

一种基于卷积神经网络的轻量级焊缝缺陷识别算法

徐飞虎, 李丹, 赵文杰

(安徽工业大学电气与信息工程学院, 安徽马鞍山 243032)

摘要: 针对传统焊缝缺陷检测方法在处理大量工业数据时存在识别效率和准确率低的问题, 提出一种基于卷积神经网络的轻量级焊缝缺陷识别算法。该算法在原 MobileNetV3 基础上引入 fire 模块以减小参数量, 并结合通道注意力 (ECA) 模块增强特征通道学习能力, 从而优化计算资源分配并提升特征提取性能。为验证所提算法的有效性, 将其与常见分类模型算法在焊缝缺陷测试数据集上进行对比实验。结果表明: 相比于其他分类模型算法, 所提算法在 fire 模块的轻量化设计和 ECA 模块的特征增强双重作用下, 对工业场景中常见的凹陷、孔洞、毛刺等缺陷的平均识别准确率达 98.50%, 较原算法显著提升。同时, 改进的 MobileNetV3 算法在保持较高识别准确率的情况下, 模型参数量和浮点运算量显著降低, 使其适合部署在计算资源有限的工业检测设备上。本文研究为智能制造领域的实时质量检测提供了切实可行的解决方案。

关键词: 焊缝缺陷; 卷积神经网络; MobileNetV3; fire 模块; ECA 模块; 轻量级; 智能识别

中图分类号: TP 391.14 **文献标志码:** A **doi:** 10.12415/j.issn.1671-7872.23178



A Lightweight Weld Defect Identification Algorithm Based on Convolutional Neural Network

XU Feihu, LI Dan, ZHAO Wenjie

(School of Electrical & Information Engineering, Anhui University of Technology, Maanshan 243032, China)

Abstract: To address the issues of low recognition efficiency and accuracy in traditional weld defect detection methods when processing large-scale industrial data, a lightweight weld defect recognition algorithm based on convolutional neural networks was proposed. The fire module was introduced into the original MobileNetV3 to reduce parameter size, while the ECA (efficient channel attention) module was incorporated to enhance feature channel learning capability, thereby optimizing computational resource allocation and improving feature extraction performance. To validate the effectiveness of the proposed algorithm, comparative experiments were conducted with common classification models on a weld defect test dataset. The results demonstrate that, compared to other classification models, an average recognition accuracy of 98.50% is achieved by the proposed algorithm for common industrial defects such as dents, pores, and burrs, with the original algorithm being significantly outperformed, thanks to the combined effects of the fire module's lightweight design and the ECA module's feature enhancement. Moreover, both parameter size and floating-point operations are significantly reduced by the improved MobileNetV3 algorithm while high recognition accuracy is maintained, making it particularly suitable for deployment on industrial

收稿日期: 2024-06-08

基金项目: 安徽省自然科学基金项目 (2108085MF225)

作者简介: 徐飞虎 (1997—), 男, 安徽亳州人, 硕士生, 主要研究方向为机器人与人工智能。

通信作者: 李丹 (1976—), 女, 山东文登人, 博士, 教授, 主要研究方向为图像处理与自主导航。

引文格式: 徐飞虎, 李丹, 赵文杰. 一种基于卷积神经网络的轻量级焊缝缺陷识别算法 [J]. 安徽工业大学学报(自然科学版), 2025, 42(3):298-305.

inspection devices with limited computational resources. A practical solution is thus provided for real-time quality inspection in the field of intelligent manufacturing.

Keywords: weld seam defect; convolutional neural networks; MobileNetV3; fire module; ECA module; lightweight; intelligent identify

焊接工艺作为一种通过加热、高温或高压实现金属和热塑性材料接合的关键制造技术,在现代工业的铁路建设、桥梁工程、汽车制造、航空航天^[1]等核心领域具有不可替代的应用价值。随着新型复合材料和先进制造工艺的不断涌现,焊接技术在工业制造业中的战略地位日益提升。然而受复杂工况环境限制、人为操作误差以及工艺参数波动等多重因素影响,焊接过程中不可避免地产生微观裂纹、内部气孔、熔渣夹杂以及宏观裂缝等典型焊接缺陷^[2]。这些缺陷不仅显著降低产品力学性能和使用寿命,严重时更可能导致产品突发性脆性断裂,甚至造成重大安全事故,给国民经济带来难以估量的损失。因此,研究智能焊缝缺陷识别方法对提升工业产品质量和生产效率具有重要意义。

目前智能缺陷识别方法主要分为传统图像处理方法和深度学习方^[3]。传统方法是基于数字图像处理和特征工程实现缺陷分类^[4],其流程包括缺陷分割、特征提取、特征选择、缺陷识别等关键环节。在焊缝缺陷分割环节^[5],主要采用改进的 Otsu^[6]等算法提取缺陷区域,如边缘特征、区域特征、纹理特征^[7]等;特征选择环节旨在消除冗余特征和噪声干扰,从而保留有用特征;缺陷识别环节作为核心技术,常采用多源信息融合决策^[8]、贝叶斯^[9]、支持向量机、模糊逻辑等方法。传统方法如 Hough 变换^[10]、SIFT 特征点提取^[11]主要通过提取固定环境下的特征点和几何关系进行缺陷识别,但其泛化能力差,对视觉设备和环境条件要求苛刻,任何环境变化都需重新建模和校正。近年来,随着深度学习技术的发展,特别是卷积神经网络(convolutional neural network, CNN)的兴起,为焊缝缺陷识别提供了新思路。CNN 具有强大的端对端自动特征提取能力^[12-13],可直接处理原始图像^[14-16],有效解决了传统方法特征提取困难的问题。杨志超等^[17]提出的 CNN 算法直接将预处理后的焊缝图像作为输入,将焊接缺陷种类作为输出,有效避免了因人为识别主观经验对检测造成的不良影响;Khumaidi 等^[18]采用 CNN 对网络摄像头获取的图像进行焊缝缺陷分类,精度达到 95.83%,

但对样本数量要求较高。随着残差连接(skip connection, SC)和批量归一化(batch normalization, BN)^[19]等关键技术的应用,深层网络的训练变得更加可行。李真等^[20]提出的深度学习方法在特定场景下实现了 96% 的分类精度,展现了良好的工程应用价值。

当前主流的深度学习分类网络模型包括 VGG-16^[21]、PReLU-nets^[22]及 ResNet^[23]等经典架构,这些模型识别准确率较高,但由于其庞大的参数量和复杂的计算结构,导致计算资源消耗巨大,难以在资源受限的工业现场设备中实现高效部署。针对焊接工程应用中硬件资源有限的特点,构建焊缝缺陷识别网络模型时须在保证较高识别精度的同时,重点优化模型的计算效率和参数量。在此背景下,MobileNet 系列轻量网络模型^[24]凭借其出色的精度-效率平衡特性脱颖而出,该模型通过深度可分离卷积等结构,在保持较高识别准确度的同时显著减少了模型参数量和计算复杂度,特别适合部署在工业现场的移动端设备。最新发展的 MobileNetV3 版本通过引入神经网络架构搜索技术进一步优化了网络结构。基于上述分析,在对 MobileNetV3 网络架构的基础上进行改进,通过引入 fire 模块的压缩-扩展机制和通道注意力机制的双重优化策略,构建 1 个新型的轻量化 CNN 模型,以期在保持轻量化的同时进一步提升缺陷识别准确率,为工业现场应用提供了更优的解决方案。

1 焊缝缺陷识别算法的改进

图 1 为 MobileNetV3 的整体网络架构,其核心组件是由多个 bneck 模块构成的深度可分离卷积结构。MobileNetV3 提供 large 和 small 两种版本变体,两者在 bneck 模块的基本结构上设计一致,区别主要在于 bneck 模块的数目不同,large 版本有 15 个 bneck 模块,而 small 版本只有 11 个 bneck 模块。在图 1 中的网络输入层中,3×224×224 表示输入 224 像素×224 像素尺寸的彩色图像,3 表示彩色图像的 3 个颜色通道。

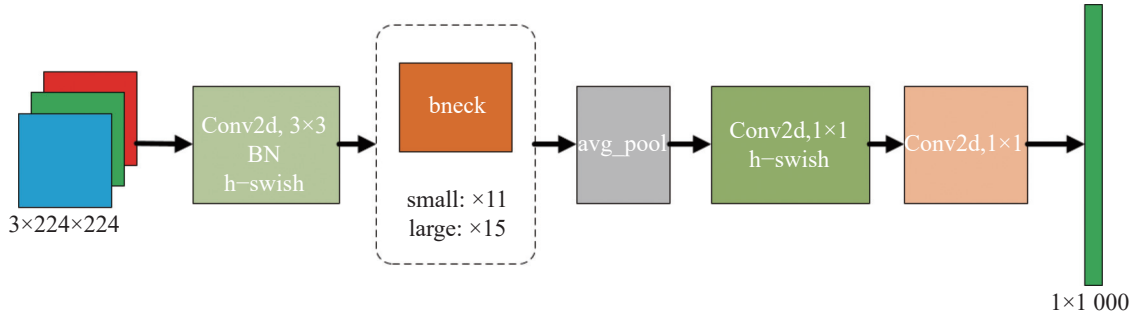


图1 MobileNetV3 网络模型结构

Fig. 1 Model structure of MobileNetV3 network

MobileNetV3 网络模型继承了 MobileNetV2 的深度可分离卷积和倒置残差模块结构,且在保证模型轻量化的同时对 bneck 模块进行改进。如图 1 所示,输入图像在经过多层 bneck 模块前,经过网络模型头部的 3×3 卷积层 (Conv2d, 3×3)、BN 层和 h-swish 激活函数处理。其中:BN 层通过规范化各层输入分布,显著提升训练过程的稳定性;经过优化的 h-swish 激活函数不仅保留了原 swish 激活函数的非线性特点,还大幅提升了计算速度,有利于后续模型的量化部署。在网络尾部处理环节,经多层 bneck 模块的特征图仅需经过全局平均池化层 (avg_pool)、2 个 1×1 卷积层 (Conv2d, 1×1) 和 h-swish 激活函数,这种设计极大简化了从特征图到最终 1×1 000 维输出向量的转换过程。相比 V1 和 V2 版本,MobileNetV3 模型虽然更加轻量化,但其参数量仍大于 SqueezeNet 模型。为此,本文引入 SqueezeNet 的 fire 模块进一步减少参数量;同时加入通道注意力 (efficient channel attention, ECA) 模块,以保持焊缝缺陷识别精度。

1.1 fire 模块的引入

SqueezeNet 作为一种典型的轻量 CNN 网络模型,其核心创新在于采用 fire 模块的轻量化设计策略显著降低网络参数量。为优化 MobileNetV3 模型体积,本文引入 SqueezeNet 的 fire 模块设计理念,该模块采用双分支结构设计,包含挤压层和扩展层:挤压层通过 1×1 卷积降低特征图维度;扩展层则通过将部分 3×3 卷积替换成 1×1 卷积实现输入通道数精简,从而有效减少模型参数^[25]。如图 2 所示,fire 模块的处理流程为:首先通过挤压层 1×1 卷积对输入特征图进行降维处理,随后在扩展层中并行执行 1×1 和 3×3 两种卷积运算,最后通过特征拼接 (Concat) 操作融合两种尺度的特征信息。为增强模型的非线性特征表达能力,在每个卷积层后均使用 Relu 激活函数进行特征变换,这种设计在保证模型轻量化的同时,仍能维持较强的特征表征能力。




图2 fire 模块结构

Fig. 2 Structure of fire module

1.2 ECA 模块的引入

通道注意力 (ECA) 机制作为一种高效的注意力模块,通过特征通道的自适应加权为不同通道分配差异化注意力权重,在提升深度 CNN 性能的同时保持轻量化设计优势。为优化 MobileNetV3 的识别精度,本文引入如图 3 所示的 ECA 模块。图中 H , W 分别表示特征图的宽度与高度。ECA 模块通过全局平均池化 (global max pooling, GAP) 捕获空间特征后,采用 1×1 卷积替代传统全连接层实现跨通道信息交互,在避免维度缩减信息损失的同时以极低参数量建模通道依赖关系。针对传统方法中手动调整卷积核效率低下的问题,ECA 提出自适应核大小机制,基于通道数 C 通过式 (1) 的非线性映射自动确定最优奇数卷积核大小 K ,实现通道数与卷积核尺寸的智能匹配。

$$K = \left\lceil \frac{\log_2 C}{\gamma} + \frac{b}{\gamma} \right\rceil \quad (1)$$

为得到图3所示的自适应卷积核大小,通常令 $\gamma=2, b=1$ 。




图3 ECA 模块结构

Fig. 3 Structure of ECA module

从图3可看出 ECA 模块的工作原理:输入特征图(维度为 $H \times W \times C$)经全局平均池化层压缩为 $1 \times 1 \times C$ 的通道描述向量后,系统首先基于通道维度 C 自动计算最优一维卷积核尺寸 K ,随后执行跨通

道卷积交互生成初始注意力权重,最终通过 Sigmoid 归一化与逐通道相乘操作输出优化后的特征图,完整实现从通道特征提取到自适应加权的注意力机制计算流程。

改进后的网络模型结构如图4。在原 MobileNetV3 模型的第一个 3×3 卷积层后、bneck 模块前插入 fire 模块,利用其压缩-扩展机制减少参数量;同时在 bneck 模块后、全局平均池化层 (avg_pool) 前插入 ECA 模块,通过自适应通道注意力机制动态调整特征通道权重,实现计算资源的合理分配。这种双模块协同优化的设计策略,在仅微量增加参数量的情况下,显著提升网络对焊缝缺陷特征的识别能力。

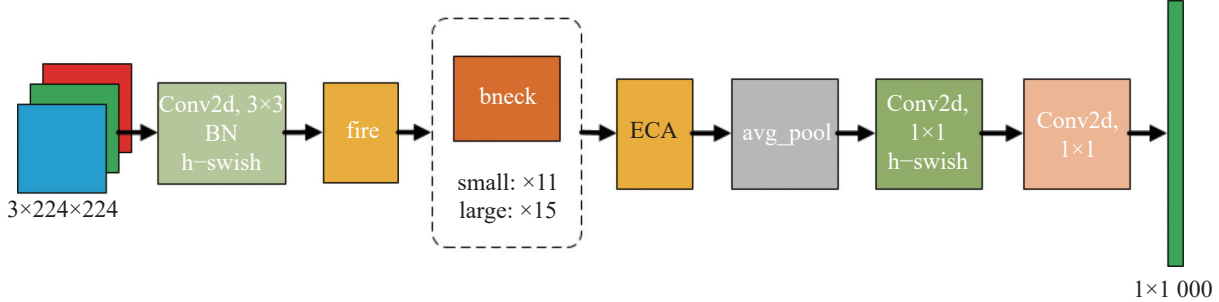


图4 改进后的网络模型结构示意图

Fig. 4 Structure diagram of the improved network model

2 实验与结果分析

为验证改进 MobileNetV3 算法的性能优势,对经数据扩充处理的焊缝缺陷数据集进行系列仿真实验。将数据集划分为训练集和验证集,训练集用于优化网络参数,验证集则用于评估模型泛化能力。

2.1 焊缝缺陷数据集的扩充处理

文中采用的焊缝缺陷数据集来源于辽宁师范大学计算机应用研究所,其是基于线结构光扫描技术构建的专业数据集。该数据集通过激光传感器和三角测距原理采集^[26],包含工业生产中常见的四类典型缺陷:凹陷、孔洞、毛刺和无缺陷样本,如图5。由于焊缝缺陷数据在自然场景中较难获取,此类经过专业设备采集的结构化数据集为深度学习模型训练提供了重要基础。





图5 焊缝线结构光示例图

Fig. 5 Example diagram of weld seam structure

由图5可看出四类焊缝缺陷的视觉特征差异,其中毛刺缺陷因其表面更凹凸不平的物理特性,在激光扫描时会产生更强的漫反射,表现为图像中更明显的高亮区域和纹理特征,这种独特的光学特性使其在后续识别中具有更高的可区分度。针对原始数据集中样本数量较少且类别不均衡的问题,文中采用保持缺陷本质特征的数据增强策略,即采用亮度增强、对比度增强和水平翻转等操作进行扩充,最终构建包含 2 000 张图像的平衡数据集,每类图像 500 张。为确保模型评估的可靠性,数据集按照 8:1:1 的比例划分为训练集、验证集和测试集。训练阶段,采用 Mosaic 数据增强技术和自适应缩放进



(a) 凹陷

(b) 孔洞

行预处理,以增加样本多样性,避免图像形变导致的特征失真。

2.2 评价指标的选取

采用多维度指标体系评估算法性能。分类性能方面,选用精确度(J)、准确率(A)、召回率(R)、 F_1 分数($F_{1-score}$)4个指标,这些指标通过混淆矩阵(如表1)计算获得。其中将预测结果划分为真阳性(T_p)、真阴性(T_N)、假阳性(F_p)和假阴性(F_N)四类: T_p 反映正类样本正确识别率, T_N 表示负类样本正确排除率, F_p 表示负类误报率, F_N 则表征正类漏检率。轻量化性能方面,选用浮点运算量(FLOPs)和模型参数量(params)2个核心指标,其中FLOPs通过开源工具thop计算,评估模型的计算复杂度,params则直接衡量模型存储大小。

表1 混淆矩阵

Tab.1 Confusion matrix

真实分类	预测分类	
	正类	负类
正类	T_p	F_N
负类	F_p	T_N

精确度(J)表示预测为正类的样本中真实正类样本的占比,反映预测结果的可靠性;准确率(A)表示预测正确样本的占比,衡量整体分类正确率;召回率(R)表示正类的样本中被正确识别为正类样本的占比; $F_{1-score}$ 作为精确度和召回率的调和平均数,能更全面评估分类器在不平衡数据集上的表现。4个指标的计算公式如下:

$$J = \frac{T_p}{T_p + F_p} \quad (2)$$

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (3)$$

$$R = \frac{T_p}{T_p + F_N} \quad (4)$$

$$F_{1-score} = 2 \frac{JR}{J+R} \quad (5)$$

式中: T_p+T_N 表示被正确预测为正类和负类的总和,通常准确率越高,模型的分类效果就越好。

2.3 实验过程

本实验在配备 Intel Xeon Olatinum 8225C CPU、43 GB 内存和 NVIDIA RTX2080Ti GPU(11GB 显存)的云服务器上进行。在 CUDA 环境下,使用 Pytorch 深度学习框架 PyTorch1.11.0,基于 Python3.8 搭建焊缝缺陷识别网络。网络的输入图像大小均为 224×224 ,样本批量大小(batch_size)为 8,迭代次

数为 200,学习率为 0.002,对处理好的数据集进行训练。网络训练时,使用自适应矩估计(adaptive moment estimation, Adam)算法动态调节参数的学习率,使参数变化范围不会太大,参数训练更稳定。

2.3.1 消融实验

为系统评估改进算法中不同策略对缺陷识别性能的影响,设计四组实验:第一组采用原 MobileNetV3 模型作为基线网络(M_Net0);第二组在基线网络中引入 fire 模块(M_Net1);第三组在基线网络中集成 ECA 注意力机制(M_Net2);第四组同时融合 fire 模块和 ECA 注意力机制的改进模型,即本文所提模型(M_Net3)。四组实验在相同测试集上的性能指标对比结果如表2。

表2 4种算法在相同测试集上的性能指标对比结果

Tab.2 The comparative results of performance metrics for the four algorithms on the same test set

算法	参数量/MB	浮点运算量/MB	准确率/%
M_Net0	4.20	232.96	97.00
M_Net1	3.53	200.36	98.50
M_Net2	4.20	233.01	98.01
M_Net3	3.53	213.43	98.53

从表2可看出:MobileNetV3中引入ECA模块后,虽然浮点运算量略有增加,但测试集准确率提升了1.0%;而采用fire模块改进后,模型参数量和浮点运算量均分别显著降低了16.0%和14.0%,同时准确率也获得1.5%的提高;最终改进算法M_Net3通过fire模块和ECA模块的协同优化,在模型压缩(参数量减少16.0%、计算量降低14.0%)和性能提升(准确率提高2.5%)方面实现全面突破,相较原始M_Net0展现出显著优势。

2.3.2 性能对比实验

为验证改进算法性能的优越性,将M_Net3算法与M_Net0、ResNet、Inceptionv4和VGG等4种常见分类算法进行对比实验,5种算法在焊缝缺陷数据集上进行200次迭代训练后的预测结果如表3。从表3可看出:相较于ResNet和Inceptionv4算法,改进的MobileNetv3算法在模型参数量和浮点运算量上优势较大,分别为3.53,213.43 MB,远低于ResNet和Inceptionv4算法,同时仍保持较高的准确率和精确度;相较于SqueezeNet算法,改进的MobileNetv3算法虽然在模型参数量上略有不足,但在其他性能指标上优势显著:不仅浮点运算量(FLOPs)更低,其精确率和准确率也均优于SqueezeNet算法。

表 3 四类焊缝缺陷基于 5 种算法的训练量化指标

Tab. 3 Comparative quantitative metrics of five algorithms for four weld defect types

算法	精确度/%	准确率/%	召回率/%	F_1 分数	模型参数量/MB	浮点运算量/MB
M_Net0	97.03	97.00	97.00	97.00	4.20	232.96
M_Net3	98.53	98.50	98.50	98.50	3.53	213.43
ResNet	96.56	96.50	96.50	96.51	25.31	4 131.69
Inceptionv4	98.51	98.50	98.50	98.50	41.14	6 153.58
SqueezeNet	95.01	95.00	95.00	95.00	0.74	732.92

综上可看出: 改进的 MobileNetv3 算法在保持较高识别精确度和准确率的同时, 显著降低了模型参数量, 展现出优异的轻量化部署特性。

2.4 缺陷识别结果的可视化分析

采用改进 MobileNetv3 算法在四类焊缝缺陷数据集 (毛刺 MC、凹陷 OX、孔洞 QC 及无缺陷 WD) 上进行训练后, 测试集评估结果显示: 如图 6 混淆矩阵所示, 各类缺陷预测结果均集中分布于对角线区域, 算法能够准确识别各类缺陷特征, 验证了改进算法在焊缝缺陷识别任务中的有效性与工程适用性。

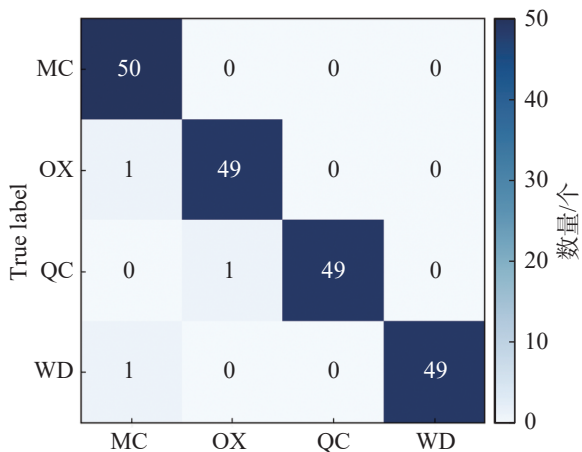


图 6 测试集混淆矩阵

Fig. 6 Test-set confusion matrix

基于混淆矩阵的量化分析 (表 4) 表明, 改进 MobileNetv3 算法在焊缝缺陷识别任务中展现出优异的性能表现: 测试集整体平均精确度达 98.50%, 其中毛刺 (MC) 凭借其显著的表现特征实现 100.00% 的识别精确度, 高于其他三类焊缝缺陷 (凹陷 OX、孔洞 QC 及无缺陷 WD) 的识别精确度 (98.00%); 同时四类缺陷的平均召回率维持在 98.55% 以上, 充分证明算法对不同形态焊缝缺陷具有稳定的鉴别能力。

表 4 四类焊缝缺陷基于混淆矩阵的量化分析结果

Tab. 4 Quantitative analysis of four weld defect types based on confusion matrix

缺陷	图像/张	精确度/%	召回率/%
毛刺 (MC)	50	100.00	96.20
凹陷 (OX)	50	98.00	98.00
孔洞 (QC)	50	98.00	100.00
无缺陷 (WD)	50	98.00	100.00

3 结论

针对传统焊缝缺陷检测方法在处理大量焊缝缺陷数据时存在的焊缝缺陷识别效率低和准确率不足等问题, 提出一种基于卷积神经网络的焊缝缺陷识别算法。通过引入 fire 模块和 ECA 模块对 MobileNet 网络进行双重优化改进, 构建具有自适应特征选择能力的增强型网络架构。在包含四类典型焊缝缺陷 (毛刺、凹陷、孔洞及无缺陷) 的专业数据集上的仿真实验表明: 改进算法展现出出色的识别性能, 平均识别准确率达到 98.50%, 较基线模型有较大提升; 在计算效率方面, 通过架构优化使模型参数量较原始算法降低 16.0%, 同时浮点运算量等关键指标均获得改善。本文研究为工业现场实时检测提供了可行的轻量化解决方案, 但仍有可以进一步完善的方面, 如将训练完成的网络模型部署至工业嵌入式设备, 通过硬件适配和量化压缩进一步优化推理效率; 采集更多实际工业场景下的焊缝缺陷样本, 构建更具代表性的扩展数据集, 以持续提升算法在复杂工况下的泛化能力和识别精度。

参考文献:

[1] 袁炜, 胡梦伟, 王晓, 等. 钢轨焊接接头电感应加热数值

- 模拟及工艺[J]. 焊接学报, 2024, 45(12):79-89.
- YUAN W, HU M W, WANG X, et al. Numerical simulation and technology of electric induction heating for welded joints of rail[J]. Transactions of the China Welding Institution, 2024, 45(12):79-89.
- [2] MADHVACHARYULA A S, PAVAN A V S, GORTHI S, et al. In situ detection of welding defects: a review[J]. *Welding in the World*, 2022, 66(4):611-628.
- [3] 邱根, 王锂, 白利兵. 基于生成对抗网络数据扩充的缺陷识别方法[J]. 电子测量与仪器学报, 2021, 35(2): 212-220.
- QIU G, WANG L, BAI L B. GANs-based synthetic data augmentation for defects recognition[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 212-220.
- [4] 彭惠奎, 陈芊一, 韩露, 等. 基于深度学习的燃气PE管道焊缝缺陷检测[J]. 半导体光电, 2023, 44(6):942-949.
- PENG H K, CHEN Q Y, HAN L, et al. Gas PE pipeline weld defect detection based on deep learning[J]. Semiconductor Optoelectronics, 2023, 44(6):942-949.
- [5] AJMI C, ZAPATA J, ELFERCHICHI S, et al. Advanced faster-RCNN model for automated recognition and detection of weld defects on limited X ray image dataset[J]. Journal of Nondestructive Evaluation, 2023, 43(1):14.
- [6] MALARVEL M, SETHUMADHAVAN G, BHAGI P C R, et al. An improved version of Otsu's method for segmentation of weld defects on X radiography images[J]. *Optik*, 2017, 142:109-118.
- [7] JIANG H Q, ZHAO Y L, GAO J M, et al. Weld defect classification based on texture features and principal component analysis[J]. *Insight- Non-Destructive Testing and Condition Monitoring*, 2016, 58(4):194-200.
- [8] JIANG H Q, WANG R X, GAO Z Y, et al. Classification of weld defects based on the analytical hierarchy process and Dempster-Shafer evidence theory[J]. *Journal of Intelligent Manufacturing*, 2019, 30(4):2013-2024.
- [9] GOUMEIDANE A B, BOUZAIENI A, NACEREDDINE N, et al. Bayesian networks-based defects classes discrimination in weld radiographic images[M]//Computer Analysis of Images and Patterns. Cham: Springer International Publishing, 2015:554-565.
- [10] 周红明, 卢建飞, 吕建森, 等. 基于多尺度纹理特征的焊缝缺陷类型识别方法研究[J]. 机电技术, 2018, 41(3): 14-16.
- ZHOU H M, LU J F, LYU J S, et al. Research on weld defect type identification method based on multi-scale texture features[J]. Mechanical & Electrical Technology, 2018, 41(3):14-16.
- [11] SUJIN J S, SOPHIA S. High-performance image forgery detection via adaptive SIFT feature extraction for low-contrast or small or smooth copy-move region images[J]. *Soft Computing*, 2024, 28(1):437-445.
- [12] 米春风, 卢琨, 汪文艳, 等. 基于机器视觉的带钢表面缺陷检测研究进展[J]. 安徽工业大学学报(自然科学版), 2022, 39(2):180-188.
- MI C F, LU K, WANG W Y, et al. Research progress on hot-rolled strip surface defect detection based on machine vision[J]. Journal of Anhui University of Technology (Natural Science), 2022, 39(2):180-188.
- [13] 陈艳菲, 彭洪晟, 王俊涛, 等. 基于 MobileNet 卷积神经网络的焊缝缺陷识别[J]. 自动化与仪表, 2022, 37(1): 49-54.
- CHEN Y F, PENG H S, WANG J T, et al. Detection and recognition of weld defects based on lightweight convolutional neural network[J]. Automation & Instrumentation, 2022, 37(1):49-54.
- [14] 谷静, 谢泽群, 张心雨. 基于改进深度学习模型的焊缝缺陷检测算法[J]. 宇航计测技术, 2020, 40(3):75-79, 87.
- GU J, XIE Z Q, ZHANG X Y. Weld defect detection based on improved deep learning[J]. *Journal of Astronautic Metrology and Measurement*, 2020, 40(3):75-79, 87.
- [15] SHAO W J, LIU X F, WU Z J. A robust weld seam detection method based on particle filter for laser welding by using a passive vision sensor[J]. The International Journal of Advanced Manufacturing Technology, 2019, 104(5):2971-2980.
- [16] RAJPUT S S, CHOI Y. Handwritten digit recognition using convolution neural networks[C]//2022 IEEE 12th Annual Computing and Communication Workshop and Conference. Las Vegas, NV, USA. IEEE, 2022:1101-1106.
- [17] 杨志超, 周强, 胡侃, 等. 基于卷积神经网络的焊接缺陷识别技术及应用[J]. 武汉理工大学学报(信息与管理工程版), 2019, 41(1):17-21.
- YANG Z C, ZHOU Q, HU K, et al. Welding defect recognition technology based on convolutional neural network and application[J]. Journal of Wuhan University of Technology (Information & Management Engineering), 2019, 41(1):17-21.
- [18] KHUMAIDI A, YUNIARNO E M, PURNOMO M H. Welding defect classification based on convolution neural network (CNN) and Gaussian Kernel[C]//2017 International Seminar on Intelligent Technology and Its Applications. Surabaya: IEEE, 2017:261-265.
- [19] LIANG S W, KHOO Y, YANG H Z. Drop-activation: implicit parameter reduction and harmonious regularization[J]. *Communications on Applied Mathematics and Computation*, 2021, 3(2):293-311.
- [20] 孙笑笑, 江本赤, 陈智君, 等. 基于数字孪生与 BP 神经

- 网络的RV减速器故障诊断[J/OL]. 安徽科技学院学报, (2024-12-16). <https://link.cnki.net/urlid/34.1300.N.20241216.1250.006>.
- SUN X X, JIANG B C, CHEN Z J, et al. Fault diagnosis of RV reducer based on digital twin and BP neural network[J/OL]. Journal of Anhui Science and Technology University, (2024-12-16). <https://link.cnki.net/urlid/34.1300.N.20241216.1250.006>.
- [21] NAIK N S, CHAUBEY H K. Weed detection and classification in sesame crops using region-based convolution neural networks[J]. *Neural Computing and Applications*, 2024, 36(30):18961–18977.
- [22] CRNJANSKI J, KRSTIĆ M, TOTOVIĆ A, et al. Adaptive sigmoid-like and PReLU activation functions for all-optical perceptron[J]. *Optics Letters*, 2021, 46(9):2003–2006.
- [23] SUDAR K M, NAGARAJ P, MUNESWARAN V, et al. Dermo classify: a dermatologist skin disease detection and classification using DCNN[J]. *Research on Biomedical Engineering*, 2024, 41(1):13.
- [24] 王静, 白云. 基于改进YOLOv5s的车辆目标检测算法[J]. 信息与电脑(理论版), 2022, 34(10):80–83.
- WANG J, BAI Y. Vehicle detection based on improved YOLOv5s[J]. *Information & Computer*, 2022, 34(10):80–83.
- [25] LIU S H, REN Y S, LI L T, et al. Micro-expression recognition based on SqueezeNet and C3D[J]. *Multimedia Systems*, 2022, 28(6):2227–2236.
- [26] LIU Y, YUAN K, LI T, et al. NDT method for line laser welding based on deep learning and one-dimensional time-series data[J]. *Applied Sciences*, 2022, 12(15):7837.
- 责任编辑:何莉
-
- (上接第297页)
- [20] YU J, XIAO F, CAO M. Lag group consensus of high-order multiagent systems in directed network settings[J]. *Ieee transactions on systems, man, and cybernetics: Systems*, 2023, 53(7):4442–4452.
- [21] 马小陆, 谭毅波, 梅宏. 符号图下含扰动的多智能体系统预定时间二分一致性[J]. 控制与决策, 2024, 39(5):1517–1526.
- [22] ROY S. Scaled consensus[J]. *Automatica*, 2015, 51:259–262.
- [23] MENG D, JIA Y. Robust consensus algorithms for multiscale coordination control of multi-vehicle systems with disturbance[J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(2):1107–1119.
- [24] ZHANG Z, CHEN S M, ZHENG Y. Leader-following scaled consensus of second-order multi-agent systems under directed topologies[J]. *International Journal of Systems Science*, 2019, 50(14):2604–2615.
- [25] MUNOZ-VAZQUEZ A J, SÁNCHEZ-TORRES J D, JIMENEZ-RODRIGUEZ E. Predefined-time robust stabilization of robotic manipulators[J]. *IEEE/ASME Transactions On Mechatronics*, 2019, 24(3):1033–1040.
- [26] OLFATI-SABER R, MURRAY R M. Consensus problems in networks of agents with switching topology and time delays[J]. *IEEE Transactions on Automatic Control*, 2004, 49(9):1520–1533.
- [27] HU B, GUAN Z H, FU M Y. Distributed event-driven control for finite-time consensus[J]. *Automatica*, 2019, 103:88–95.
- [28] LIU J, SHI J L, YUAN X, et al. Dynamic event-based nonsingular practical fixed-time second-order consensus[J]. *IEEE Transactions on Network Science and Engineering*, 2024, 11(2):1959–1970.
- 责任编辑:何莉