

## 基于改进 YOLOv11 的地铁暗挖施工作业面裂缝检测

赵树林<sup>1,2</sup> 李元凯<sup>1,2</sup> 李 冬<sup>3</sup> 翟鸿漾<sup>4</sup> 张 涛<sup>4</sup> 王 金<sup>4</sup>  
ZHAO Shulin LI Yuankai LI Dong ZHAI Hongyang ZHANG Tao WANG Jin

## 摘 要

暗挖法在城市地下空间开发中应用广泛,施工过程中出现的裂缝等异常现象可能会导致事故发生。传统的异常检测方法存在成本高、效率低、易受人为因素影响等局限性。文章提出了一种基于 YOLOv11 的暗挖施工作业面异常检测方法 YOLO-AT,通过引入可变形注意力模块(DA)和自适应细粒度通道注意力模块(AFGC),提升了模型对不规则裂缝的特征提取能力和检测精度。实验结果表明,YOLO-AT 在 Precision、Recall 和 mAP50 等指标上均优于 YOLOv5n、YOLOv8n 和 YOLOv11n,能够准确检测出不同形态和大小的裂缝,为暗挖施工安全提供了有效的监测手段。

## 关键词

裂缝检测;暗挖法;改进 YOLOv11;施工安全监测

doi: 10.3969/j.issn.1672-9528.2025.09.008

## 0 引言

暗挖法如今已广泛应用于城市地下空间开发,尤其是在地铁、隧道、地下管廊等项目中。与传统明挖法相比,暗挖法具有避免地面交通影响、减少环境扰动等特点,在现代都市地下工程中应用广泛<sup>[1]</sup>。然而,尽管暗挖施工技术已被广泛采用,但在施工过程中如何实时监测作业面状态,仍存在诸多挑战。暗挖施工中的常见异常包括鼓包、涌水、土体剥离和裂缝等,这些问题如果得不到及时检测和处理,可能会导致工程进度延误、结构安全隐患甚至施工事故。尤其是裂缝的出现,可能会导致鼓包等事故的发生。其扩展将影响隧道的稳定性,甚至在极端情况下可能导致大规模塌方<sup>[2]</sup>。因此,实时监测施工作业面并尽早发现裂缝,成为确保暗挖施工安全的关键。

传统的异常检测方法主要依赖人工巡检、传感器监测等手段<sup>[3]</sup>。尽管传感器可以提供精确的位移和应力数据,但其成本高昂且布设复杂,无法覆盖大规模的施工区域;人工巡检虽然能够灵活应对现场情况,但效率低、受限于环境复杂性,且容易受到人为因素的影响。与此同时,随着计算机视觉和深度学习技术的飞速发展,基于图像的智能检测成为暗

挖施工裂缝检测的重要方向<sup>[4-6]</sup>。

目标检测算法如 YOLO (you only look once) 系列<sup>[7-8]</sup>因其高效和实时性的优势,已被应用于多个行业的自动化检测中。YOLOv11 在前代模型的基础之上,在特征提取能力,速度优化和精度提升方面进行了多项创新,尤其是在复杂环境下的鲁棒性和实时性得到了显著增强,更加适合于施工过程监测应用。为了解决暗挖场景下因图像整体灰暗导致的裂缝不易精准识别的难题,本文在 YOLOv11 算法的基础上,提出了 YOLO-AT。通过引入可变形注意力<sup>[8]</sup>和自适应细粒度通道注意力机制<sup>[9]</sup>,根据输入数据动态调整注意力区域,提升模型对于裂缝的特征提取能力,尤其在复杂背景下的表现更为突出,并且能够在保持较高检测精度的同时减少计算开销。可用于暗挖施工场景下裂缝的快速精准识别,支撑施工智能监管和预警等。

## 1 YOLO-AT

## 1.1 YOLOv11

YOLOv11 是最新的目标检测模型,延续了 YOLO 系列轻量、高效、准确的特点,并在前代版本的基础上实现了重要升级。在主干网络中引入了新的 C3k2 和 C2PSA 模块,增强了模型的特征提取能力,尤其是在复杂环境下提高了对小目标的检测精度。在保持高精度的同时,YOLOv11 通过改进 GPU 计算效率和模型架构,将推理速度提升了 25%,满足了实时检测的需求。但是 YOLOv11 在识别鼓包裂缝这样的不规则目标时,面临着裂缝形状复杂多样、目标与背景相似以及全局上下文信息利用不足等挑战。因此本文通过引入可变形注意力模块(deformable attention module, DA)和自适应细粒度通道注意力模块(adaptive fine-grained channel attention,

1. 北京市轨道交通建设管理有限公司 北京 100068
  2. 城市轨道交通全自动运行系统与安全保障北京市重点实验室 北京 100068
  3. 济南市勘察测绘研究院 山东济南 250013
  4. 北京工业大学城市交通学院 北京 100124
- [基金项目] 北京市轨道交通建设管理有限公司“双创”基金项目(SCJJ2023002)

AFGC)，YOLO-AT 能够动态调整注意力区域，增强对不规则裂缝的特征提取能力，从而提升检测精度。这两种注意力机制的灵活性和数据依赖性使模型能够有效应对不规则裂缝的复杂形状和变形特性，同时增强对全局上下文信息的利用，进一步提升模型的表现，如图 1 所示。




图 1 改进后的 YOLO-AT 网络结构图

## 1.2 可变形注意力模块 (DA)

可变形注意力机制旨在解决传统自注意力机制计算复杂度高和无法根据输入数据动态调整的问题。可变形注意力的核心思想是通过数据依赖的方式选择自注意力机制中的 key 和 value 的位置，从而使得模型能够动态地关注输入图像中的重要区域，而不是像传统自注意力机制对所有 patch 进行全局或固定的局部注意力计算。可变形注意力首先在特征图上生成一组均匀分布的参考点。这些参考点的位置是固定的，通常是通过下采样得到的。然后通过一个轻量级的子网络生成每个参考点的偏移量。这个子网络以查询特征 (query features) 作为输入，输出每个参考点的偏移量。根据生成的偏移量，对特征图进行采样，得到变形后的 key 和 value。采样过程使用双线性插值，确保可微性。最终使用变形后的 key 和 value 进行标准的自注意力计算，最终得到输出特征。

在 YOLOv11 的骨干网络的最后一层 C2PSA 后引入可变形注意力模块，可以显著提升对不规则裂缝目标的提取效果。具体体现在可变形注意力机制能够根据来自 C2PSA 的特征图动态调整 key 和 value 的位置，使得模型能够更灵活地关注裂缝的不规则形状。对于弯曲、分叉等复杂形状的裂缝，可变形注意力机制可以通过偏移量生成网络将注意力集中在裂缝的关键区域，从而提升边界框的拟合精度。另外，可变形注意力机制不仅能够关注局部特征，还能够通过变形后的 key 和 value 捕捉全局上下文信息。在检测细长裂缝时，可以通过全局上下文信息推断裂缝的整体走向和分布，提升对裂

缝整体结构的理解。这将使 YOLOv11 在裂缝检测任务中表现更加出色。

## 1.3 自适应细粒度通道注意力模块 (AFGC)

自适应细粒度通道注意力通过利用相关计算来获取相关

矩阵，捕捉到了不同粒度的全局信息和局部信息之间的相互依赖关系。促进了全局信息和局部信息之间的交互，从而能够在不同粒度级别更精确地描述它们的相关性。最终引入了可学习的因子来动态融合全局和局部信息，促进通道权重的自适应分配并增强了对不规则裂缝的检测性能。具体而言，首先，对输入

的特征图进行全局平均池化，生成一个通道描述符，用于捕捉全局信息。然后通过使用带状矩阵进行局部通道交互，捕捉局部信息。带状矩阵的作用是限制局部信息的范围，减少模型参数的同时，保留局部通道的交互。同时使用对角矩阵捕捉所有通道之间的依赖关系，增强全局信息的表示能力。最终引入可学习因子，动态融合全局和局部信息，生成最终的通道权重。

裂缝形状不规则且尺度变化大，给裂缝检测带来了挑战。通过在 YOLOv11 的 3 个检测头前引入 AFGC 注意力模块，捕捉局部细节和全局信息，动态分配特征权重，提升了对不规则裂缝的检测精度，同时通过多尺度特征融合优化了不同尺度裂缝的检测能力，减少漏检和误检，显著提升了模型的检测性能。

## 2 实验与结果分析

### 2.1 数据集介绍

本文的视频数据源自北京地区某暗挖施工作业面的现场监控数据。通过对监控视频进行间隔帧提取，筛选出带有鼓包裂缝的作业面的图像，经过平移、镜像、旋转、添加椒盐噪声、马赛克等数据扩增方法，最终共获得 911 张图像数据。其中 728 张用于训练，183 张用于测试。图片使用 Labellmg 进行标定。

### 2.2 实验环境配置与评价指标

本文的实验环境是在 Windows10 操作系统下基于 Py-Torch 深度学习框架的软硬件环境，具体参数设置如表 1 所示。

表1 参数配置

| 参数名称    | 版本                               |
|---------|----------------------------------|
| 操作系统    | Windows10                        |
| CPU     | Intel(R) Core (TM) i7-10700F     |
| GPU     | NVIDIA GeForce RTX 4070 Ti SUPER |
| CUDA    | 12.1                             |
| PyTorch | 2.2.1                            |
| Python  | 3.9                              |

为保证算法对比的公平性,本文所有的实验都基于开源的 Ultralytics 框架下进行,该框架提供了一系列流行的目标检测模型,包括 YOLOv5、YOLOv8、YOLOv11 等。训练轮数统一为 300 轮,训练批次为 32,采用 SGD 优化器,采用精确率(Precision)、召回率(Recall)和 mAP50 三个常用的目标检测指标评价网络性能。

### 2.3 YOLO-AT 网络消融实验

为了评估可变形注意力模块(DA)和自适应细粒度通道注意力模块(AFGC)对 YOLOv11n 模型性能的影响。该消融实验通过逐步引入 DA 和 AFGC,对比了模型在 Precision、Recall 和 mAP50 三个指标上的表现。消融实验结果如表 2 所示。

表2 YOLO-AT 消融实验结果

| 模型               | Precision/% | Recall/% | mAP50/% |
|------------------|-------------|----------|---------|
| YOLOv11n         | 93.1        | 96.2     | 98.0    |
| YOLOv11n+DA      | 94.2        | 97.1     | 98.9    |
| YOLOv11n+AFGC    | 94.3        | 97.5     | 98.9    |
| YOLOv11n+DA+AFGC | 95.0        | 96.7     | 99.1    |

实验结果显示,在 YOLOv11n 模型的基础上,引入 DA 模块和 AFGC 模块后,模型的检测能力都有提升。同时引入 DA 和 AFGC 后,DA 动态调整注意力区域,聚焦于裂缝关键部位,减少背景干扰;AFGC 增强局部特征提取和多尺度特征融合,提升对不规则裂缝的检测精度。两者结合进一步提升了模型的整体性能,模型的 Precision 和 mAP50 达到最高值,分别为 95.0% 和 99.1%,Recall 较基线模型也有 0.5% 的提升。

### 2.4 检测结果对比实验

为验证本文提出的改进算法的优势,以 YOLOv5n、YOLOv8n 以及 YOLOv11n 作为对照,在相同的数据集上以相同的参数进行对比试验。表 3 展示了本文所提出的 YOLO-AT 模型与其他典型目标检测网络的性能对比。YOLO-AT 的 Precision 比 YOLOv11n 提高了 1.9%,Recall 提高了 0.5%,

mAP50 提高了 1.1%。这表明 YOLO-AT 在检测暗挖施工作业面鼓包裂缝具有更高的准确性和鲁棒性。

表3 典型目标检测模型性能对比结果

| 模型       | Precision/% | Recall/% | mAP50/% |
|----------|-------------|----------|---------|
| YOLOv5n  | 92.7        | 95.6     | 97.7    |
| YOLOv8n  | 93.2        | 96.0     | 97.5    |
| YOLOv11n | 93.1        | 96.2     | 98.0    |
| YOLO-AT  | 95.0        | 96.7     | 99.1    |

图 2 展示了 YOLO-AT 网络在不同阶段的鼓包裂缝检测结果。阶段一裂缝初现,此时裂缝形态细长难以准确识别;阶段二裂缝初步扩展;阶段三裂缝继续扩展,开始出现放射状裂缝;阶段四纵向裂缝和放射状裂缝扩展到最终形态。YOLO-AT 能够准确地检测出不同形态和大小的裂缝,包括细长裂缝、放射状裂缝等。在裂缝开展的初期,YOLO-AT 就能够准确地检测出细小的裂缝,为早期预警提供了有力支持。




图2 基于 YOLO-AT 网络的鼓包裂缝检测结果

## 3 结语

本文针对暗挖施工作业面裂缝检测的挑战,提出了一种基于 YOLOv11 的改进算法 YOLO-AT。通过引入可变形注意力模块(DA)和自适应细粒度通道注意力模块(AFGC),YOLO-AT 能够动态调整注意力区域,增强对不规则裂缝的特征提取能力,从而提升检测精度。实验结果表明,YOLO-AT 在多个性能指标上均优于现有的 YOLO 系列模型,能够准确检测出暗挖施工作业面中的鼓包裂缝,为施工安全提供了有效的检测手段。

### 参考文献:

- [1] 张龙,高菊茹,袁玮.地铁区间暗挖法施工技术比选[J].隧道建设(中英文),2019,39(S1):404-410.
- [2] 刘璇.地铁隧道衬砌结构裂缝演化及其对结构安全性影响研究[D].北京:北京交通大学,2018.



# 基于少量传感器的高山滑雪动作识别研究

张浩<sup>1</sup> 乔慧<sup>1</sup> 潘若芊<sup>1</sup>

ZHANG Hao QIAO Hui PAN Ruoqian

## 摘要

针对多传感器系统在高山滑雪训练中增加运动员负荷及降低识别效率问题,文章提出了一种基于特征权重和冗余分析的少量传感器配置策略。通过融合动作要点和人体约束,构建滑降、回转等5类基础动作类库,结合17节点传感器数据实验表明:随机森林算法下,单传感器动作识别精度达91.39%;进一步通过ReliefF算法权重分配与互信息冗余计算,确定传感器精简为6个关键节点后,识别精度提升至98.11%。实验显著降低了设备负担并提升了训练指导效率,为高山滑雪训练提供科学化的动作识别方案。

## 关键词

高山滑雪; 动作类库; 动作识别; 传感器精简策略

doi: 10.3969/j.issn.1672-9528.2025.09.009

## 0 引言

冬奥会比赛项目中,高山滑雪以运动速度快、视觉刺激强及动作技巧足等特点深受大众喜爱<sup>[1]</sup>,但由于我国在该项目研究少、起步晚等<sup>[2]</sup>,高山滑雪项目的比赛成绩一直不够理想。因此,高山滑雪运动员亟须科学化的训练指导方法以提升比赛成绩。动作识别作为运动分析中的重要研究方向,广泛应用于体育训练、动作指导及健身康复等,对运动员的训练指导具有重要研究意义。目前,高山滑雪动作识别研究主要依赖于高速摄像机和可穿戴传感器<sup>[3]</sup>。摄像机数据主要是视频、图片等,对硬件配置、环境光照等要求较高。而传感器所采集的数据主要是加速度、欧拉角、四元数等,可通过人体动作姿态复现及关节贡献度分析等对滑雪运动

员动作进行指导,数据抗干扰能力强、对环境要求低、姿态准确性高。

目前针对增加可穿戴传感器以丰富运动员动作姿态数据的研究较多,例如篮球、乒乓球等,通过在训练者重要关节增加传感器数量,完成更细致的动作指导。例如闫继龙<sup>[4]</sup>研究惯性感知乒乓球动作识别时,将传感器绑定在四肢、髌等9个位置处,对运动员进行训练指导。但实际上,训练指导时并不是传感器佩戴数量越多越好。关节佩戴传感器数量越多,既会对运动员的动作施展造成一定的干扰,也会增加姿态识别数据的传输和存储的负担。因此,合理有效的少量传感器配置策略对高山滑雪动作识别及后续训练指导具有重要的研究意义。

## 1 高山滑雪动作类库的构建

动作类库是研究高山滑雪动作识别的基础,其完整性和

1. 青岛工程职业学院 山东青岛 266112

- [3] 苑玮琦,薛丹.基于机器视觉的隧道衬砌裂缝检测算法综述[J].仪器仪表学报,2017,38(12):3100-3111.
- [4] 付春双.基于机器视觉的地铁隧道表面裂缝及渗水检测系统研究[D].成都:西南交通大学,2023.
- [5] 薛亚东,李宜城.基于深度学习的盾构隧道衬砌病害识别方法[J].湖南大学学报(自然科学版),2018,45(3):100-109.
- [6] 龙学军,张杰,谭志国.基于视觉的隧道裂缝检测技术研究[J].现代计算机,2021,27(30):94-98.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[EB/OL]. (2016-05-09) [2024-05-26]. <https://doi.org/10.48550/arXiv.1506.02640>.

- [8] XIA Z F, PAN X R, SONG S J, et al. Vision transformer with deformable attention[EB/OL]. (2022-05-24) [2024-09-26]. <https://doi.org/10.48550/arXiv.2201.00520>.
- [9] SUN H, WEN Y, FENG H J, et al. Unsupervised bidirectional contrastive reconstruction and adaptive fine-grained channel attention networks for image dehazing[J]. Neural networks, 2024, 176: 106314.

## 【作者简介】

赵树林(1975—),男,辽宁大连人,本科,高级工程师,研究方向:轨道交通建设管理, email: yuankailee@163.com.

(收稿日期:2025-02-14 修回日期:2025-07-19)