

基于边缘 AI 的焊缝 X 射线图像缺陷检测

王睿^{1,2}, 胡云雷¹, 刘卫朋¹, 李海涛¹

(1. 河北工业大学, 天津, 300131; 2. 哈尔滨工业大学, 先进焊接与连接国家重点实验室, 哈尔滨, 150001)

摘要: 为了提高深度学习在 X 射线焊缝缺陷检测中的实用性, 降低缺陷检测任务的硬件需求, 提出模型参数量仅为 3.6 M 的 YOLO-M 网络. 通过在网络中引入轻量级的倒残差结构, 减少网络计算量; 采用多尺度预测机制, 网络分层预测不同缺陷特征; 跨网格扩增图片正样本信息, 加快网络训练过程中的收敛速度. 结果表明, YOLO-M 网络不仅应用于传统计算机, 而且成功试验于超低功耗边缘人工智能芯片勘智 K210 中. 所提方法在嵌入式端的检测准确率为 93.5%, 检测速度为 11 帧/s. 该方法具有良好的检测准确度, 极大降低了缺陷检测的成本.

创新点: (1) 轻量级的焊缝缺陷识别网络, 精准识别焊缝缺陷, 具有较少的模型参数和较快的推理速度.
(2) 在低功耗边缘智能设备上完成焊缝缺陷识别任务, 极大降低了自动质检工作的成本.

关键词: 缺陷检测; 深度学习; 轻量化; 嵌入式设备

中图分类号: TG 441 **文献标识码:** A **doi:** 10.12073/j.hjxb.20210516001

0 序言

X 射线焊缝检测在管道焊接和连接领域应用广泛^[1]. 针对 X 射线焊缝图像底片的质检, 更多的是采用人工检测的方式, 根据工程师的经验来判断检测结果的好坏, 在检测效率和检测标准上会受到主观性的制约. X 射线焊缝图像的检测大多基于主观设定阈值来凸显缺陷特征, 焊缝缺陷对比度低, 许多时候不易直接提取特征, 而且, 基于阈值的方式很难对缺陷类型进行定位和分类^[2]. 随着计算机和人工智能的发展, 许多学者从传统的主观提取 X 射线焊缝图像特征, 转向用自动学习的方式提取 X 射线焊缝特征^[3-4]. 刘涵等人^[5]采用卷积神经网络 (convolutional neural networks, CNN) 和 Softmax 分类器, 研究了基于石油钢管场景下的焊缝的缺陷检测与识别. 樊丁等人^[6]改进了模型中的指数线性单元 (exponential linear unit, ELU) 函数, 来识别焊缝 X 射线图像的缺陷. 谢经明等人^[7]通过减少 X 射线焊缝识别网络的检测层数, 提高卷积神经网络的推理速度.

卷积神经网络通过反向传播学习缺陷特征, 通

过数据提高模型的鲁棒性, 利用卷积神经网络可以有效解决 X 射线焊缝缺陷自动检测问题. 目标检测的主要算法包括以 Faster R-CNN^[8] 系列为代表的两阶段目标检测算法和以 YOLO^[9] 系列为代表的一阶段算法. 从焊缝缺陷检测的已有研究来看, 焊缝自动辨识技术的研究建立在高性能计算机之上^[10], 所提出的算法参数较多、权重较大、训练较慢, 更多考虑的是模型单方面性能, 缺乏对硬件资源的全面考虑.

针对以上问题, 结合 X 射线焊缝缺陷检测任务特点, 算法基于 YOLO 目标检测框架, 引入轻量级的倒残差结构^[11], 加快缺陷信息在边缘硬件上的传播效率. 采用多尺度预测机制, 精准识别不同缺陷特征. 跨网格扩增缺陷正样本, 加快模型训练过程中的收敛速度. 最后, 通过计算机以及边缘设备进行焊接质检试验, 研究轻量级卷积神经网络的检测性能和智能硬件的运行性能.

1 系统架构

边缘分布式运算具有实时性、高效性、安全性和低成本等特点^[12], 试验采用的边缘人工智能 (artificial intelligence, AI) 检测器的核心部件为 K210 芯片, 芯片功耗为 0.3 W, 主要负责图像检测、控制器运算和数据处理. K210 是 RISC-V 双核

64 位 CPU, 支持机器视觉多模态识别, 具有神经网络硬件加速器, 其处理器运算能力为 1 TOPS, 相比于拥有 128 个 CUDA 单元的 Jetson Nano, K210 芯片具有良好的性能指标和更低廉的价格。

系统部署流程如图 1 所示, 首先组成适用于提取缺陷特征的数据集, 通过深度学习中卷积神经网络构建检测模型, 训练出来的模型文件通过勘智官方提供的工具链转换成 K210 芯片支持的 KModel 格式, 转换后的模型烧录进边缘识别设备。

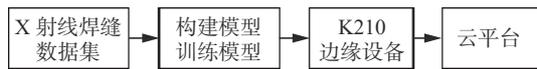


图 1 系统部署流程图
Fig. 1 Flow chart of system deployment

具有辨识能力的嵌入式设备可以对焊缝图像进行区域性检测, 安装在检测器前方的摄像头将缺陷图片信息传递给 K210 芯片, 芯片利用自身神经网络加速器处理输入图片, 最终获得目标位置类别等处理结果. 通过物联网模块进行 MQTT 协议通信, 连接物联网云平台并上传设备状态信息, 云平台统计边缘 AI 设备的状态信息, 方便工程人员观察统计 X 射线焊缝缺陷信息. 把边缘硬件验证算

法和云端数据存储相结合, 极大增加了缺陷识别系统的鲁棒性。

2 CNN 模型

2.1 模型架构

复杂模型在工业场景或低端设备上难以被使用, 工程设计需要采用更加轻量的网络形式, 卷积网络不仅要在性能和模型大小之间进行衡量取舍, 同时要考虑勘智官方工具链对网络结构的支持. YOLO-M 是基于格子预测, 相比较于先产生候选区域, 再生成候选框的双阶段算法, 其不仅有更快的检测速度, 也具有更好的准确率. 如图 2 所示, 针对焊缝缺陷多尺度的特征, 从 3 个不同输出层对 X 射线焊缝缺陷进行检测, 网络可以更好地辨别缺陷特征。

考虑到边缘设备的加速器结构和计算效率等问题, 为了充分满足 K210 边缘设备的需求特点, 算法的主干网络采用轻量的线性瓶颈的倒残差结构, 从而实现在不同图像细粒度上聚合并形成图像特征. 随着神经网络的训练, 网络的参数不断更新, 预测层结果不断接近目标真实结果, 训练结束后卷积

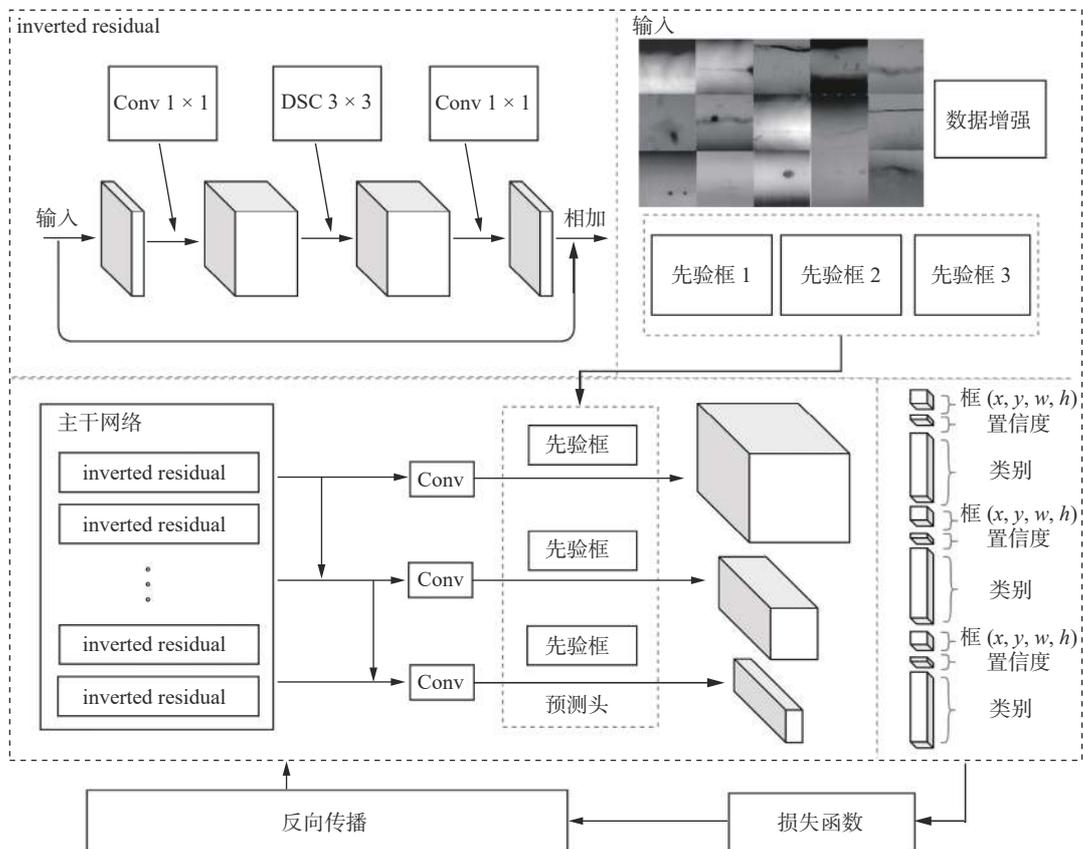


图 2 YOLO-M 架构图
Fig. 2 YOLO-M architecture diagram

神经网络的参数达到最佳,通过最佳参数的模型实现焊缝辨识任务.

2.2 主干网络结构

如图 2 所示,主干网络采用倒残差 (inverted residual) 结构,倒残差先使用 1×1 的卷积 (convolution, Conv) 结构,目的是将低维空间映射到高维空间,增加维度后采用分离提取的方式来提取特征,由于将传统的卷积改为了分离提取的方式,使得网络的计算量和参数大幅减少,线性瓶颈的倒残差结构的中间层可以增加通道数来提取更多特征,更好的识别 X 射线焊缝缺陷信息.对于低维空间图片信息而言,进行线性映射会保存 X 射线焊缝缺陷特征,而非线性函数会影响缺陷信息的传递,残差结构两边的维度信息通道数都较少,可以认为是“低维向量”,所以后面线性激活选择大小为 1×1 的卷积核.倒残差结构可以增加缺陷信息在不同层级之间的传播能力,保持目标向量信息传输,有着更好的内存使用效率.一个瓶颈块的操作运算 $F(x)$ 可以表示为 3 个运算操作的组合.

$$F(x) = [A \cdot N \cdot B]x \quad (1)$$

式中: A 为线性变换函数; N 为卷积的每个通道非线性变换函数; B 为输出域的线性变换函数; x 为卷积运算输入.

如图 3 所示,深度可分离卷积 (deep separable convolution, DSC) 将传统的卷积提取特征的过程分解为两部分,首先对输入每个通道的图像信息采用轻量级的单通道滤波器,分别提取不同信息,然后通过逐点卷积组成新的图像信息.在达到同样的输出效果的同时,采用分离提取的方式比传统卷积参数减少 8~9 倍.

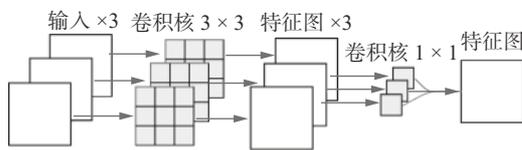


图 3 深度可分离卷积模型

Fig. 3 Deeply separable convolution model

2.3 目标框生成

在 X 射线焊缝缺陷检测训练任务中, YOLO-M 网络通过 k-mean 聚类产生适合焊缝缺陷的先验框,目的是对预测焊缝缺陷识别框进行约束,根据预测头的结构特点,在最小的特征图上,其单位面积内的图像感知范围最大,应用最大尺度的先验框,适合辨识尺度较大的目标.在最大的特征图上,

其单位面积内的图像感知范围最小,应用最小尺度的先验框,适合辨识尺度小的目标.

YOLO-M 网络输出三维特征来表达缺陷坐标 x 和 y 、宽度 w 和高度 h 、缺陷置信度、缺陷类别.其中,缺陷坐标 x 和 y 、缺陷宽度 w 、高度 h 经先验框微调与真正的目标缺陷图像重合,置信度信息判断是否存在目标缺陷,缺陷类别信息判断缺陷类型.通过网络训练得到最优损失函数,损失函数 L 由边框信息损失函数 L_{box} 、目标置信度损失函数 L_{obj} 和目标分类损失函数 L_{cls} 组成.网络中置信度预测和类别预测均采用二分类交叉熵损失 L_{BCE} (binary cross entropy loss, BCE),边框回归采用 Complete IoU (CIoU) loss^[13].

$$t_x = g_x - c_x \quad (2)$$

$$t_y = g_y - c_y \quad (3)$$

$$t_w = \log(g_w/p_w) \quad (4)$$

$$t_h = \log(g_h/p_h) \quad (5)$$

$$b_x = 2\sigma(t_x) - 0.5 + c_x \quad (6)$$

$$b_y = 2\sigma(t_y) - 0.5 + c_y \quad (7)$$

$$b_w = p_w [2\sigma(t_w)]^2 \quad (8)$$

$$b_h = p_h [2\sigma(t_h)]^2 \quad (9)$$

$$L_{\text{BCE}} = -\frac{1}{n} \sum_{i=1}^n [t_i \ln o_i + (1 - t_i) \ln(1 - o_i)] \quad (10)$$

$$L = L_{\text{box}} + L_{\text{obj}} + L_{\text{cls}} \quad (11)$$

式中: t_x, t_y, t_w, t_h 为归化后的坐标和宽、高度信息; g_x, g_y, g_w, g_h 为标注框的坐标和宽、高度信息; c_x, c_y 为预设先验框的左上角坐标信息; p_w, p_h 为预设先验框的宽、高度信息; b_x, b_y, b_w, b_h 为网络输出的坐标和宽、高度信息; σ 为 Sigmoid 归一化函数^[9], 加快模型收敛; n 为输出信息数量; t_i 为目标信息; o_i 为输出信息; L 为模型损失函数; L_{box} 为边框信息损失函数; L_{obj} 为目标置信度损失函数; L_{cls} 为目标分类损失函数.

为了增加焊缝缺陷正样本和加快网络的收敛速度,如图 4 所示,网络采用跨网格的预测机制,模型基于网格预测,缺陷中心点所在的网格负责预测缺陷,同时增加相邻网格作为负责预测缺陷的网格,通过跨网格策略极大提高了网络训练时的收敛速度.网络训练中采用数据增强策略,随机拼接缺陷图片,增强小目标的检测能力.每一个网格生成 3 个先验框,先验框通过调整生成目标框,在输出真

正目标框之前,模型通过目标框分数特征信息筛选和保留最优目标框.

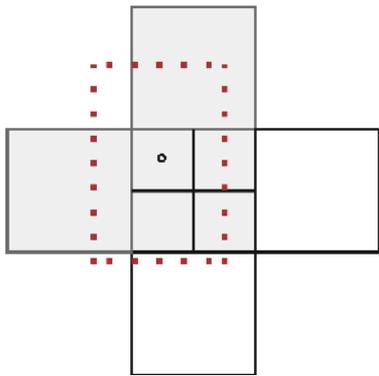


图 4 预测机制

Fig. 4 Prediction mechanism

3 试验结果与分析

3.1 X 射线数据集

训练算法和验证算法的数据集由 GDXray 公共数据库^[14]和中国石油天然气管道科学研究院提供的缺陷底片样本共同组成. 从联合数据集中获取 2070 个具有相同大小的不同缺陷裁剪补丁, 图像的尺寸为 128 像素 × 128 像素. 图 5、图 6、图 7 和图 8 分别为裂纹 (crack, CR)、气孔 (porosity, PO)、未焊透 (lack of penetration, LOP)、未熔合 (lack of fusion, LOF) 缺陷图像检测过程可视化. X 射线焊

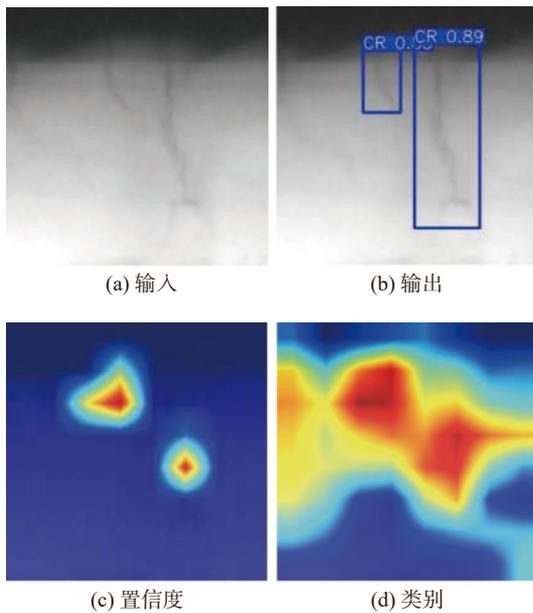


图 5 CR 图像检测过程可视化

Fig. 5 Visualization of CR image detection process. (a) input; (b) output; (c) confidence; (d) class

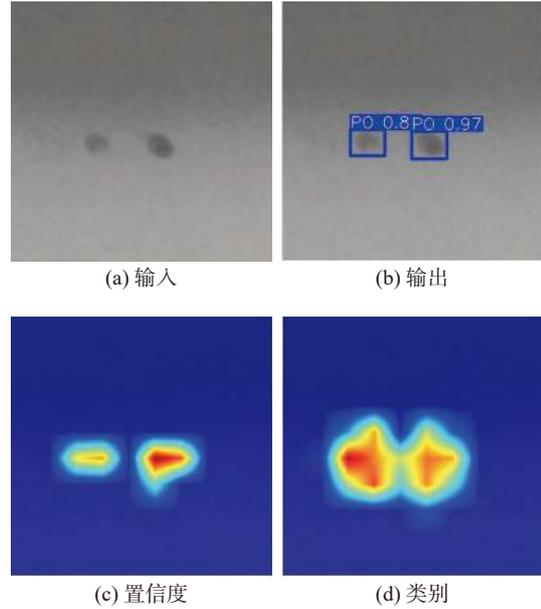


图 6 PO 图像检测过程可视化

Fig. 6 Visualization of PO image detection process. (a) input; (b) output; (c) confidence; (d) class

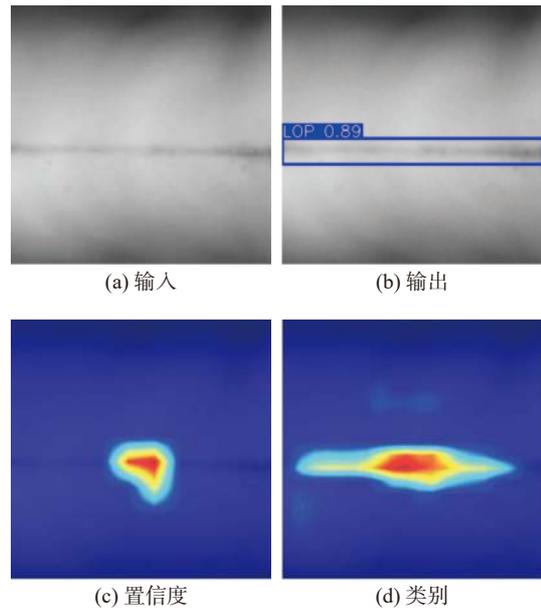


图 7 LOP 图像检测过程可视化

Fig. 7 Visualization of LOP image detection process. (a) input; (b) output; (c) confidence; (d) class

缝缺陷图像具有模糊、多尺度等特征, 其中, 裂纹缺陷大小不一, 未焊透缺陷对比度极低, 未熔合缺陷长宽对比大, 气泡缺陷相对微小.

3.2 网络试验分析

3.2.1 评价指标

以下指标评估网络的综合性能, 例如准确率 (average precision, AP)、平均准确率 (mean average precision, mAP)、每秒帧数 (frames per second, FPS)、模型参数 (model parameters, MP).

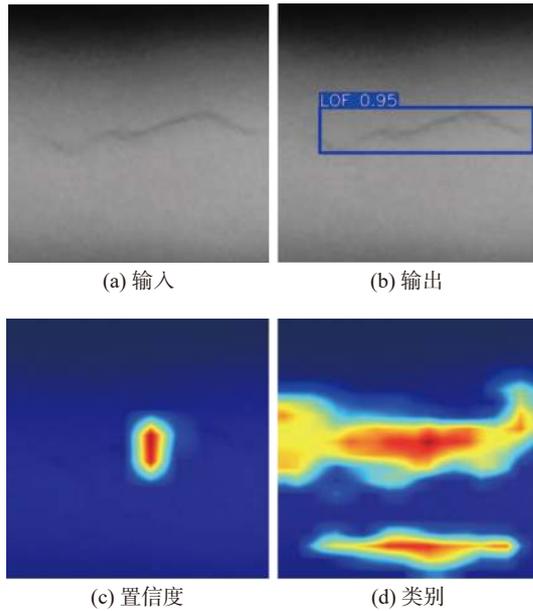


图 8 LOF 图像检测过程可视化

Fig. 8 Visualization of LOF image detection process. (a) input; (b) output; (c) confidence; (d) class

$$Y_{AP} = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (12)$$

$$Y_{MP} = n(hwc + 1) \quad (13)$$

式中: Y_{AP} 为准确率; Y_{MP} 为模型参数量; N_{TP} 为检测结果正确的图片数量; N_{FP} 为检测结果错误的图片

数量; c 为卷积输入通道数; n 为卷积输出通道数; h, w 为卷积核的高度和宽度; 1 为偏置因子。

3.2.2 结果可视化

卷积神经网络是黑盒模型, 通过可视化输出层的方式验证网络的效果. 卷积神经网络输出三维向量, 每一层的二维向量都代表不同含义, 如图 5~图 8 所示, 其中图 5~图 8 中 b 图为可视化缺陷检测结果, 包括缺陷位置框, 缺陷类别和置信度分数. 图 5~图 8 中 c 图为可视化缺陷检测过程中置信度信息层. 图 5~图 8 中 d 图为可视化缺陷检测过程中类别信息层。

检测过程中, 缺陷图片上会形成特征信息, 把特征信息映射到原图片上产生不同颜色, 由于是跨网格预测机制, 所以缺陷附近也存在不同程度信息, 网络筛选分数最优的信息, 通过置信度和类别分数的综合评定, 网络最终确定缺陷类型。

3.2.3 试验对比

对比试验网络包括主流一阶段目标识别网络、二阶段目标识别网络、多阶段目标识别网络以及基于非边框预测的目标识别网络, 在 X 射线焊缝缺陷数据集上验证网络的有效性, 网络运行硬件的显卡环境为 Nvidia Gefore GTX TITAN, 对比结果如表 1 所示。

表 1 焊缝识别效果对比

Table 1 Comparison of weld recognition effect

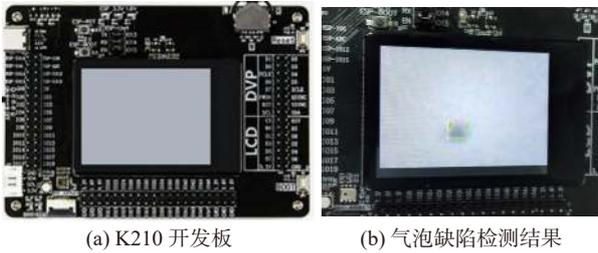
测试网络	准确率 $Y_{AP}(\%)$				平均准确率 $Y_{mAP}(\%)$	检测速度 $Y_{FPS}/(\text{帧} \cdot \text{s}^{-1})$	模型参数量 $Y_{MP}(\text{M})$
	CR	LOF	LOP	PO			
YOLO V3	93.12	93.11	94.30	98.18	94.68	5.25	61.54
Faster-RCNN	85.33	95.40	95.26	92.11	92.03	6.30	41.14
Cascade-RCNN	87.17	92.31	98.30	95.33	93.28	7.88	68.94
RegNet	89.97	94.77	98.51	96.87	95.03	9.00	31.48
CentripetalNet	84.05	90.13	93.19	91.04	89.60	7.87	205.68
YOLO-M	92.53	93.30	93.40	96.46	93.92	100	3.60

由于裂纹缺陷的尺度不均匀, 对比度较小, 不同检测网络对于裂纹的识别率较低. 具有多尺度检测机制的网络可以更好识别不同尺度缺陷, 其中, YOLO-M 网络对于不同类型的缺陷都具有较好的检测效果. 特征残差提取结构使得 YOLO-M 网络整体参数量极低, 模型权重仅为 3.6 M, 较少的计算量和更高效的残差结构使得网络具有较高的推理速度, 在计算机上的前向推理速度为 100 帧/s, 可

以实时检测焊缝缺陷。

由于嵌入式平台的内存限制, 只有参数较少的网络才能进行部署. YOLO-M 网络进一步转化为 K210 芯片支持的 KModel 网络格式, 转化后的模型权重仅为 3.7 M. 识别过程中, 由于摄像头传输信息加大噪声对缺陷识别任务的影响, 所以使用程序对数据集加入随机的椒盐噪声和高斯噪声, 提升网络识别能力. 如图 9 所示, K210 边缘设备具有良好

的识别效果。经过测试,由于试验中摄像头采集性能的限制,K210 设备上的网络检测速度为 11 帧/s,检测准确率为 93.5%。



(a) K210 开发板 (b) 气泡缺陷检测结果

图 9 嵌入式设备和检测结果

Fig. 9 Embedded device and detection results. (a) K210 development board; (b) bubble defect detection results

4 结论

(1) YOLO 系列检测模型的计算量主要集中在主干网络,采用倒残差结构减少模型参数量,加快了缺陷特征提取速度,模型参数量仅为 3.6 M。从训练可视化图得出,多尺度检测网络可以学习缺陷信息,识别不同焊缝缺陷。

(2) 由于裂纹缺陷的尺度不均匀,对比度较小,不同检测网络对于裂纹的识别率较低,需要不断扩增数据集,提高网络的拟合能力。

(3) 在勘智 K210 设备上进行了试验,YOLO-M 网络检测准确率为 93.5%,检测速度为 11 帧/s,该网络可以检测小目标缺陷。试验结果证明了低成本焊缝自动质检的可行性,所提方法可结合数字射线成像检测设备进行缺陷质检试验。

参考文献

- [1] 迟大钊, 马子奇, 程怡, 等. 不等厚板搭接焊缝缺陷数字 X 射线检测 [J]. 焊接学报, 2019, 40(11): 45 - 48.
Chi Dazhao, Ma Ziqi, Cheng Yi, *et al.* Digital X-ray detection of lap weld defects in unequal-thickness plates[J]. Transactions of the China Welding Institution, 2019, 40(11): 45 - 48.
- [2] Yan Z H, Xu H, Huang P F. Multi-scale multi-intensity defect detection in ray image of weld bead[J]. NDT & E International, 2020, 116: 102342 - 102357.
- [3] Hou W, Zhang D, Wei Y, *et al.* Review on computer aided weld defect detection from radiography images[J]. Applied Sciences, 2020, 10(5): 1878 - 1893.
- [4] 修延飞, 李海超, 胡广泽, 等. 一种用于穿孔塞焊缝特征提取的视觉识别算法 [J]. 焊接学报, 2020, 41(2): 75 - 79, 86.
Xiu Yanfei, Li Haichao, Hu Guangze, *et al.* A visual recognition algorithm for feature extraction of perforated plug weld[J]. Transactions of the China Welding Institution, 2020, 41(2): 75 - 79, 86.
- [5] 刘涵, 郭润元. 基于 X 射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别 [J]. 仪器仪表学报, 2018, 39(4): 247 - 256.
Liu Han, Guo Runyuan. Detection and recognition of weld defects of petroleum steel pipe based on X-ray image and convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 247 - 256.
- [6] 樊丁, 胡桢得, 黄健康, 等. 基于改进卷积神经网络的管焊缝 X 射线图像缺陷识别方法 [J]. 焊接学报, 2020, 41(1): 7 - 11.
Fan Ding, Hu Yude, Huang Jiankang, *et al.* X-ray image defect recognition method of pipe weld based on improved convolutional neural network[J]. Transactions of the China Welding Institution, 2020, 41(1): 7 - 11.
- [7] 谢经明, 刘默耘, 何文卓, 等. 基于轻量化 YOLO 的 X 射线焊缝图像信息检测 [J]. 华中科技大学学报(自然科学版), 2021, 49(1): 1 - 5.
Xie Jingming, Liu Moyun, He Wenzhuo, *et al.* X-ray weld image information detection based on lightweight YOLO[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2021, 49(1): 1 - 5.
- [8] Ren S, He K, Girshick R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137 - 1149.
- [9] 鞠默然, 罗海波, 王仲博, 等. 改进的 YOLO V3 算法及其在小目标检测中的应用 [J]. 光学学报, 2019, 39(7): 253 - 260.
Ju Moran, Luo Haibo, Wang Zhongbo, *et al.* Improved YOLO V3 algorithm and its application in small target detection[J]. Journal of Optics, 2019, 39(7): 253 - 260.
- [10] Nacereddine N, Goumeidane A B, Ziou D. Unsupervised weld defect classification in radiographic images using multivariate generalized Gaussian mixture model with exact computation of mean and shape parameters[J]. Computers in Industry, 2019, 108: 132 - 149.
- [11] Hou D, Miao Z, Xing H, *et al.* Exploiting low dimensional features from the MobileNets for remote sensing image retrieval[J]. Earth Science Informatics, 2020, 13(4): 1437 - 1443.
- [12] Wang X, Han Y, Wang C, *et al.* In-Edge AI: Intelligentizing mobile edge computing, caching and communication by federated learning[J]. IEEE Network, 2019, 33(5): 156 - 165.
- [13] Zheng Z, Wang P, Liu W, *et al.* Distance-IoU loss: Faster and better learning for bounding box regression[C]//Association for the Advancement of Artificial Intelligence. Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA, 2020, 34(7): 12993-13000.
- [14] Mery D, Rizzo V, Zscherpel U, *et al.* GDxray: The database of X-ray images for nondestructive testing[J]. Journal of Nondestructive Evaluation, 2015, 34(4): 1 - 12.

第一作者: 王睿, 博士, 讲师; 主要从事焊接过程控制和焊缝缺陷检测等研究; Email: wangrui@hebut.edu.cn.

通信作者: 胡云雷, 硕士研究生; Email: 961584451@qq.com.

(编辑: 张芷晴)