

# 基于深度学习算法的超声 TOFD 图像焊缝缺陷识别

胡伟<sup>1</sup>, 阮先虎<sup>2</sup>, 金明东<sup>1</sup>, 刘朵<sup>2</sup>, 张建东<sup>2,3</sup>

(1. 南通市港航事业发展中心, 江苏 南通 226000; 2. 苏交科集团股份有限公司, 长大桥梁安全长寿与健康运维国家重点实验室, 南京 211112; 3. 南京工业大学, 南京 211816)

**摘要:** 【目的】针对传统焊缝缺陷检测中人工效率低、检测难度大和漏检率高等问题, 基于试验模拟与深度学习算法提出了一种面向 TOFD D 扫图像的缺陷识别方法。【方法】通过室内试验对不同类型的对接焊接缺陷(夹渣、裂纹、未焊透、气孔和未熔合)进行了模拟, 利用不同数据增强方法构建了实际 TOFD 检测数据特征图库, 结合 YOLOv5 深度学习网络结构进行 TOFD D 图像数据集的训练与检测, 提升模型对焊接缺陷的识别性能, 并且自动输出缺陷智能检测结果。【结果】试验结果表明, 该方法具备优越的模型泛化能力, 当 IoU 阈值设定为 0.5 时, 模型训练的准确率可达到 98.05%; 针对 5 种焊接缺陷类型, 在识别时的分类置信度均超过 95%, 有效提升了焊接缺陷识别的效率, 可满足实际场景在线识别要求。【结论】提出的焊接缺陷识别方法具有较高的准确性, 可广泛用于不同缺陷检测模型的构建, 为焊接质量控制提供了有效的技术支持。

**关键词:** 缺陷识别; TOFD; YOLOv5; 深度学习

中图分类号: TG441.7 文献标识码: A doi: 10.12073/j.hj.20240228005

## Weld defect recognition in ultrasonic TOFD image based on depth learning algorithm

Hu Wei<sup>1</sup>, Ruan Xianhu<sup>2</sup>, Jin Mingdong<sup>1</sup>, Liu Duo<sup>2</sup>, Zhang Jiandong<sup>2,3</sup>

(1. Nantong Port and Shipping Development Center, Nantong 210019, Jiangsu, China;

2. State Key Laboratory of Safety, Durability and Healthy Operation of Long Span Bridges,

JSTI Group Co., Ltd., Nanjing 211112, China; 3. Nanjing Technology University, Nanjing 211816, China)

**Abstract:** [Objective] Addressing the issues of low manual efficiency, high detection difficulty, and high missed detection rates in traditional weld defect detection, this study proposes a defect recognition method for TOFD D-scan images based on experimental simulation and deep learning algorithms. [Methods] Different types of butt weld defects (slag inclusions, cracks, lack of penetration, porosity, and lack of fusion) are simulated through indoor experiments. A feature image library of actual TOFD detection data is conducted by various data augmentation methods. TOFD D-scan image datasets are trained and detected by the YOLOv5 deep learning network structure to enhance the model's capability to recognize weld defects and automatically output intelligent detection results. [Results] The experimental results indicate that this method possesses excellent model generalization ability, achieving an accuracy of 98.05% with an IoU threshold of 0.5. For five types of welding defects, the classification confidence during recognition exceeds 95%, significantly improving the efficiency of weld defect recognition and meeting the requirements for online recognition in practical scenarios. [Conclusion] The proposed weld defect recognition method demonstrates high accuracy and can be widely used for constructing various defect detection models, providing effective technical support for welding quality control.

**Key words:** defect recognition, TOFD, YOLOv5, deep learning

收稿日期: 2024-02-28

基金项目: 江苏省交通运输科技与成果转化项目(2023Y20); 江苏省交通运输重点科技项目(2022QD11)。

## 0 前言

超声衍射时差法(Time of flight diffraction, TOFD)以其精确的缺陷定位特性、丰富的检测信息、良好的抗干扰能力和高效率,在焊接质量评估领域备受青睐,成为常用的无损检测技术之一。但传统上 TOFD 数据的分析依赖于专家的目视评估,这一过程易受成像原理、焊缝特性及现场环境等因素干扰,尤其在处理大规模焊接数据时,缺陷数据量太少,导致检测结果中可能出现噪声难以分辨<sup>[1]</sup>。因此,人工分析方法在效率、一致性和准确性方面存在局限。随着 TOFD 技术在交通领域的深入应用以及数据的大量积累,基于 TOFD 检测数据进行自动化焊缝缺陷鉴定的技术研究变得日益重要。

近几年专家学者对深度学习等理论进行了深入研究,其中基于无损检测数据的识别技术也逐渐受到关注。陈振华等人<sup>[2]</sup>通过对 TOFD 直通波信息特征的分析与提取,实现了对表层缺陷的有效识别与分类。Ren 等人<sup>[3]</sup>开发了一种两阶段的检测器 Faster-RCNN,该检测器结合仿真和少量真实数据训练的卷积神经网络,能够从超声相控阵数据中实现缺陷的检测、定位及大小确定,在 IOU 阈值设定为 0.4 时,其定位准确率达到 70%。Posilovic<sup>[4]</sup>利用 B 扫描的缺陷检测图像测试了 SSD 和 YOLOv3 两类算法,发现 YOLOv3 的无损评估数据分析精度达到了 89.7%,但测试数据集只包含 98 张图像,可能会导致网络过于泛化。Jin<sup>[5]</sup>将 B 扫描图像信息转换为波形信号,提取出波的传播时间和振幅等特征,实现了对厚壁构件表面缺陷的鉴别。Silva 等人<sup>[6]</sup>采用极限学习机(ELM)分类网络算法对 TOFD 信号进行分析,通过输入傅里叶频谱系数,实现了 85% 的缺陷检测准确率。林乃昌等人<sup>[7]</sup>通过结合粒子群优化算法和核主成分分析法对图像特征进行降维处理,并选取 109 幅 D 扫描图像作为训练样本,以 25 幅图像测试支持向量机(SVM)分类器,获得了 76% 的缺陷检测率。Chen 等人<sup>[8]</sup>利用区域性卷积神经网络(R-CNN)构建缺陷识别模型,输入 D 扫描图像中的缺陷区域,实现了超过 80% 的缺陷识别准确度。黄焕东等人<sup>[9]</sup>探讨了 TOFD-D 扫描图像中缺陷轮廓与图像特征之间的关联,运用 Faster R-CNN 算法对图像进行分类,不过该方法对 TOFD 数据中的噪声和界面波的判别存在误差风险。谷静等人<sup>[10]</sup>利用深度学习的 DenseNet 算

法对数据进行了动态增强,并与 LS-SVM 及 LeNet 算法相比较,结果显示 DenseNet 网络在焊接缺陷识别上的准确率可达 98.97%。

综上所述,TOFD 检测方法具有海量的数据特征,其中波形数据与图像数据各自承载了部分的缺陷信息<sup>[11]</sup>,但已有研究主要以 A 扫、B 扫和 D 扫产生的波形数据进行分析,对图像数据的相关研究较少,不能完全挖掘出图像包含的丰富信息。目前应用于焊接缺陷图像识别的算法(例如 SVM, BP, AdaBoost, ANN, MLP 等)在图像的精确分割方面效果并不理想<sup>[12]</sup>,特征选择及其参数化过程容易受到主观因素的干扰,进一步限制了缺陷识别效率与准确性的提升。因此,文中针对不同类型焊接缺陷展开试验模拟,利用实际 TOFD 检测数据构建样本库,基于 YOLOv5 算法自动学习不同缺陷类型中的复杂特征,从而对目标进行分类,并确定缺陷目标在图像中的精确定位,有效提高缺陷识别效率。

## 1 网络结构

YOLOv5 算法根据网络深度和宽度的不同有 4 个版本,分别为 v5s, v5m, v5l 和 v5x。根据目标检测的精度和时间需求,需要调整相应的深度系数(depth\_multiple)和宽度系数(width\_multiple)。考虑到 YOLOv5s 具有较快的检测速度<sup>[13]</sup>,文中选择采用 YOLOv5s 网络来检测焊缝缺陷。该网络架构主要包括输入层、骨干网络(Backbone)、特征融合层(Neck)和目标检测头(YOLOHead)。

图像在 Backbone 骨干网络中首先进行 Focus 切片,然后进入 CSPDarknet53 网络,该网络主要结构是多个 CBS(Conv + BatchNorm + SiLU)模块和 C3 模块堆叠,CBS 模块用于辅助 C3 模块进行特征提取,最后连接一个 SPPF 模块,通过最大池化特征,避免了 SPPNet 中 SPP 的重复操作,增强了主干的特征表达能力,显著提高模块的运行速度,其结构如图 1 所示。




图 1 SPPF 模块结构

Fig. 1 SPPF module structure

Neck 模块由特征金字塔网络(FPN)和路径聚合网络(PAN)组成。在 FPN 中,通过将 Backbone 提取的深层特征上采样与浅层信息逐元素相加,形成了多尺度的特征金字塔结构(32 倍下采样,16 倍下采样,8 倍下采样)。同时 FPN 巧妙地融合了低层特征的高

分辨率和高层特征的高语义信息<sup>[14]</sup>,PAN 在进一步强化语义信息的同时,增加了多层自底向上的金字塔结构,以获取更多的位置信息。通过将 PAN 与 FPN 相结合,有效获得了丰富而全面的特征信息。YOLOv5 特征融合部分如图 2 所示。




图 2 特征融合示意图

Fig. 2 Feature fusion schematic diagram

在特征融合后提取多个不同尺度的检测特征,最终将输出的特征分成  $S \times S$  的网格,在目标框定位损失  $l_{loc}$  中使用  $GIoU$  计算边界框得分,可以更好地反映预测框与真实框之间的重叠关系,不断调整得到最终预测框,其相互关系如图 3 所示。虚线框代表需要调整的 anchor,地图坐标的左上角设置为  $(0,0)$ ,  $p_w$  和  $p_h$  分别是 anchor 的宽度和高度,  $b_w, b_h$  为预测框尺寸,  $b_x$  和  $b_y$  为虚框的中心。

覆盖了目前钢桥常用的钢板厚度,材质为 Q345,坡口形式为 V 形,编号为  $N_1 \sim N_{12}$ ,试板缺陷形式以及部分试板形貌如图 4 和图 5 所示。




图 3 预测锚框

Fig. 3 Prediction anchor frame

## 2 TOFD 检测图像数据集

### 2.1 对接焊缝试验

利用 YOLOv5 的方法进行缺陷识别并评估此方法的性能,就必须有一个较大的图像数据集。文中通过制作了 12 块含有裂纹、气孔、夹渣、未焊透、未熔合缺陷的测试试块进行试验研究<sup>[15]</sup>,板材厚度基本




图 4 部分模拟试块

Fig. 4 Part of the simulated test block




图 5 缺陷示意图

Fig. 5 Defect diagram



试验仪器为汕头研究所生产的 SUPOR 32PT, 工艺参数采用楔块角度 60°、探头频率 7.5 MHz、晶片尺寸 3 mm, PCS 70 mm, 通过使用相控阵探头对区块进行扫描, 扫描角度为 30°~90°。从不同的角度和扫描方向可以看到其中的缺陷, 每个扫描图像中其外观都会略有不同, 忽略焊缝组织的不均匀性, 以射线/渗透检测结果为基准, 分别使用 TOFD 进行检测, 试验 D 扫图像样本如图 6 所示。




图 6 TOFD 焊缝缺陷图像样本

Fig. 6 TOFD weld defect image sample

## 2.2 图像数据集

文中对试验照片进行噪声添加、对比度调整、裁剪、平移、旋转、马赛克等处理, 以此作为一种隐式的规整化方法提高网络的鲁棒性, 防止小样本训练产生过拟合现象。最终的 TOFD 数据集包含 462 张图像, 其中包含 5 种典型表面缺陷, 即裂纹 (Crack)、未熔合 (Incomplete fusion)、未焊透 (Lack of penetration)、气孔 (Porosity)、夹渣 (Slag inclusion)。为了便于训练 YOLOv5 算法, 需将 VOC 格式的数据集标注文件批量转换为 YOLO 格式, 标注文件包括类别序号 (0, 1, 2, 3, 4) 和目标位置的边框坐标, 见表 1。同时为了保持数据集的多样性和均衡性, 编写脚本将数据集按照 7:3 的比例划分为训练集和验证集, 其中训练集包含 396 张图像, 验证集包含 66 张。

表 1 数据集划分

Tab. 1 Partitioning of data sets

编号	缺陷类型	名称	总样本数 $n$	训练样本 $n_1$	验证样本 $n_2$
0	裂纹	Crack	112	96	16
1	未熔合	Incomplete fusion	84	72	12
2	未焊透	Lack of penetration	84	72	12
3	气孔	Porosity	112	96	16
4	夹渣	Slag inclusion	70	60	10

## 3 试验设置

启动网络训练流程之前, 需对训练文件内的参数执行调整, 详细参数配置见表 2。CUDA 版本是 10.2.89, Python 版本是 3.7, 将迭代次数设置为 90 次, 迭代的批量大小设置为 16, 优化器选择 SGD, 并采用余弦退火算法来更新学习速率。

表 2 试验关键超参数

Tab. 2 Experimental key hyperparameters

试验超参数	值
初始学习率	0.01
IoU 训练阈值	0.2
IoU 损失系数	0.05
Anchor 长宽比	4.0
梯度下降动量	0.937
预训练权重	YOLOv5s
训练图像大小	640
训练轮数 epoch	90
Batch-size	16
权重衰减系数	0.000 5

## 4 试验结果

### 4.1 训练过程

焊缝缺陷智能识别算法在制作好的训练集上训练, 损失函数曲线如图 7 所示。可以看出: (1) 置信度损失  $l_{conf}$  降低到了 0.01 左右, 分类损失  $l_{class}$  降低到了 0.001 左右, 目标框定位损失  $l_{loc}$  的 loss 值在 0.015; (2) 在模型训练达到稳定状态后, 损失值的下降曲线

呈现一致性,逐步趋于收敛,表明在训练与验证阶段均未观察到过拟合现象。在 TOFD 图像数据集上的各种参数指标的变化情况如图 8 所示,从图中可以发现:(1)在精确率方面,YOLOv5 网络模型达到最高的精确率为 98.05%;(2)网络模型在小范围训练时,召回率会有较大波动,但后面随着输入量的提高,召回率逐渐收敛;(3)在前 25 轮训练过程中,模型迅速达到了收敛状态,但经过 50 轮训练后,mAP 值趋于稳定,这表明训练效果比较理想,同时表现出对训练数据和新样本的良好泛化能力。

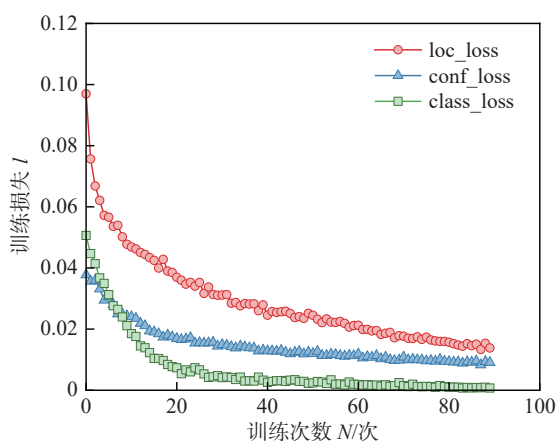


图 7 网络模型训练损失函数曲线

Fig. 7 Network model training loss function curve




图 8 网络模型评价指标

Fig. 8 Network model evaluation index

## 4.2 识别结果

训练流程完成后,在验证数据集上对模型进行了评估,相关的部分检测效果如图 9 所示,依次展示了对气孔、裂纹、未融合、未焊透以及夹渣等缺陷的检测结果图像。通过采用 YOLOv5 算法对检测到的目

标进行分类,结果显示没有发生分类错误,无论从目标框的回归效果、错检以及漏检现象而言,效果都较为良好,各类缺陷的单个分类置信度都在 95% 以上,最高达到 97%。同时可以发现,在已有的焊缝缺陷图像中气孔、夹渣和未焊透的形态和灰度较为相似,呈线状的裂纹、细线状的未融合这 2 类缺陷在形态上相似,这些都可能会导致网络结构产生错误识别,但是 YOLO 的算法结构能够有效学习到各类图像的深度特征。




图 9 焊缝缺陷检测结果

Fig. 9 Weld defect test result

## 5 结论

(1)展开室内试验获得 TOFD 检测焊缝缺陷数据,通过不同数据增强方法建立对接熔透焊缝典型缺陷的图像训练库,结合能够自动提取不同特征的 YOLOv5 算法,提出了 TOFD 焊缝缺陷类型和区域的智能识别方法,在输入检测图像后自动识别焊缝图像中每个缺陷的位置、大小与类型。

(2)训练的深度学习网络能够准确、快速地检测出不同缺陷的 D 扫图像,网络模型达到最高的精确率为 98.05%,取得了良好的分类效果,且对于试验样本验证的分类置信度都在 95% 以上,为 TOFD 当前检测数据的深入分析与实践应用提供技术路径。此外,该方法具有一定的适用性,其技术架构能够被扩展至包括相控阵在内的其他具备显著图像特性的检测数据分析领域。

## 参考文献

- [1] Praveen A, Vijayarekha K, Abraham S T, et al. Fourier analysis of ultrasonic TOFD signals for defect detection in austenitic stainless steel welds[J]. *International Journal of Computer Applications*, 2013, 71(9): 14–17.
- [2] 陈振华, 胡怀辉, 卢超. 基于超声 TOFD 直通波及神经网络的近表面缺陷自动识别 [J]. *无损检测*, 2014, 36(3):

- 14 – 17.
- Chen Zhenhua, Hu Huaihui, Lu Chao. Automatic identification technology of near surface defects based on neural network and through wave of ultrasonic TOFD[J]. *Non-destructive Testing*, 2014, 36(3): 14 – 17.
- [3] Ren Shaoqing, He Kaiming, Girshick Ross, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137 – 1149.
- [4] Posilović L, Medak D, Subašić M, et al. Flaw detection from ultrasonic images using YOLO and SSD[C]//2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA). IEEE, 2019: 163 – 168.
- [5] Jin S J, Sun X, Ma T T, et al. Quantitative detection of shallow subsurface defects by using mode-converted waves in time-of-flight diffraction technique[J]. *Journal of Nondestructive Evaluation*, 2020, 39(2): 33 – 41.
- [6] Silva L C, Filho E, Albuquerque M, et al. Segmented analysis of time-of-flight diffraction ultrasound for flaw detection in welded steel plates using extreme learning machines[J]. *Ultrasonics*, 2019, 102(11): 106057.
- [7] 林乃昌, 杨晓翔, 林文剑, 等. 基于改进的 KPCA 的 TOFD 图像缺陷识别方法 [J]. *福州大学学报 (自然科学版)*, 2014, 42(2): 277 – 281.
- Lin Naichang, Yang Xiaoxiang, Lin Wenjian, et al. Research on defect recognition of TOFD image based on improved KPCA[J]. *Journal of Fuzhou University (Natural Science Edition)*, 2014, 42(2): 277 – 281.
- [8] Chen Z, Huang G, Lu C, et al. Automatic recognition of weld defects in TOFD D-scan images based on faster R-CNN[J]. *Journal of Testing and Evaluation*, 2020, 48(2): 1 – 15.
- [9] 黄焕东, 胡利晨, 李斌彬, 等. 基于区域的快速卷积神经网络的焊缝 TOFD 检测缺陷识别 [J]. *无损检测*, 2019, 41(7): 12 – 18.
- Huang Huandong, Hu Lichen, Li Binbin, et al. Recognition of defect in TOFD image based on faster region convolutional neural networks[J]. *Nondestructive Testing Technology*, 2019, 41(7): 12 – 18.
- [10] 谷静, 王琦雯, 张敏, 等. 基于 DenseNet 网络的焊缝缺陷检测识别 [J]. *传感器与微系统*, 2020, 39(9): 129 – 131.
- Gu Jing, Wang Qiwen, Zhang Min, et al. Weld defect detection and recognition based on DenseNet network[J]. *Transducer and Microsystem Technologies*, 2020, 39(9): 129 – 131.
- [11] 支泽林, 姜洪权, 杨得焱, 等. 图谱数据深度学习融合模型及焊缝缺陷识别方法 [J]. *西安交通大学学报*, 2021, 55(5): 73 – 82.
- Zhi Zelin, Jiang Hongquan, Yang Deyan, et al. A deep learning fusion model of wave and image data for weld defect recognition[J]. *Journal of Xi'an Jiaotong University*, 2021, 55(5): 73 – 82.
- [12] 李砚峰, 刘翠荣, 吴志生, 等. 基于深度学习 One-stage 方法的焊缝缺陷智能识别研究 [J]. *广西大学学报 (自然科学版)*, 2021, 46(2): 362 – 372.
- Li Yanfeng, Liu Cuirong, Wu Zhisheng, et al. One-stage identification method for weld defects based on deep learning network[J]. *Journal of Guangxi University (Natural Science Edition)*, 2021, 46(2): 362 – 372.
- [13] 吕秀丽, 卢海滨, 侯春光, 等. 改进 YOLOv5s 的钢材表面缺陷检测算法 [J]. *化工自动化及仪表*, 2024, 51(2): 301 – 309.
- Lv Xiuli, Lu Haibin, Hou Chunguang, et al. Improved YOLOv5s algorithm for steel surface defect detection[J]. *Control and Instruments in Chemical Industry*, 2024, 51(2): 301 – 309.
- [14] 张龙. 基于 YOLOX-S 深度学习算法的多路视频火灾烟雾检测系统研究 [D]. 太原: 中北大学, 2023.
- Zhang Long. Research on multi-channel video fire smoke detection system based on YOLOX-S deep learning algorithm[D]. Taiyuan, China: North University of China, 2023.
- [15] 彭森, 何连海, 马志华, 等. 钢结构桥梁对接焊缝缺陷的 TOFD 检测图像特征 [J]. *无损检测*, 2021, 43(12): 49 – 53.
- Peng Sen, He Lianhai, Ma Zhiha, et al. TOFD testing image characteristics of butt weld defects in steel structure bridges[J]. *Nondestructive Testing*, 2021, 43(12): 49 – 53.

第一作者: 胡伟, 高级工程师; 主要从事桥梁工程方面的工作; 418767066@qq.com。

通信作者: 刘朵, 博士, 正高级工程师; 主要研究预制装配式桥梁、施工与养护技术研发工作; ld238@jsti.com。

(编辑: 曲畅)

本文引用格式:

胡伟, 阮先虎, 金明东, 等. 基于深度学习算法的超声 TOFD 图像焊缝缺陷识别[J]. *焊接*, 2024(10): 55 – 60.

Hu Wei, Ruan Xianhu, Jin Mingdong, et al. Weld defect recognition in ultrasonic TOFD image based on depth learning algorithm[J]. *Welding & Joining*, 2024(10): 55 – 60.