

DOI:10.19344/j.cnki.issn1671-5276.2026.02.055

基于 YOLOv3 的夹砂玻璃钢管泄漏检测与定位研究

张江红

(安徽省水利水电勘测设计研究总院有限公司,安徽 合肥 244061)

摘要:为解决夹砂玻璃钢管因其多层复合结构和不规则表面,使得泄漏检测和定位难度加大的问题,提出一种改进单次注视目标检测算法第三版(YOLOv3)的泄漏检测模型,以及基于加速鲁棒特征的泄漏定位模型。YOLOv3 引入多边形包围框、特征图融合及并行最大池化等策略改进。加速鲁棒特征引入描述符降维、最近邻比值法及视差梯度约束的提纯算法。性能测试中,定位模型在 60°视角下的特征点匹配率与特征点重复率分别为 67.2%、58.9%。仿真测试中,泄漏检测模型的最高准确率 94.3%,定位模型的定位误差仅为 2.07 px。实验结果表明:研究所提出的泄漏检测和定位模型的检测精度均有显著提升。

关键词:YOLOv3;夹砂玻璃钢管;泄漏检测;定位;加速鲁棒特征

中图分类号:TP274 **文献标志码:**B **文章编号:**1671-5276(2026)02-0289-06

Research on Leakage Detection and Location of Sand-filled Glass Fiber Reinforced Plastic Pipe Based on YOLOv3

ZHANG Jianghong

(Anhui Water Conservancy and Hydropower Survey and Design Research Institute Co., Ltd., Hefei 244061, China)

Abstract:To overcome the increased difficulty in leak detecting and positioning of sand-filled FRP pipes due to the pipes' multi-layer composite structure and irregular surface, this study proposes a leak detection model improving "You Only Look Once Version 3" (YOLOv3), and a leak location model based on accelerated robust features. YOLOv3 introduces strategic improvements such as polygon bounding boxes, feature map fusion, and parallel maximum pooling. The accelerated robust features introduce descriptor dimensionality reduction, nearest neighbor ratio method and purification algorithm of disparity gradient constraint. The performance test displayed the feature point matching rate and feature point repetition rate of the positioning model under a 60° viewing angle as 67.2% and 58.9% respectively, the simulation test indicated the leakage detection model's highest accuracy as 94.3%, and the positioning error of the positioning model merely as 2.07 px. The experimental results demonstrate the significant improvement of detection accuracy of the proposed leak detection and positioning model.

Keywords:YOLOv3; sand-filled glass fiber reinforced plastic pipe; leak detection; positioning; acceleration robust characteristics

0 引言

夹砂玻璃钢管作为一种新型复合材料柔性管涵,是由树脂、纤维、石英砂缠绕而成的多层复合结构,具有高比强度、高比模量、优异的耐腐蚀性等优点,被广泛应用于石油、化工和市政给排水等工程中^[1]。然而,随着管道使用时间的延长,其泄漏问题日益严重。传统的检测方法如超声波和目视检查在复杂管道环境下的效率和精度有限,难以应对多种形式的泄漏检测需求。特别是夹砂玻璃钢管的多层结构和不规则表面使得泄漏检测和定位更加困难。工业管道的表面磨损、污染、光照

不均匀等因素,增加了漏检和误检的风险^[2-3]。近年来,得益于算法通用性强和背景误检率低的优点,YOLO 及其改进算法受到市场的青睐。同时,传统的泄漏定位算法虽然能够应对多视角和多尺度的变化,但在复杂管道环境下的匹配率和精度仍然受限,尤其是面对管道表面不规则变化时,其定位效果不佳。鉴于此,研究提出了基于边界多边形增强(you only look once version 3, YOLOv3)的夹砂玻璃钢管泄漏检测模型(you only look once version 3-boundary polygon enhancement, YOLOv3-BPE)和基于降维加速鲁棒特征的泄露点定位模型(speeded-up robust features-dimension

作者简介:张江红(1978—),男,河北赤城人,高级工程师,本科,研究方向为水工结构设计,HhongZj8865@163.com。

reduction and nearest neighbor ratio, SURF-DNR)。YOLOv3-BPE 模型通过多边形包围框、特征图融合及自适应非极大值抑制等技术,优化复杂表面上的检测性能。SURF-DNR 模型则融合了视差梯度约束和随机抽样一致性(random sample consensus, RANSAC)算法,以提升特征点匹配率和定位精度。

1 夹砂玻璃钢管泄漏检测与定位模型构建

1.1 基于YOLOv3-BPE的泄漏检测设计

夹砂玻璃钢管表面常呈现不规则的粗糙纹理,且由于夹砂层的存在,管道的强度和刚性较高^[4]。这种复合材料的多层结构导致其在泄漏时的表现形式更加复杂,泄漏点呈现为裂缝、孔洞或材料分层等多种形式^[5-6]。而YOLOv3能够在保证精度的前提下实现实时处理,对于要求高效、精确检测管道泄漏的场景尤为适用^[7]。因此,研究将利用YOLOv3构建夹砂玻璃钢管泄漏检测模型。

为更好地适应夹砂玻璃钢管的特性,研究将在YOLOv3的基础上进行相应改进,从而提高检测精度和对多样化泄漏形式的适应性。首先,优化检测框架,采用多个小检测框的并集来更精确地捕捉复杂表面的泄漏区域,将基础矩形框输出改进为多边形包围框,减少背景区域干扰。其次,增强特征提取层,提升网络对小尺度目标和复杂表面纹理的感知能力。最后,采用并行排列的最大池化层,分别提取管道在图像中的纵横坐标信息,更好地适应管道的条形分布特性。多边形包围框策略中,矩形包围框通过左上角 $(x_{\min}, y_{\min})$ 和右下角 $(x_{\max}, y_{\max})$ 坐标来定义,更改为多边形包围框,则使用一系列顶点坐标来表示多边形形状,见式(1)。

$$P = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

式中: P 表示多边形的顶点集合; (x_i, y_i) 则表示每个顶点的坐标, $i = 1, 2, \dots, n$ 。在特征图融合策略,特征图融合通过上采样操作,将深层特征图的分辨率提高到与浅层特征图一致,进行逐元素相加,见式(2)。

$$f_{\text{fused}} = f_s + \text{UpSample}(f_l) \quad (2)$$

式中: f_s 、 f_l 分别表示浅层、深层特征图;UpSample(f_l)表示对深层特征图 f_l 进行上采样,使其尺寸与 f_s 一致; f_{fused} 表示融合后的特征图。在并行最大池化步骤,对输入特征图在水平方向

和垂直方向分别进行最大池化操作,提取显著特征,见式(3)。

$$\begin{cases} F_{\text{horizontal}} = \max(F_{i,j}, F_{i,j+1}, \dots, F_{i,j+n}) \\ F_{\text{vertical}} = \max(F_{i,j}, F_{i+1,j}, \dots, F_{i+n,j}) \end{cases} \quad (3)$$

式中: $F_{\text{horizontal}}$ 、 F_{vertical} 分别表示水平、垂直方向池化后的特征图; i, j 表示特征图的像素位置; n, m 表示池化窗口的大小。使用自适应非极大值抑制(non-maximum suppression, NMS)替代传统NMS,通过动态调整交并比以筛选出重叠检测框中的最优框,避免多框重复检测同一目标,表达式见式(4)。

$$\text{NMS}(P) = \{P_i \mid \text{IOU}(P_i, P_j) < T_{\text{adaptive}}\} \quad (4)$$

式中: P_i 表示候选检测框; T_{adaptive} 表示自适应阈值。为优化模型在多维度的性能,在损失函数部分选择使用混合损失函数,同时优化误差,表达式见式(5)。

$$L_{\text{total}} = \lambda_1 L_{\text{location}} + \lambda_2 L_{\text{classification}} + \lambda_3 L_{\text{scale}} \quad (5)$$

式中: L_{location} 、 $L_{\text{classification}}$ 、 L_{scale} 分别表示位置、分类、尺度误差; λ_1 、 λ_2 、 λ_3 表示权重系数。因此,根据以上优化策略,改进后的泄漏检测模型结构如图1所示。




图1 改进后的泄漏检测模型结构

如图1所示,首先,输入的夹砂玻璃钢管图像通过Darknet53网络进行特征提取,逐层卷积获取深层次特征图,并通过并行最大池化提取横纵向特征。其次,通过特征图融合结合深层语义信息与浅层细节,确保大、小尺度泄漏的全面检测,并生成泄漏位置和管道状态的置信度及坐标。然后,候选检测框通过自适应NMS动态调整交并比阈值,筛选出最优检测框。最后,训练中使用混合损失函数优化模型参数,提升泄漏位置和类型的检测精度。

1.2 基于 SURF-DNR 的泄漏定位检测模型设计

完成泄漏检测后,泄漏点的精确定位是进一步提升管道安全性的重要步骤^[8]。为此,需要在保证高效计算的同时,能够适应不同尺度和旋转不变性的算法。加速鲁棒特征(speeded-up robust features, SURF)算法凭借其快速的特征提取能力,特别是在处理光照变化、尺度和旋转变换时表现优异,成为泄露定位的理想选择^[9-10]。因此研究将基于 SURF 算法构建泄露定位检测模型,以应对复杂环境下的泄漏检测需求。

为提高特征提取的速度与精度,同样将对 SURF 算法进行改进。第一,对 SURF 描述符进行降维,降低计算复杂度。第二,引入最近邻比值法,通过筛选最优匹配对,提升匹配的准确性。第三,结合基于视差梯度约束的 RANSAC 提纯算法,进一步去除误匹配点^[11]。在泄漏定位检测中, SURF 通过提取图像中的关键特征点及其对应的描述符来进行图像匹配。其描述符通常为 64 维或 128 维,但在实际应用中,这些维度中的部分信息是冗余的^[12-13]。因此研究将传统的矩形区域替换为圆形区域,并将其进行等分,如图 2 所示。




图 2 圆形区域描述符

如图 2 所示,圆形区域被划分为若干个扇形区域,每个扇区负责计算不同方向上的梯度信息,从而减少了特征点周围冗余信息的影响。通过计算每个扇区内的梯度方向和幅值,将描述符降维为式(6)。

$$D_{\text{reduced}} = \left[\sum_{i=1}^n |g_i|, \sum_{i=1}^n |\theta_i| \right] \quad (6)$$

式中: D_{reduced} 表示降维后的描述符; n 表示扇区数量; $|g_i|$ 、 $|\theta_i|$ 分别表示第 i 个扇区内的梯度幅值和方向。在最近邻比值法筛选最优的匹配点对策略中,对于每个特征点 p_i 在图像 A 中,找到其在图像 B 中的最近邻匹配点 p_{i1} 和次近邻匹配点 p_{i2} 。匹配比值的表达式见式(7)。

$$r = \frac{\|p_i - p_{i1}\|}{\|p_i - p_{i2}\|} \quad (7)$$

式中: r 表示匹配比值; $\|p_i - p_{ij}\|$ 表示特征点之间的欧氏距离。当比值 r 小于某个阈值时,即认为该匹配为有效匹配。为进一步去除匹配过程中的错误点,研究结合 RANSAC 算法,并引入了视差梯度约束对匹配点进行提纯。RANSAC 通过随机采样一部分匹配点,拟合出一个几何模型,接着根据拟合结果计算剩余点的匹配度,进而剔除离群点。加入视差梯度约束后,模型能够更精确地处理复杂的管道表面特征,确保匹配点对的稳健性。该算法的优势在于能够在大量噪声数据中找到符合大多数数据特征的模型,从而增强了模型的鲁棒性和准确性。在建立拟合模型后,计算所有数据点到模型的残差见式(8)。

$$\varepsilon_i = |y_i - (a \cdot x_i + b)| \quad (8)$$

式中: ε_i 表示第 i 个点的残差; a 、 b 分别表示参数; x_i 、 y_i 表示匹配点的坐标。如果残差 ε_i 小于给定的阈值,则该点被视为内点。重复采样和拟合过程,直到找到内点最多的模型。视差梯度约束进一步要求,在匹配过程中,视差值的变化要符合预定的梯度变化范围,以确保选取的点对满足一定的几何一致性。其表达式见式(9)。

$$\Delta d = \frac{\Delta y}{\Delta x} \quad (9)$$

式中: Δd 表示视差梯度; Δy 、 Δx 表示对应点的坐标差异。通过 SURF 描述符降维减少冗余信息、最近邻比值法提升匹配精度以及基于视差梯度约束的 RANSAC 提纯算法去除误匹配点,这 3 种改进策略共同作用,旨在提高 SURF 在泄漏定位中的准确性、鲁棒性及计算效率,适应复杂的夹砂玻璃钢管表面特性。

2 夹砂玻璃钢管泄漏检测与定位模型性能测试

2.1 算法性能测试

首先将对 YOLOv3-BPE 检测模型进行性能测试,选取 YOLOv3、快速区域卷积神经网络(faster region convolutional neural network, Faster R-CNN)^[14]以及 RetinaNet^[15]作为对比算法。使用 SFP Leak Detection 数据集,涵盖了约 5 000 张高分辨率图像,图像分辨率为 1 024×1 024 像素的管道在不同环境、不同材质和多样化泄漏形式下的图像。首先,在不同样本数量下的检测精度与结果如图 3 所示。




图3 泄漏检测精度与损失函数测试

图3(a)、图3(b)分别是模型在不同样本数量下的检测精度与损失函数测试结果。在图3(a)中,当样本量增加到2000时,4种模型的检测精度分别为87.5%、84.8%、89.7%、94.1%。在图3(b)中,YOLOv3-BPE的损失函数值在1000样本时为0.37,且随着样本量增加至2000时下降至0.32。

随后,针对SURF-DNR性能测试,选择SURF、尺度不变特征变换算法(scale-invariant feature transform, SIFT)^[16]以及方向快速和旋转二进制鲁棒独立特征算法(oriented FAST and rotated BRIEF, ORB)^[17]作为对比算法。各模型的测试结果如图4所示。




图4 特征点匹配测试

图4(a)、图4(b)分别是特征点匹配率与特征点重复率测试结果。在图4(a)中,4种模型的特征点匹配率在0°视角下分别为72.5%、74.3%、69.1%、77.4%。图4(b)中,在0°视角下,4种模型的重复率为62.3%、67.8%、61.3%、69.2%。SURF-DNR的较高重复率归功于其优化的特征点提取和描述子设计,特别是在视角变化时能够保持较高的一致性和稳定性,从而提升了重复率。

2.2 实际应用测试

1) 实验环境及设置

研究在实验室环境下搭建夹砂玻璃钢管泄漏检测仿真平台,以模拟实际工业环境中的泄露场景。实验采用了Basler acA1 920-155 um 高分辨率工业相机,其分辨率为1920×1200像素,用于捕捉管道表面泄漏区域的图像。配置了一套可调节的LED光源系统,其光照强度可在50~1500

lux 范围内调节,以模拟不同的光照条件,确保实验在多种环境光照下的适应性。此外,选用不同老化程度和表面特性的管道样本,包括平滑、粗糙和镀锌等表面,以代表工业中常见的多样材质与复杂表面条件,提升实验结果的代表性与模型的适用性。系统通过PC端搭载Intel i7处理器及NVIDIA GTX 1080 GPU运行仿真,结合特定的图像处理软件进行实时处理。

在实验流程中,首先利用Basler acA1 920-155 um 工业相机在不同光照条件下采集管道表面泄漏图像。通过LED光源调节环境光强,从50 lux的低光照到1500 lux的高光照逐级增加,获取在多种光照强度下的泄漏图像数据。每组图像经过背景噪声过滤及边缘强化预处理,以便提高模型输入的图像质量和检测准确性。然后将预处理后的图像输入模型进行泄漏检测与定位,通过模型输

出的检测框和定位坐标记录泄漏区域的位置及置信度,获取检测的准确率和定位偏差。最后,对比模型预测的泄漏位置与实际泄漏点,评估其精确度与稳定性,并记录每次实验的结果以用于后续分析。实验过程中,为全面评估模型的适用性,研究分别在光照条件、表面材质和泄漏类型等多个变量下进行实验。

实验过程中,为确保实验结果的准确性,每次测试仅固定一个变量并控制光照强度和泄漏类型,逐步测试模型在平滑表面、粗糙表面及镀锌表面上的检测效果。此外,实验选用裂缝、孔洞和材料分层3种常见泄漏类型,分别在不同光照和表面条件下进行检测,确保变量控制的全面性和实验的可靠性。实验1中,固定光照条件和泄漏类型,测试不同表面材质下模型的表现。实验2中,

固定表面材质和泄漏类型,测试不同光照条件下的检测效果。实验3中,固定光照条件和表面材质,测试不同泄漏类型对模型检测性能的影响。为模拟不同环境下的光照条件,实验设置了3种光照强度,良好光照为1500 lux,代表明亮的工业环境光线条件。较差光照为800 lux,对应常规室内光照。低光照为300 lux,模拟阴暗或夜间条件,测试模型在低光环境中的适应能力。

2) 定量测试实验结果

引入改进版 Efficient Det(improved efficientDet, I-EfficientDet)与神经架构搜索特征金字塔网络(neural architecture search feature pyramid network, NAS-FPN)^[18],验证模型在不同表面材质、光照条件及泄漏类型下的检测精度和实时性。每个模型在不同条件下运行10次,测试结果如图5所示。




图5 不同环境条件下的检测准确率与帧率测试

在图5(a)、图5(b)、图5(c)分别是模型在不同环境条件下的检测准确率与帧率测试结果。由图5可见,YOLOv3-BPE模型在不同环境条件下均具备较高的检测精度和定位准确性,尤其在光照变化较大的工业环境中表现突出。在图5(a)展示了模型在不同表面材质下的检测表现,YOLOv3-BPE在平滑表面上的检测准确率为92.8%,高于I-EfficientDet的89.5%和NAS-FPN的88.7%,表明其对平滑表面特征的捕捉和适应能力更强。图5(b)展示了不同光照条件下的检测效果,YOLOv3-BPE在良好光照下的准确率为94.3%,在较差和低光照下分别为86.7%和84.5%。表明尽管光照条件不足,研究所提模型仍能有效保持较高的检测稳定性。图5(c)展示了模型在裂缝和孔洞类型泄漏中的检测效果,YOLOv3-BPE在裂缝和孔洞检测中表现最佳,分别达到93.2%和89.8%。不同环境下的帧率均保持在30帧/s以

上,能够满足工业实时检测的要求。随后,基于该检测结果,使用相同的夹砂玻璃钢管泄漏仿真平台进行定位测试。摄像头角度和光源位置保持不变,增加了额外的红外线扫描器,以捕捉泄漏点位置的信息,结果如表1所示。

表1 泄露点定位实验

模型	定位精度/%	定位误差/px	匹配率/%	计算时间/ms
SIFT	92.6	3.52	83.0	148.7
ORB	90.3	4.15	80.3	108.9
SURF	93.5	3.09	85.1	132.1
SURF-DNR	95.1	2.07	88.5	122.3

如表1所示,SURF-DNR的定位精度达到了95.1%,同时具有最小的定位误差2.07 px和88.5%的匹配率,说明在复杂表面材质和多样光照条件下,SURF-DNR能够更准确、稳定地定位

泄漏点,适合具有较高精度要求的工业检测任务。而SIFT的定位精度为92.6%,但定位误差较大,为3.52 px,匹配率为83.0%,略逊于SURF-DNR。ORB的计算时间最短108.9 ms,但定位精度仅为90.3%,且定位误差为4.15 px,匹配率最低,不适合对精度有严格要求的应用。SURF的表现介于SIFT与SURF-DNR之间,定位精度为93.5%,误差为3.09 px。整体来看,SURF-DNR在保持较高实时性的同时,实现了更高的定位精度和更小的误差,充分满足了工业环境中对定位精度和实时性的双重需求。

3 结语

针对夹砂玻璃钢管的复杂泄漏检测与定位问题,研究提出了基于YOLOv3-BPE的泄漏检测模型和基于SURF-DNR的定位模型。性能测试表明,当样本量为2 000时,YOLOv3-BPE的检测精度为94.1%,损失函数值为0.32。SURF-DNR在0°视角下的特征点匹配率与重复率分别为77.4%、69.2%。仿真测试中,YOLOv3-BPE在平滑表面上的检测准确率为92.8%,帧率为33帧/s,在良好光照条件下的检测准确率为94.3%,帧率为34帧/s,充分验证了模型在复杂光照和材质条件下的适应性与实时性。随后,在定位仿真测试中,SURF-DNR的定位精度为95.1%,定位误差为2.07 px,匹配率为88.5%,计算时间为122.3 ms。结果表明:YOLOv3-BPE泄漏检测模型和SURF-DNR定位模型均具备良好的实时性能,适合应用于多样复杂环境下的夹砂玻璃钢管检测需求。尽管模型在复杂管道环境中表现优越,但在极端环境下仍存在改进空间。未来工作将同时利用GPU并行计算或其他硬件加速技术以进一步缩短计算时间,从而扩大模型在实际工业场景中的应用潜力。

参考文献:

- [1] 王清洲,孙言文,肖成志,等. 基于层间分离的玻璃钢管夹砂管渐进损伤仿真与强度计算[J]. 振动与冲击, 2021,40(18):164-173.
- [2] 杨理践,石萌,耿浩. 长输油气管道内检测技术[J]. 沈阳工业大学学报,2024,46(5):676-684.
- [3] 王清洲,孙颖晖,薛晓,等. 玻璃钢夹砂管涵夹砂层细观断裂数值模拟[J]. 材料导报,2024,38(17):298-307.
- [4] 王伟,柳谔林,史喜珍,等. 服役后玻璃钢夹砂管力学性能及断口结构研究[J]. 水利水电技术(中英文), 2021,52(4):202-208.

- [5] 彭道刚,潘俊臻,王丹豪,等. 基于改进YOLO v5的电厂管道油液泄漏检测[J]. 电子测量与仪器学报, 2022,36(12):200-209.
- [6] 刘淑艳,崔洪军,张朝阳,等. 多夹砂层玻璃钢夹砂管弯曲性能及破坏模式[J]. 工程塑料应用, 2021, 49(7):126-131.
- [7] MARTINEZ - ALPISTE I, GOLCARENARENJI G, WANG Q, et al. A dynamic discarding technique to increase speed and preserve accuracy for YOLOv3[J]. Neural Computing and Applications, 2021, 33(16): 9961-9973.
- [8] 游小玲,蔡永香,王荟奥,等. FEDDR:一套实用的地下排水管道缺陷智能检测系统[J]. 科学技术与工程,2023,23(7):2932-2944.
- [9] ANZID H, LE GOIC G, BEKKARI A, et al. A new SURF-based algorithm for robust registration of multimodal images data[J]. The Visual Computer, 2023, 39(4): 1667-1681.
- [10] 张蕾,石岩,卢文雍,等. 基于SURF-OKG特征匹配的三维重建技术[J]. 光学精密工程,2024,32(6): 915-929.
- [11] 白晓虎,杨瑞峰,郭晨霞,等. 基于SIFT和自适应阈值的RANSAC算法的茶饼图像配准研究[J]. 中国农机化学报,2024,45(10):193-198.
- [12] 陈贤儿,梁丹,傅云龙,等. Harris与SURF特征点检测的手术器械机器视觉识别方法[J]. 传感器与微系统,2023,42(2):118-121.
- [13] 洪鹏程,唐垚,任重. 基于SURF分割圆形区域的图像拼接[J]. 电讯技术,2021,61(11):1424-1430.
- [14] REN S Q, HE K M, 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.
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2999-3007.
- [16] LOWE D G. Distinctive image features from scale-invariant keypoints[J]. International Journal of Computer Vision, 2004,60(2):91-110.
- [17] RUBLEE E, RABAU D V, KONOLIGE K, et al. ORB: an efficient alternative to SIFT or SURF[C]//2011 International Conference on Computer Vision. Barcelona, Spain: IEEE, 2011:2564-2571.
- [18] GHIASI G, LIN T Y, LE Q V. NAS-FPN: Learning scalable feature pyramid architecture for object detection[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA: IEEE, 2019:7029-7038.

收稿日期:2024-10-22