对小目标特征的压缩加剧,导致两者 Recall 差值加剧,CBAM_4/5 虽然通过残差块增强特征,但此时特征图分辨率已降低,小目标信息进一步丢失。综上,将 CBAM 模块放置在最大池化层和平均池化层之前是一种有效的结合方式,该方式能在特征关键下采样节点前增强关键特征,避免池化导致的细节丢失,能够在不显著增加模型复杂度的情况下,显著提高模型的 Accuracy 和 Precision_{p2},均衡提升小目标检测能力,实现了高效的注意力机制应用。

为探索 CBAM 的性能影响,在相同条件下构建了 4 种对比模型,在最大池化层和平均池化层之前分别引入 CAM、引入 SAM、引入 SE 注意力机制(SE attention machanis, SEAM)、双注意力机制(dual attention mechanism, DAM),验证结果如表 5 所示。由表 5 可知:引入 CBAM 的网络模型仅增加 0.3 M 参数,但其 Accracy、Recall、Precision_{p2} 值全面领先其他注意力机制,这说明 CBAM 能同时从通道与空间两个维度对特征进行加强处理,更有效地利用原始特征信息、捕捉小目标的特征,减少漏检;而同样是通道、空间双注意力计算的 DAM 则较为次之,是因为 DAM 的双注意力并行计算方式导致缺陷关键信息在特征优化过程中受到过多信息的干扰,随之也引入了更多的参数量,导致计算复杂度有所增加。SEAM 通过更复杂的通道交互作用使得其对缺陷目标的检测效果比 CAM 更优,但其计算参数量较多、计算速度更慢;SAM 仅关注空间位置,缺乏不同缺陷特征的表达能力。综上,引入 CBAM 能在保证网络模型推理速度与实时性的同时提高模型检测性能,验证了引入 CBAM 的双维度注意力协同优势。

表 5 引入不同注意力机制的验证结果

Table 5 The validation results of introducing different attention mechanisms

网络模型	Accuracy/%	Recall/%				Precision _{p2} /%	FPS	params
		SD	FSI	CW	Hole			
+CAM	85.4	83.5	65.2	85.7	68.4	58.9	70	21.9×10 ⁶
+SAM	83.9	82.8	50.3	84.0	60.5	57.1	68	21.9×10 ⁶
+SEAM	85.9	83.2	65.8	86.5	69.1	59.0	66	22.0×10 ⁶
+DAM	86.2	86.0	68.1	87.8	71.2	60.3	63	22.4×10 ⁶
+CBAM_7	87.6	86.8	73.0	90.2	74.8	62.4	68	22.0×10 ⁶

3) DSG-FPN 对模型性能的影响

为探索 DSG-FPN 的性能影响,构建了 3 种对比模

型,验证结果如表 6 所示。由表 6 可以发现:引入 DSG-FPN 的网络模型的 Accuracy、Recall 与 Precision_{p2} 均

表 6 引入 FPN、PANet、DSG-FPN 的验证结果

Table 6 The validation results of introducing FPN, PANet, DSG-FPN

网络模型	Accuracy/%	Recall/%				Precision _{p₂} /%	FPS	params
		SD	FSI	CW	Hole			
+CBAM_7+FPN	84. 9	82. 1	68. 7	84. 5	65. 3	63. 4	60	22. 2×10 ⁶
+CBAM_7+PANet	88. 3	85. 8	69. 9	81. 1	70. 4	65. 2	55	22. 9×10 ⁶
+CBAM_7+DSG-FPN	90. 1	88. 5	82. 0	90. 3	83. 2	68. 1	69	22. 5×10 ⁶

显著高于其他两个模型,其中路径聚合网络(path aggregation network, PANet)的 Recall 值有的甚至低于 FPN,但仍低于 DSG-FPN,这是因为 PANet 的双向传递会过度追求特征复用,突出表明了 DSG-FPN 结构能够自适应地融合多尺度特征信息,在处理特定缺陷类型时具有更强的适应性,能有效解决传统方法在特征融合过程中存在的关键信息丢失或冗余等问题。引入 DSG-FPN 的模型 FPS 高于 FPN 与 PANet,在计算效率上具有明显的优势,其参数量仅比 FPN 略高,但在性能得到显著提升,说明该结构能够自动识别并跳过对低权重特征的计算,在有效保留关键区域特征的同时,又能减少冗余计算操作。相比之下,传统 FPN 结构采用固定权重自顶向下去融合不同层级特征,浅层特征极易受到大量冗余信息的干扰,使得小目标极易被大尺度特征压制;PANet 结构增加了自底向上的路径,但过度特征复用会导致信息冗余,增加了计算复杂度、降低了模型性能;DSG-FPN 通过其动态自适应特性与稀疏性,有选择地激活关键特征通道,有效克服了这些固有缺陷,在保持计算效率的同时显著提升了检测精度。

4) ELU 激活函数对模型性能的影响

为探索 ELU 激活函数的性能影响,基于上述改进模型设计了 5 组对比实验,将残差卷积层中原本的 ReLU

函数分别替换为 ELU 函数、Sigmoid 函数、Tanh 函数、带泄露线性整流(leaky rectified linear unit, LeakyReLU)函数、Swish 函数^[20],最终的验证结果如表 7 和图 5 所示,可以发现:使用 ELU 激活函数能使改进模型的检测性能指标达到最佳,尤其是能更好地处理小目标特征,其损失值最低、收敛速度最快,在训练初期就能快速降低损失值,在训练后期的损失波动次数与幅度最少;原 ReLU 函数的损失(Loss)曲线在前中期极不稳定,部分“死亡神经元”无法更新权重导致模型训练前中期的收敛速度较缓;饱和非线性激活函数 Sigmoid 和 Tanh 仍存在梯度消失问题,其 Loss 初始值远高于其他函数,难以快速收敛,导致其在 50 次训练后 Loss 值仍较高,模型的 Accuracy、Precision_{p₂} 甚至低于 ReLU;LeakyReLU 函数虽然缓解了 ReLU 函数的“死神经元”问题,但当模型进入后期精细调整阶段时其较弱的梯度可能导致参数更新缓慢,所以后期其 Loss 值会高于原 ReLU 函数;采用 Swish 函数的模型检测性能提升较为优秀, Loss 曲线最接近 ELU 函数,但其复合运算方式也不仅增加了模型计算复杂度,也导致其训练中期 Loss 值远高于 ELU 函数。综上,选用 ELU 激活函数能在训练过程中更快地降低 Loss 值、有效减少梯度消失问题,还能更好地适应改进后的模型、有效增强模型的缺陷检测性能。

表 7 引入不同激活函数的验证结果

Table 7 The validation results of introducing different activation functions

模型的激活函数	Accuracy/%	Recall/%				Precision _{p₂} /%	FPS	params
		SD	FSI	CW	Hole			
ReLU	90. 1	88. 5	82. 0	90. 3	83. 2	68. 1	69	22. 5×10 ⁶
ELU	95. 5	98. 1	87. 7	98. 8	88. 3	82. 7	68	22. 3×10 ⁶
Sigmoid	87. 2	85. 3	82. 1	92. 1	79. 5	65. 8	72	22. 6×10 ⁶
Tanh	85. 8	82. 7	79. 3	89. 5	76. 8	62. 3	70	22. 4×10 ⁶
LeakyReLU	91. 2	94. 2	85. 9	94. 5	84. 7	74. 9	73	22. 1×10 ⁶
Swish	94. 6	96. 7	87. 3	98. 0	87. 1	79. 5	66	23. 0×10 ⁶

5) 消融实验

为验证改进方法的有效性,设置了 4 组消融实验,实验结果如表 8 所示。从表 8 可以看出,该消融实验验

证了各模块对模型性能的独立贡献于协同效应,CBAM 通过通道-空间双维度校准动态特征,使得网络模型聚焦于电熔焊接缺陷区域,改进后网络模型的检测效果




图 5 引入不同激活函数的损失值

Fig. 5 The loss value of introdcng different action fuction

得到显著的提升,小目标特征响应的增强效果最为明显,FSI 和 Hole 的 Recall 值分别提升至 73.0% 和 74.8%;DSG-FPN 通过动态门控筛选高价值路径、Detect Head 则通过独立分支优化不同尺度目标的分类与定位,仅增加 0.5×10^6 参数量,在特征融合方面表现出色,Precision_{p2} 提升了 13.3%;ELU 有效缓解了 ReLU 的“神经元坏死”问题,增强了对微弱缺陷特征的捕

捉能力,进一步提升网络模型缺陷检测效果。最终网络模型参数量 (22.3×10^6) 较中间阶段 (22.5×10^6) 得以减少,得益于 DSG-FPN 设计的动态稀疏门控模块与稀疏连接。相对于最初的 ResNet34 模型,DSG-ResNet34 模型在参数量控制与检测精度间有着更好的平衡能力,以极小的参数量代价实现特征的显著增强,突破了传统 FPN 的精度-速度瓶颈。

表 8 消融实验

Table 8 The ablation study

网络模型			Accuracy	Recall/%				Precision _{p2}	FPS	params
CBAM_7	DSG-FPN+Detect Head	ELU	/%	SD	FSI	CW	Hole	/%		
×	×	×	82.2	78.2	23.5	82.3	35.1	53.4	72	21.8×10 ⁶
√	×	×	87.6	86.8	73.0	90.2	74.8	62.4	68	22.0×10 ⁶
√	√	×	91.3	93.5	85.9	95.3	86.6	75.7	68	22.5×10 ⁶
√	√	√	95.5	98.1	87.7	98.8	88.3	82.7	68	22.3×10 ⁶

6) 模型性能对比

为了比较本文中的模型相较于其他网络模型的性能,在相同的实验条件下,对比评估了 DSG-ResNet34 模型与原 ResNet34 模型、YOLOv5 (you only look once, YOLO) 网络模型、MobileNetV3 (mobile network third version, MobileNet) 模型、区域卷积神经网络 (region-based convolutional neural networks, Faster R-CNN) 模型以及近年的轻量化检测网络模型的检测性能^[21-26],其结果如表 9 所示。由表 9 可以看出:DSG-ResNet34 模型的检测性能相对更为优越。YOLOv5s、YOLOv7-tiny 模型的主干网络替换为 ResNet34 后,其检测性能指标全面提升,小目标 Recall 值分化的改善尤为明显,但对小目标特征的敏感度仍然较低,说明跨阶段局部网络 (cross stage partial networks, CSPDarknet) 主干容易导致小目标特征在浅层网络中丢失,对小目标的语义信息捕捉弱,ResNet34 主干的残差连接比 CSPDarknet 的跨阶段连接

更稳定,能有效缓解浅层特征的消失;而采用高效层聚合网络 (efficient layer aggregation network, ELAN) 主干的 YOLO-NAS 模型尽管在网络结构中保留了更多小目标的高分辨率特征,小目标敏感度明显更强,但其神经网络架构搜索 (neural architecture search, NAS) 更偏向于中大目标,DSG-ResNet34 模型通过动态门控主动增强小目标通道,其小目标 Recall 值分化现象明显优于 YOLO-NAS 模型;PP-YOLOE 模型替换主干网络后网络通道数与层数减少、深层语义特征丢失,与 ResNet50-vd 主干相匹配的检测头更依赖于深层语义特征,均导致主干替换后 PP-YOLOE 模型的 Accuracy 和部分 Recall 增值小,而 DSG-ResNet34 模型的 DSG-FPN 通过动态权重分配,即使在 ResNet34 主干下,仍能高效融合多尺度特征,避免特征丢失;双阶段网络模型 Faster R-CNN 在替换主干网络前后的检测速度都低于 DSG-ResNet34 模型,这得益于 DSG-FPN 结构的稀疏门控机制减少了冗余计算;实时端到

表 9 不同模型的性能对比结果

Table 9 The performance comparison results of different models

网络模型	主干网络	Accuracy/%	Recall/%				Precision _{p2} /%	FPS	params
			SD	FSI	CW	Hole			
DSG-ResNet34	ResNet34	95.5	98.1	85.6	98.8	88.3	82.7	68	22.3×10 ⁶
ResNet34	ResNet34	82.2	78.2	23.5	82.3	35.1	53.4	72	21.8×10 ⁶
YOLOv5s	CSPDarknet53	66.5	72.3	7.2	70.2	26.2	38.2	62	7.2×10 ⁶
	ResNet34	72.1	78.5	12.1	72.9	31.7	45.3	58	21.9×10 ⁶
Faster R-CNN	VGG-16	84.3	81.2	1.9	84.5	32.1	32.7	25	136.9×10 ⁶
	ResNet34	85.8	83.6	8.5	86.2	36.2	33.8	18	141.0×10 ⁶
MobileNetV3	MobileNetV3	82.1	79.6	15.3	80.2	22.7	46.1	54	3.6×10 ⁶
YOLOv7-tiny	CSPDarknet-tiny	78.2	77.1	20.1	80.5	42.5	41.3	85	6.0×10 ⁶
	ResNet34	81.3	82.0	27.5	83.5	44.2	48.5	73	12.6×10 ⁶
YOLO-NAS	ELAN	86.7	87.2	20.2	90.7	43.6	58.9	58	18.4×10 ⁶
PP-YOLOE	ResNet50-vd	85.1	89.4	31.0	90.2	42.5	62.7	63	20.4×10 ⁶
	ResNet34	85.7	90.2	30.4	90.7	40.3	63.5	60	20.9×10 ⁶
NanoDet-Plus	ShuffleNetV2	79.5	85.5	23.1	88.2	45.2	55.4	92	1.1×10 ⁶
RT-DETR-R50	ResNet50	89.1	90.5	29.0	93.2	54.2	66.0	54	24.0×10 ⁶
	ResNet34	91.3	92.4	32.4	95.1	55.8	70.4	55	23.1×10 ⁶
EfficientDet	EfficientNet	81.5	76.5	12.5	79.8	32.7	49.6	47	6.6×10 ⁶

端目标检测(real-time detection transformer, RT-DETR)模型的 Accuracy 仅次于 DSG-ResNet34 模型,但其架构复杂度导致其 FPS 仅 55 帧、参数量高于 DSG-ResNet34 模型,而 DSG-ResNet34 模型通过轻量化注意力机制 CBAM 与稀疏连接,在参数量接近的情况下,能显著提升小目标 Recall 值;相对 MobileNetV3、YOLOv7-tiny、NanoDet-Plus、EfficientDet 等轻量化网络模型,DSG-ResNet34 模型在检测速度与参数量上不具备绝对的优势,但其在轻量化设计的同时仍保留了特征提取能力,小目标 Recall 值及分化现象明显优于这些轻量化模型。因此,相对于其他网络模型,DSG-ResNet34 模型在参数量仅增加 2.3% 的情况下,既能保持 68 fps 的实时性,又能实现 Accuracy 95.5% 和 Precision_{p2} 82.7% 的显著提升,在小目标 Hole、FSI 的 Recall 指标上表现突出,全面超越同主干网络的轻量化网络模型,为工业缺陷检测提供了高精度、高效率的解决方案。

3 结 论

针对 PE 燃气管道电熔焊接缺陷检测的工程痛点,提出了基于 DSG-ResNet34 模型的缺陷检测方法,该模型通过 CBAM 的通道-空间双维度协同增强关键特征的筛选、DSG-FPN 的动态稀疏门控模块优化跨尺度信息传

递、多检测头的深度可分离卷积与参数共享,有效实现了高检测准确率与实时性的平衡。在由 DE80 和 DE110 管径样本构成的数据集测试中,该模型对 SD、FSI、CW、Hole 缺陷展现出优异检测性能,Accuracy 达 95.5%、Precision_{p2} 为 85.6%,小目标 Recall 最低为 85.6%,在笔记本电脑端上能保持 68 fps 的推理速度,参数量仅为 22.3×10⁶,以检测速度和参数量的微小代价,相对于其他模型实现了检测性能的全面提升,不仅满足了 PE 管道电熔焊接缺陷快速、精准检测的需求,更为燃气管道巡检从人工目测向智能化检测转型提供了切实可行的技术方案。但受限于数据集范围,当前模型无法覆盖更多管径、材质、焊接工艺的管道,在未来的研究中将进一步扩充数据,同时紧密与相关检测部门合作,在实际管网检测场景中开展更大规模的实地验证,并针对边缘设备进行深度优化,持续提升模型在复杂工程环境下的鲁棒性与实用性。

参考文献

[1] 李夏喜,邢琳琳,田晓江,等. 城市聚乙烯燃气管道漏气案例统计与原因分析[J]. 装备环境工程, 2023, 20(4): 107-114.

LI X X, XING L L, TIAN X J, et al. Statistics and cause analysis of gas leakage in urban polyethylene gas pipelines[J]. Equipment and Environmental Engineer-

- ing, 2023, 20(4): 107-114.
- [2] 王胜辉, 汤陈怀, 杨惠谷, 等. HDPE 管电熔接头冷焊和过焊缺陷的检测与评价[J]. 金属热处理, 2019, 44(S1): 290-294.
- WANG SH H, TANG CH H, YANG H G, et al. Inspection and evaluation of cold/over welding defect in HDPE pipe electro-fusion joint[J]. Heat Treatment of Metals, 2019, 44(S1): 290-294.
- [3] 符中欣, 赵春, 张昆. 油田非金属管道无损检测技术现状及发展建议[J]. 石油机械, 2024, 52(10): 144-152.
- FU ZH X, ZHAO CH, ZHANG K. Current situation and development suggestions of non-destructive testing technology for non-metallic pipelines in oilfield[J]. China Petroleum Machinery, 2024, 52(10): 144-152.
- [4] 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 SH S, LI P, HUANG D W, et al. Image recognition and enhancement of X-ray detection of weld defects based on deep learning[J]. Non-destructive Testing, 2024, 46(6): 17-23.
- [5] 李亚舟, 曹江涛, 姬晓飞. 融合改进 Padim 建模和 ResNet 网络的喷涂质量检测算法[J]. 电子测量与仪器学报, 2022, 36(11): 91-97.
- LI Y ZH, CAO J T, JI X F. Spraying quality detection algorithm by fusing improved Padim modeling with ResNet network[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 91-97.
- [6] 袁嘉辉, 刘蕊, 梁虹, 等. 基于 SE-ResNet34 的红火蚁巢穴判别模型[J]. 电子测量技术, 2023, 46(23): 97-104.
- YUAN J H, LIU R, LIANG H, et al. Red fire ant nest classification model based on SE-ResNet34[J]. Electronic Measurement Technology, 2023, 46(23): 97-104.
- [7] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述[J]. 电子学报, 2020, 48(3): 590-601.
- LIU Y, LIU H Y, FAN J L, et al. A survey of research and application of small object detection based on deep learning[J]. Acta Electronica Sinica, 2020, 48(3): 590-601.
- [8] YIN L F, GE W. Mobileception-ResNet for transient stability prediction of novel power systems[J]. Energy, 2024, 309: 133163.
- [9] 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.
- [10] CHERNOV A V, SAVVAS I K, ALEXANDROV A A, et al. Integrated video and acoustic emission data fusion for intelligent decision making in material surface inspection system[J]. Sensors, 2022, 22(21): 8554.
- [11] 刘述喜, 刘科, 黄思源, 等. 基于多源融合图与 SE-BiGRU-ResNet 模型的 MMC 子模块开路故障诊断[J]. 仪器仪表学报, 2024, 45(11): 322-337.
- LIU SH X, LIU K, HUANG S Y, et al. Open-circuit fault diagnosis of MMC sub-module based on multi-source fusion graph and SE-BiGRU-ResNet model[J]. Chinese Journal of Scientific Instrument, 2024, 45(11): 322-337.
- [12] MIRZA A F, MANSOOR M, USMAN M, et al. A comprehensive approach for PV wind forecasting by using a hyperparameter tuned GCVCNN-MRNN deep learning model[J]. Energy, 2023, 283: 129189.
- [13] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Computer Vision-ECCV 2018, 2018: 3-19.
- [14] GUO J Y, WAN J L, YANG Y, et al. A deep feature learning method for remaining useful life prediction of drilling pumps[J]. Energy, 2023, 282: 128442.
- [15] 童小钟, 魏俊宇, 苏绍璟, 等. 融合注意力和多尺度特征的典型水面小目标检测[J]. 仪器仪表学报, 2023, 44(1): 212-222.
- TONG X ZH, WEI J Y, SU SH J, et al. Typical small target detection on water surfaces fusing attention and multi-scale features[J]. Chinese Journal of Scientific Instrument, 2023, 44(1): 212-222.
- [16] 郭启帆, 刘磊, 张城, 等. 基于特征金字塔的多尺度特征融合网络[J]. 工程数学学报, 2020, 37(5): 521-530.
- GUO Q F, LIU L, ZHANG CH, et al. Multi-scale feature fusion network based on feature pyramid[J]. Chinese Journal of Engineering Mathematics, 2020, 37(5): 521-530.
- [17] ZHU M J, HAN K, YU CH B, et al. Dynamic feature pyramid networks for object detection[J]. ArXiv preprint arXiv:2012.00779, 2020.
- [18] 赵婷婷, 丁翹楚, 马冲, 等. 基于探针稀疏注意力机制的门控 Transformer 模型[J]. 天津科技大学学报, 2024, 39(3): 56-63.
- ZHAO T T, DING Q CH, MA CH, et al. Gated transformer based on prob-sparse attention[J]. Journal of Tianjin University of Science & Technology, 2024, 39(3): 56-63.

[19] FUHG J N, BOUKLAS N, JONES R E. Learning hyperelastic anisotropy from data via a tensor basis neural network[J]. Journal of the Mechanics and Physics of Solids, 2022, 168: 105022.

[20] 张猛, 尹丽菊, 周辉, 等. 基于 SimAM-Ada YOLOv5 的太阳能电池表面缺陷检测[J]. 电子测量技术, 2023, 46(22): 17-25.

ZHANG M, YIN L J, ZHOU H, et al. Surface defect detection of solar cells based on SimAM-Ada YOLOv5[J]. Electronic Measurement Technology, 2023, 46(22): 17-25.

[21] LI J H, LI CH L, LUO X W, et al. Real-time pineapple detection for agricultural robot via lightweight YOLOv7-tiny model[J]. Procedia Computer Science, 2023, 226: 92-98.

[22] SLIMANI H, EL MHAMDI J, JILBAB A. Advancing disease identification in fava bean crops: A novel deep learning solution integrating YOLO-NAS for precise rust[J]. Journal of Intelligent & Fuzzy Systems, 2024, 46(2): 3475-3489.

[23] QU Y, WAN B Y, WANG CH, et al. Optimization algorithm for steel surface defect detection based on PP-YOLOe[J]. Electronics, 2023, 12(19): 4161.

[24] 刘方坚, 李媛. 基于视觉显著性的 SAR 遥感图像 NanoDet 舰船检测方法[J]. 雷达学报, 2021, 10(6): 885-894.

LIU F J, LI Y. SAR remote sensing image ship detection method NanoDet based on visual saliency[J]. Journal of Radars, 2021, 10(6): 885-894.

[25] GUEMAS E, ROUTIER B, GHELFENSTEIN-FERREIRA T, et al. Automatic patient-level recognition of four Plasmodium species on thin blood smear by a real-time detection transformer (RT-DETR) object detection algorithm: A proof-of-concept and evaluation[J]. Microbiology Spectrum, 2024, 12(2): e0144023.

[26] 包壮壮, 赵学军. 基于 EfficientDet 的无预训练 SAR 图像船舶检测器[J]. 北京航空航天大学学报, 2021, 47(8): 1664-1672.

BAO ZH ZH, ZHAO X J. Ship detector in SAR images based on EfficientDet without pre-training[J]. Journal of

Beijing University of Aeronautics and Astronautics, 2021, 47(8): 1664-1672.

作者简介




凌晓(通信作者),2000 年于华北水利水电大学获得学士学位,2013 年于兰州理工大学获得博士学位,现为兰州理工大学副教授,主要研究方向为油气储运设备安全保障技术。
E-mail:lingxiao_lut@163.com。

Ling Xiao (Corresponding author) received his B. Sc. degree from North China University of Water Resources and Electric Power in 2000 and Ph. D. degree from Lanzhou University of Technology in 2013. Currently, he is an associate professor at Lanzhou University of Technology. His main research interests include the safety assurance technology of oil and gas storage and transportation equipment.



刘露,2023 年于重庆科技大学获得学士学位,现为兰州理工大学石油化工学院硕士研究生,主要研究方向为油气储运设备智能检测技术。
E-mail:1056076268@qq.com

Liu Lu received her B. Sc. degree from Chongqing University of Science and Technology in 2023. She is currently a master student in the School of Petrochemical Engineering at Lanzhou University of Technology. Her main research focus on intelligent detection technology for oil and gas storage and transportation equipment.



孙宝财,2005 年于东北石油大学获得学士学位,分别在 2011 年、2020 年于兰州理工大学获得硕士学位、博士学位,现为甘肃省特种设备检验检测研究院副院长、正高级工程师,主要研究方向为特种设备检验检测。

E-mail:463299457@qq.com

Sun Baocai received his B. Sc. degree from Northeast Petroleum University in 2005, M. Sc. and Ph. D. degrees from Lanzhou University of Technology in 2011 and 2020, currently. Now he is the vice dean of Gansu Province Special Equipment Inspection and Testing Institute and a senior engineer. His main research interests include the inspection and testing of special equipment.