

一种边坡位移视觉测量装置与方法研究*

宋旻辰¹ 宓超^{1,2} 刘熠¹ 沈阳^{2,3}

(1. 上海海事大学物流工程学院 上海 201306; 2. 上海海瞞智能科技有限公司 上海 201306;

3. 上海海事大学高等技术学院 上海 201306)

摘要:针对传统边坡位移监测方法成本高昂,对环境要求高等问题,提出了一种低成本、高精度的边坡位移视觉测量装置及其方法。首先,在监测场景中部署高精度摄像机和特制标志物,利用改进的YOLOv8-Pose算法实现对标志物关键点的初步识别。随后,采用亚像素提取技术对标志物关键点进行处理,以获得其亚像素级别的精确坐标。接着,通过比较不同时刻关键点的坐标偏移量,计算标志物的像素位移变化。最后,结合已知标志物的几何尺寸,通过尺度转换方法计算实际位移变化,从而实现对边坡位移的精确监测。为验证该方法的实际应用效果,选取贵州省某高速公路的边坡进行了现场监测实验。实验结果表明,该视觉测量方法在边坡位移监测中具有良好的精度表现。与全站仪监测结果比较,水平位移的准确率达到90.43%,竖直位移的准确率为91.58%,均超过90%,充分验证了该方法在实际工程应用中的可行性和有效性。

关键词:高速公路边坡;位移视觉测量;YOLOv8-Pose;关键点识别;亚像素提取

中图分类号: TN06;TP391.4 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on a visual measurement device and method for slope displacement

Song Yangchen¹ Mi Chao^{1,2} Liu Yi¹ Shen Yang^{2,3}

(1. School of Logistics Engineering, Shanghai Maritime University, Shanghai 201306, China; 2. Shanghai SMU Vision Co. Ltd., Shanghai 201306, China; 3. Higher Institute of Technology, Shanghai Maritime University, Shanghai 201306, China)

Abstract: Aiming at the problems of high cost and high environmental requirements of traditional slope displacement monitoring methods, a low-cost and high-precision slope displacement visual measurement device and its method are proposed. First, a high-precision camera and a special marker are deployed in the monitoring scene, and the improved YOLOv8-Pose algorithm is utilized to realize the initial recognition of the key points of the marker. Subsequently, a sub-pixel extraction technique is used to process the key point of the marker to obtain its precise coordinates at the sub-pixel level. Next, the pixel displacement change of the marker is calculated by comparing the coordinate offsets of the keypoints at different moments. Finally, the actual displacement change is calculated by the scale conversion method in combination with the known geometric dimensions of the markers, so as to realize the accurate monitoring of slope displacement. In order to verify the practical application effect of the method, this paper selects the slope of a highway in Guizhou Province for on-site monitoring experiments. The experimental results show that the visual measurement method has good accuracy performance in slope displacement monitoring. Compared with the monitoring results of total station, the accuracy of horizontal displacement reaches 90.43%, and the accuracy of vertical displacement is 91.58%, which are more than 90%, fully verifying the feasibility and effectiveness of the method in practical engineering applications.

Keywords: highway slopes; visual measurement of displacement; YOLOv8-Pose; key point identification; sub-pixel extraction

0 引言

高速公路作为现代交通网络的重要组成部分,其安全运营对于保障人民生命财产安全和促进社会经济发展具有重要意义。特别是在山区高速公路的建设中,通常需要开挖山体,破坏原有的地质条件,在高速公路两边形成路堑边坡,而边坡的稳定性直接关系到道路的安全使用和寿命。由于地质条件的复杂性和不确定性,边坡可能发生形变,从而引发滑坡或塌方等严重地质灾害。因此,对高速公路边坡进行位移监测是解决边坡稳定性问题的关键措施^[1]。

当前,边坡位移测量与实时监测在各类场景中已有广泛研究。Prasetya 等^[2]使用机器人全站仪(real-time system, RTS)对隧道修复斜坡进行监测。虎勇等^[3]利用机电系统(micro-electro-mechanical system, MEMS)姿态传感器实时计算边坡变化,实现边坡表面位移监测。Mazzanti 等^[4]结合多时相三维激光扫描结果,建立了意大利北部 Baldi 滑坡演化模型。Wang 等^[5]应用光纤布拉格光栅技术(fiber bragg gratings, FBG),在温州滑坡监测项目中分析现场监测数据预测潜在滑动区。Alameda-Hernandez 等^[6]利用近距离地面数字摄影测量技术(close-range terrestrial digital photogrammetry, CR-TDP)监测弱叶面岩质边坡的稳定性。Wang 等^[7]结合 GPS 监测数据与精密单点定位(precise point positioning, PPP)后处理方法,探索了毫米级精度的滑坡监测。Mateos 等^[8]结合摄影测量与永久散射体合成孔径雷达干涉测量技术(persistent scatterer interferometric synthetic aperture radar, PS-InSAR)分析了滑坡运动与空间和时间的相关性。现有方法在监测精度和自动化程度方面取得了显著进展,但大多依赖人工测量以及精密检测设备,成本高昂,且对环境要求高,恶劣环境难以部署。

基于机器视觉的目标检测技术以其自动化、易部署、高精度以及低成本的潜力,正逐步取代传统监测技术^[9]。目标检测技术分为两种,经典的目标检测算法与依赖深度学习的目标检测算法。经典的目标检测算法为使用分类器对目标部分和非目标部分进行检测分类,其中定向梯度直方图(histogram of oriented gradients, HOG)+支持向量机(support vector machine, SVM)的识别模式应用较为广泛。Mi 等^[10]设计了一种结合优化的 HOG 算法和 PNP 算法(perspective-n-point)的三维位移测量方法并验证该方法在基坑监测中有良好的效率和实时性。基于深度学习的目标检测方法可以分为单阶段检测算法和双阶段检测算法两大类。单阶段方法,如 YOLO、SSD 和 RetinaNet,直接在整个图像上一次性完成目标的检测和分类^[11];双阶段方法,如 Faster R-CNN 和 Mask R-CNN,

先生成候选区域,再进行详细的分类和定位。而关键点检测^[12]被看作是目标检测的一个扩展或细化,旨在从图像中检测出代表物体或场景重要特征的关键点。Liang 等^[13]引入了一种自适应中心关键点选择方法(adaptive center keypoint selection network, ACKSNet)用于解决目标检测任务中关键点不匹配产生的识别问题。Yu 等^[14]将遥感图像中小型车辆作为背景中的关键点进行鲁棒检测。由于 YOLO 算法网络模型简单且识别效率高,在关键点检测方面具备良好的应用效果。Wang 等^[15]提出了基于关键点回归策略和角度损失的 YOLOv4,提高了 YOLOv4 算法对关键点检测的精度。Pranavan 等^[16]应用改进的 YOLOv7 关键点检测模型预测人体摔倒时的姿态。近年来, YOLOv8-Pose 算法显著提升了关键点检测精度, Wang 等^[17]使用改进的 YOLOv8-Pose 算法来增强多模态机器人的感知和执行能力。Yuan 等^[18]将 YOLOv8-Pose 算法应用于面部穴位检测。尽管关键点检测算法可以在图像中直接预测并定位关键点位置,得到关键点的坐标,但定位的精度仅能达到像素级,直接应用不能满足边坡检测的精度要求,所以需要进一步提升关键点识别精度。

在图像处理领域,亚像素提取技术作为一种提高识别精度的方法被广泛应用于各种场景。常用的亚像素提取方法有灰度重心法、插值法、边缘检测算法等。其中双三次插值法相较于其他方法具有出色的平滑性、细节保留能力和准确性,能够得到精准的亚像素级别识别结果。贺强旅等^[19]提出一种基于双三次插值和高斯拟合的激光线条亚像素提取方法。郑心草等^[20]实现了经典双三次插值算法的非局部拓展。

针对上述不足以及相关研究,本研究考虑结合关键点检测算法以及亚像素提取算法提出了一种边坡位移视觉测量装置与方法。首先通过改进的 YOLOv8-Pose 算法实现标志物关键点的初步定位,然后利用亚像素提取算法获得标志物关键点的亚像素级别坐标,并计算标志物在不同时刻的关键点坐标偏移,通过尺度转换得到实际位移变化,从而实现高精度高速公路边坡位移检测。相比现有边坡监测方法,本方法具备显著的低成本和强环境适应性优势:无需精密仪器或复杂传感设备,仅凭普通摄像设备及靶标即可完成关键点定位与位移检测,部署简便,适用于复杂地形。以监测 1 km 边坡为例,传统全球导航卫星系统(global navigation satellite system, GNSS)监测设备成本超 1 万美元,且体积大、安装困难。而本研究设备小巧,成本低廉:一台带云台的相机约 1 000 美元,每个标志物成本不足 10 美元,每隔 10 m 安装一个标志物,总成本仅约 2 000 美元,仅为 GNSS 成本的 20%。换言之,使用本研究方法,仅一套 GNSS 系统的费用即可监测 10 个边坡,大幅降低监测成本。

本研究方法相比 YOLOv5n-Pose、YOLOv7n-Pose 等主流关键点检测算法,在准确率、召回率和平均精度均值(mean average precision, mAP)指标上表现出显著提升。与基线模型 YOLOv8n-Pose 相比,本研究方法的准确率提高了 4.33%,召回率提高了 3.82%,mAP 提升了 7.78%,展现出优异的关键点识别性能。此外,通过引入亚像素提取技术,将关键点像素坐标精度提高至 0.001 个像素,位移监测精度提升至 0.01 mm 级,极大地增强了边坡监测领域的监测精度。

1 高速公路边坡位移测量方案

本研究设计了一套完整的高速公路边坡位移测量方案,通过在监测场景下部署相机和特殊规格标志物,保证本研究提出的位移测量方法的可行性。

1.1 相机设置

为了确保监测数据的准确性和有效性,本研究选用带云台的高精度变焦摄像机通过水泥浇筑固定于远离监测区域的地基稳定位置,尽可能保证相机不受外部环境因素的影响而产生位移,确保相机在长期监测过程中稳定可靠,并保障其视角能够广泛覆盖监测区域,不留盲区,以获得全面的监测数据。同时采取高频采样策略来保证图像样本的质量,通过高频采样确保相机不同时刻采集的图像数据有效可靠,即便存在残缺或无效的样本数据,也不会对后续识别解算位移变化量产生影响。

1.2 标志物设计

为了实现边坡监测系统的高精度和高效性,并确保相机能够清晰准确地采集到标志物信息,本研究采用一个由 5 行 5 列黑白方格组成的棋盘作为标志物,每个小方格的边长为 30 mm,如图 1 所示。这种标志物具有独特的几何图案和高对比度,在图像处理和特征识别中表现出优异的性能。棋盘格每个黑白十字交叉点即为标志物的关键点,每个标志物上有多个关键点,有效避免单一关键点被遮挡或误识别导致的监测结果误差问题。通过监测这些关键点随时间产生的位移变化,可以实时反映边坡位移情况。多个关键点也意味着每个标志物具有多组位移变化结果,通过平均滤波处理可以确保每个标志物的位移变化更加准确和可靠。

为实现位移监测系统对边坡全面的监测,标志物需沿着边坡均匀分布,本研究选择在边坡的所有坡面每隔 10 m 安装一个标志物,确保标志物正对相机,保证监测精度的同时确保标志物覆盖整个监测区域,设备布置效果如图 2 所示。鉴于夜间光照条件较差可能对监测结果产生影响,本研究设计的监测系统主要针对白天进行工作。系统通常设置为每天 8:00~17:00,每隔 0.5 h 采




图1 棋盘格标志物

Fig. 1 Traditional measurement programs

集 1 次监测数据,以确保监测结果的准确性和实时性。这种设计充分考虑了光照条件对标志物识别的影响,避免了夜间环境变化可能带来的干扰。




图2 设备布置效果

Fig. 2 Equipment layout effect diagram

2 算法流程

在上述高速公路边坡位移测量方案的基础上,本研究设计了结合改进的 YOLOv8-Pose 算法与亚像素提取技术的高速公路边坡位移测量方法。首先,相机在相同预置位不同时刻高频采样,捕获边坡上每个标志物的图像。相机完成图像采集任务后,采用改进的 YOLOv8-Pose 标志物关键点检测方法进行标志物关键点的预测与识别,获取标志物每个关键点在图像中的像素坐标。然后使用亚像素提取算法获取标志物所有关键点的亚像素级别精确坐标。接着,比较当前时刻和上一时刻每个标志物关键点的像素偏差,通过平均滤波整合每个标志物所有关键点的像素位移,得到标志物的偏移量。最后,通过二维和三维位移之间的尺度因子转换,将标志物的二维位移转化为实际位移,得到边坡位移监测结果。

2.1 改进的 YOLOv8-Pose 标志物关键点检测方法

当图像采集结束后,需对图像中标志物及其关键点进行定位。本研究采用改进的 YOLOv8-Pose 关键点检测方法对标志物上的关键点进行识别,得到每个关键点在图像中的像素坐标。

YOLOv8-Pose 是 YOLOv8 算法中同时实现目标框检测和关键点检测的模型,YOLOv8-Pose 的目标任务是在完成目标检测的基础上进行图像关键点的预测,在检测精度和速度方面表现良好。然而,在对小目标进行检测时,由于小目标的特征不够明显,模型难以准确识别和定位关键点。此外,模型在识别不同尺度的目标时也存在

局限性。而本研究的标志物关键点较小,且边坡不同位置的标志物在图像中的大小不一,所以必须对原有模型进行改进以实现相机画面中棋盘格标志物关键点的精

确检测与定位。对此,本研究在 YOLOv8-Pose 的基础上进行了改进,改进后的网络结构如图 3 所示,图中红色部分为新增的改进模块。

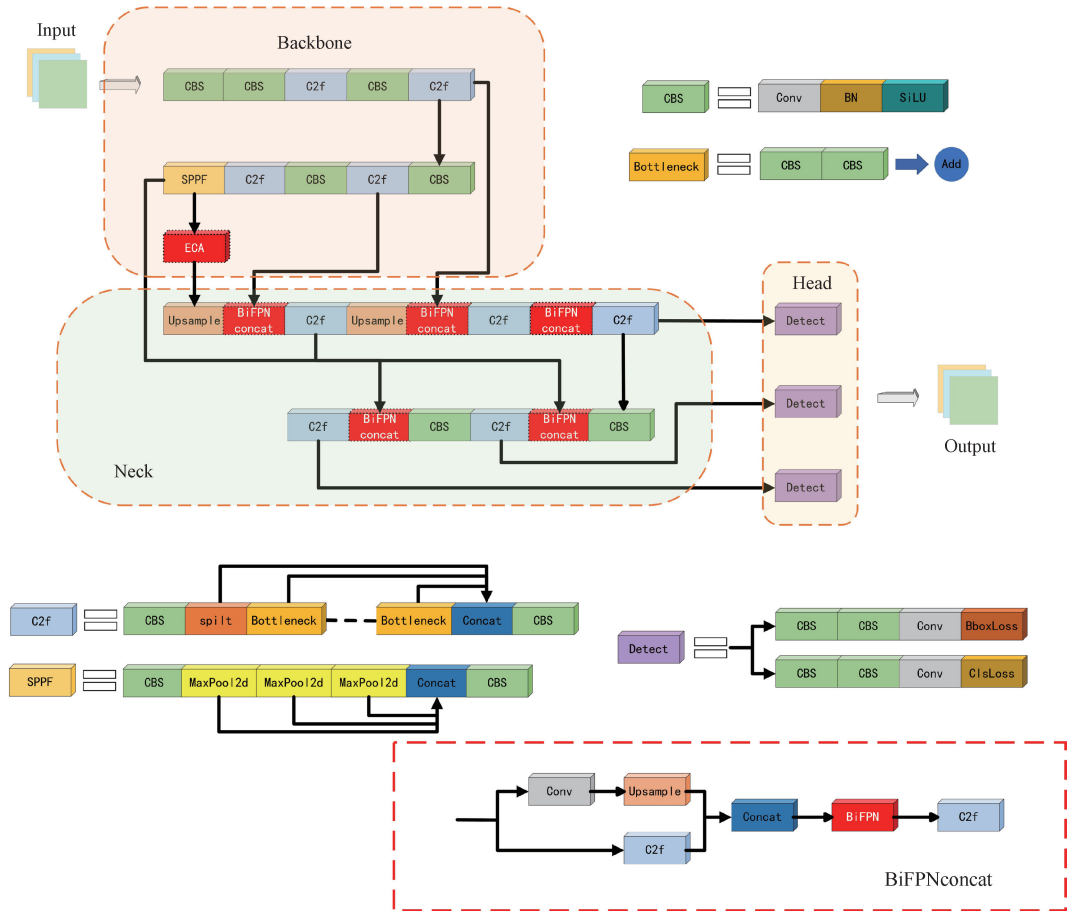


图 3 改进的 YOLOv8-Pose 网络结构

Fig. 3 Improved YOLOv8-Pose network structure

1) 高效通道注意力(ECA)机制

ECANet^[21]是一种轻量级通道注意机制,通过 ECA 注意力机制,模型处理特征图时,自动为不同的通道分配不同的权重,增强重要的通道并抑制不重要的通道,使模型在学习过程中更加集中于关键特征,从而提高模型的性能。为增强 YOLOv8-Pose 模型对标志物关键点特征的检测能力,同时避免深层网络处理过程中丢失关键点特征,本研究将模块加入 backbone 网络的最后一层中,ECANet 结构如图 4 所示。

ECANet 首先对输入的特征图进行全局平均池化(GAP),使特征图的维度由 $H \times W \times C$ 变为 $1 \times 1 \times C$,对于输入特征图 $X \in \mathbf{R}^{H \times W \times C}$,全局平均池化将其压缩为 $Z \in \mathbf{R}^{1 \times 1 \times C}$,平均池化操作表达式为:

$$Z = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_{ij} \quad (1)$$




图 4 ECA 注意力机制

Fig. 4 ECA attention mechanism

然后通过卷积核大小为 k 的一维卷积对池化后的 Z 进行卷积操作,以捕获局部跨通道交互,卷积核大小 k 与通道尺寸 C 存在映射关系,求解 k 的表达式为:

$$k = \psi(C) = \left\lfloor \frac{\log_2(C)}{\beta} + \frac{\alpha}{\beta} \right\rfloor_{\text{Odd}} \quad (2)$$

式中:一般取 $\alpha = 2, \beta = 1, |x|_{odd}$ 表示 x 的最近奇数。

接着应用 *Sigmoid* 函数激活得到表示特征通道重要性的权重 $\omega \in \mathbf{R}^{1 \times 1 \times C}$ 。计算权重 ω 的表达式为:

$$\omega = \text{Sigmoid}[C1D_k(\mathbf{Z})] \quad (3)$$

其中, $C1D_k$ 代表一维卷积, *Sigmoid* 函数的表达式为:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

最后将权重 ω 与原始特征 \mathbf{X} 逐个相乘获得加权特征 $\tilde{\mathbf{X}}$ 。

2) 加权双向特征金字塔

YOLOv8-Pose 原本的 Neck 模块采用路径聚合网络^[22] (path aggregation network, PAN), 这种特征提取方式虽然包含了自上而下以及自下而上的特征传递, 但是仅能实现两个层次的特征融合。所以本研究采用加权双向特征金字塔网络^[23] (bidirectional feature pyramid network, BiFPN) 代替原有的路径聚合网络-特征金字塔网络结构 (path aggregation network-feature pyramid network, PAN-FPN), 增强多尺度特征融合的效果, 有效提高网络对不同尺度物体的检测能力, 降低模型的计算复杂度, 同时提高模型的精度。

BiFPN 是一种高效的多尺度特征融合结构, 其在传统 FPN 和 PAN 基础上进行了优化, 引入双向跨尺度连接和加权特征融合机制, 不仅在自顶向下 (top-down) 的路径上进行特征融合, 还添加了自底向上 (down-top) 的路径, 形成了双向的特征流动, 能够快速地将特征融合到各个层次中。FPN、PAN、BiFPN 的网络结构如图 5 所示。

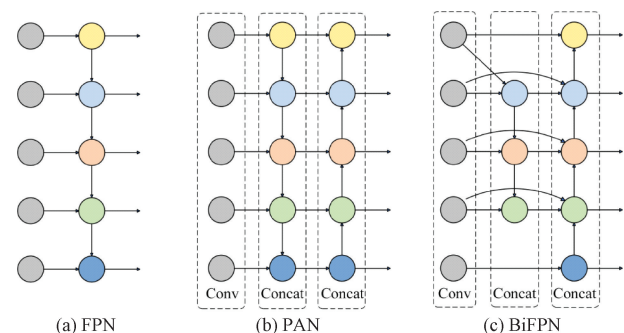


图 5 BiFPN 特征金字塔

Fig. 5 BiFPN feature pyramid

BiFPN 的特征融合过程可以表达为一系列加权求和的操作, 并通过快速归一化来实现加权特征融合, 定义如式(5)所示。

$$\text{Output} = \sum_i \frac{w_i}{\varepsilon + \sum_j w_j} \times \mathbf{I}_i \quad (5)$$

式中: w_i 代表可以学习的权重大小; \mathbf{I}_i 表示输入特征;

$\varepsilon = 10^{-3}$ 用来避免数值不稳定。

2.2 关键点亚像素提取算法

在对图像样本进行改进的 YOLOv8-Pose 标志物关键点检测后可以得到每一标志物全部关键点的像素坐标, 接着需要引入关键点亚像素提取算法得到每个关键点在原图像中的精准亚像素坐标。研究选择双 3 次插值法^[24], 来获得亚像素级别的关键点坐标。

双三次插值通过考虑每个关键点周围的 16 个像素计算插值。其核心在于利用三次多项式对每个方向进行插值, 从而在水平方向和垂直方向上都获得平滑的过渡。

对待关键点 $P(x, y)$, 取其附近的 4×4 邻域点 $(x_i, y_j), i, j = 0, 1, 2, 3$, 如图 6 所示。




图 6 关键点插值领域

Fig. 6 Keypoint interpolation field

按式(6)进行插值计算, 得到所求亚像素关键点像素值。

$$f(x, y) = \sum_{i=0}^3 \sum_{j=0}^3 f(x_i, y_j) W(x - x_i) W(y - y_j) \quad (6)$$

其中, $f(x_i, y_j)$ 表示关键点 4×4 邻域内每个像素点的像素值, $W(x - x_i)$ 、 $W(y - y_j)$ 分别表示这个关键点到邻域内每一像素点在 x 和 y 方向上的权重系数。权重系数计算公式为:

$$W(x) = \begin{cases} (a+2)|x|^3 - (a+3)|x|^2 + 1, & |x| \leq 1 \\ a|x|^3 - 5a|x|^2 + 8a|x| - 4a, & 1 < |x| \leq 2 \\ 0, & |x| > 2 \end{cases} \quad (7)$$

式中: x 表示当前关键点到邻域内每一像素点 x 或 y 方向上的距离; a 表示分段曲线的变化趋势, 一般取 $a = -0.5$ 。

2.3 位移求解

在获得标志物 16 个关键点的亚像素坐标后, 需比较当前时刻关键点坐标相对于上一时刻坐标是否发生偏移, 并计算出图像坐标系中 x 轴方向和 y 轴方向上的偏移量。若每个关键点可得到坐标 (x, y) , 以每个关键点

横坐标 x 为例,前后两个监测时刻同一标志物可以得到两组 4 阶矩阵,前一时刻横坐标矩阵为 X_1 ,后一时刻为 X_2 。将矩阵 X_2 中的每个元素减去 X_1 中对应位置的元素得到结果矩阵 X_{out} 。

$$X_{out} = X_2 - X_1 \quad (8)$$

其中,结果矩阵中每一元素 $x_{out_{ij}} = x_{2_{ij}} - x_{1_{ij}}$,接着通过平均滤波,得到更准确的结果。

$$\bar{X}_{out} = \frac{1}{4^2} \sum_{i=1}^4 \sum_{j=1}^4 x_{out_{ij}} \quad (9)$$

最终得到这一标志物当前时刻相对于上一时刻 x 轴方向上的平均偏移量 \bar{X}_{out} ,同理可得到 y 轴方向上的平均偏移量 \bar{Y}_{out} ,然后根据距离公式计算当前时刻标志物每相邻两个关键点之间像素距离并取平均值得到棋盘格每一小格的平均像素长度 l ,同时已知棋盘格每一小格的边长 $L=30$ mm,从而得到二维和三维位移之间变换的尺度因子 k 的值。

$$k = \frac{L}{l} \quad (10)$$

由于标志物正对相机,可以认为标志物表面与相机画面处于同一平面,标志物水平方向即为图像坐标系中 x 轴方向,竖直方向即为图像坐标系中 y 轴方向。将尺度因子 k 乘上 x 轴方向上的平均偏移量 \bar{X}_{out} 和 y 轴方向上的平均偏移量 \bar{Y}_{out} ,最终得到标志物水平方向上以及竖直方向上的实际位移,从而间接得到相邻两个时刻边坡在标志物水平及竖直方向的沉降位移监测结果,将所有时刻位移监测结果累加,可以得到从初始时刻开始的累计位移监测结果,最终实现高精度的高速公路边坡沉降位移监测。

3 实验验证

3.1 关键点检测精度实验

本实验旨在验证本研究提出的改进 YOLOv8n-Pose 标志物关键点检测方法的有效性,并通过与其他关键点检测算法的对比,全面评估本研究方法的性能优势。

1) 数据集

本研究通过采集边坡现场安装标志物后实际拍摄样本组成数据集。该数据集由 600 个样本实例组成,按照 8:1:1 的比例随机分为训练集(480 张图像)、验证集(60 图像)和测试集(60 张图像),再通过高斯模糊,镜像等数据增强技术,最终扩展到 4 800 个训练样本、600 个验证样本和 600 个测试样本,部分代表性样本如图 7 所示。

2) 训练环境以及参数设置

本研究模型的训练及测试均在同一台计算机上进




图 7 样本实例

Fig. 7 Sample example

行,训练迭代次数设为 500,批量大小设为 8,初始学习率设置 0.01,主要训练环境配置如表 1 所示。

表 1 训练环境配置

Table 1 Configuration of the training environment

硬件配置	参数
CPU	12th Gen Intel(R) Core(TM) i9-12900H
GPU	GeForce RTX 3060 Ti
操作系统	Windows 11 专业版
开发环境	Python 3.11.9 Pytorch 2.3 cuda 11.8

3) 评估指标

为了评估标志物识别的准确性,采用精确度(precision, P)、召回率(recall, R)作为性能指标,为了评估标志物关键点检测的准确性,采用目标关键点相似度(object keypoint similarity, OKS)计算出平均精度(average precision, AP),再通过 AP 得到 mAP 作为评价指标,定义为:

$$P = \frac{TP}{TP + FP} \times 100\% \quad (11)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (12)$$

$$OKS = \frac{\sum_i \exp\{-d_{pi}^2/2S_p^2\sigma_i^2\}\delta(v_{pi} > 0)}{\sum_i \delta(v_{pi} > 0)} \quad (13)$$

$$\delta = \begin{cases} = 1 (v_{pi} > 0) \\ = 0 (v_{pi} \leq 0) \end{cases}$$

$$AP = \frac{\sum_m \sum_p \beta(OKS_p > T)}{\sum_m \sum_p 1} \quad (14)$$

$$\beta = \begin{cases} OKS(OKS > T) \\ 0(OKS \leq T) \end{cases}$$

其中, TP 表示准确预测目标对象样本数量,而 FN 表示模型未检测到目标对象样本的数量, FP 表示模型误识别的实例数。 d_{pi} 表示预测第 i 个关键点与真实关键点的欧拉距离; S_p 表示标志物 p 点的尺度因子; v_{pi} 表示关键点可见性,关键点的可见性可以分为 3 种情况:0 表示未标注,1 表示标注被遮挡,2 表示标注并可见; σ_i 表示关键点的归一化因子。

4) 对比实验

本研究使用 YOLOv5n-Pose、YOLOv7n-Pose 和 YOLOv8n-Pose 模型作为对照组与改进的 YOLOv8n-Pose 模型进行比较,实验结果如表 2 所示,从 YOLOv5n-Pose 到 YOLOv8n-Pose,模型在准确率、召回率和 mAP 方面均有显著提高,同时 FPS 也逐步增加,验证了模型在性能与速度上的优化,因此,YOLOv8n-Pose 被选为基线模型。改进的 YOLOv8n-Pose 在所有性能指标上表现优异,与基线相比,准确率提升 4.33%,召回率提升 3.82%,mAP 提升 7.78%,进一步增强了关键点检测性能。尽管帧率下降了 3.6%,仍保持较高水平,表明改进模型在提升性能的同时基本维持了实时性。

表 2 不同模型的关键点检测效果
Table 2 Effectiveness of keypoint detection with different models

模型	P/%	R/%	mAP/%	帧率/FPS
YOLOv5n-Pose	83.74	74.53	78.25	183
YOLOv7n-Pose	88.16	80.71	83.27	204
YOLOv8n-Pose	93.54	91.62	89.43	221
改进的 YOLOv8-Pose	97.87	95.44	97.21	213

如图 8 所示,所有模型均成功检测到图像中的棋盘格标志物,但预测效果存在差异。YOLOv5n-Pose 在关键点预测时偏移较大,甚至出现误识别;YOLOv7n-Pose 能够预测大部分关键点,但部分位置与实际偏差明显;YOLOv8n-Pose 预测效果优于 YOLOv7n-Pose,但仍有少数关键点不够精确。改进的 YOLOv8n-Pose 则表现最佳,不仅准确预测了关键点位置,且置信度更高,性能更加优异。

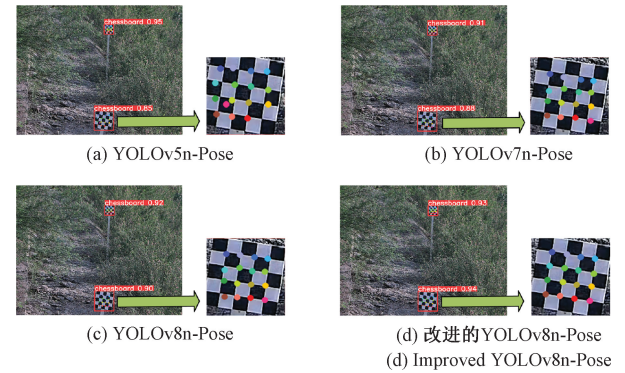


图 8 不同模型关键点预测结果

Fig. 8 Prediction results of key points of different models

3.2 边坡位移监测实验

为验证本研究提到的高速公路边坡位移测量方法在实际应用中的可行性与准确性,依托贵州剑榕高速公路某边坡作为实验地点,根据本研究提出的高速公路边坡

位移测量方案设计实验并部署相关设备。根据实验要求,主要采用设备包括视觉摄像机、标志物若干、数据采集卡、便携式计算机等硬件设备,现场布置如图 9 所示。



图 9 现场部署

Fig. 9 Site deployment diagram

本研究选择现场 10 个标志物作为监测对象,按照上述算法流程进行实验,以其中一个标志物为例,在某一个监测时刻其实验过程如图 10 所示。



图 10 实验过程

Fig. 10 Site deployment diagram

相机采集的原始图像先通过改进的 YOLOv8-Pose 算法识别图像中标记物关键点,再通过亚像素提取得到关键点亚像素坐标。标志物经过关键点检测以及亚像素提取后可以得到每个关键点的亚像素坐标,如表 3 所示。

表 3 标志物关键点亚像素坐标

Table 3 Subpixel coordinates of key points of markers

编号	x	y
1	458.787	445.332
2	484.376	449.700
3	509.521	453.766
4	534.729	458.125
5	455.106	471.262
6	480.502	475.098
7	505.749	479.717
8	531.416	483.854
9	451.366	496.676
10	476.824	500.984
11	501.981	505.142
12	527.500	509.431
13	447.649	522.011
14	473.051	526.446
15	498.512	530.737
16	523.689	535.069

接着根据上述算法流程中位移求解方法可得到该标志物当前时刻与上一时刻的位移变化以及从当前时刻到初始时刻标志物水平及竖直方向的累计位移监测结果,现场 10 个标志物的累计位移结果如表 4 所示,标志物竖直向下位移为正,水平向边坡外侧位移为正。

表 4 现场某一时刻累计位移监测结果

Table 4 Cumulative displacement monitoring results at a given point in time on site

监测点 编号	本研究方​​法监测		全站仪监测	
	水平累计 位移/	竖直累计 位移/	<i>x</i> 轴方向 位移/	<i>y</i> 轴方向 位移/
	mm	mm	mm	mm
1	0.01	-0.03	0.00	0.00
2	-0.12	-0.02	-0.10	0.00
3	-0.48	1.04	-0.50	1.00
4	0.17	0.14	0.20	0.10
5	0.23	0.32	0.20	0.30
6	-0.42	1.13	-0.40	1.10
7	-0.54	1.24	-0.5	1.20
8	-0.02	0.08	0.00	0.10
9	0.29	0.05	0.3	0.00
10	0.12	0.03	0.10	0.00

并通过全站仪测量结果对本研究方法的监测结果进行验证,设定全站仪测量 *x* 轴为标志物水平方向,*y* 轴为标志物竖直方向,正方向与本研究方​​法监测结果一致,本文方法与全站仪监测数据对比如图 11 所示。




图 11 测量数据与全站仪数据对比

Fig. 11 Comparison of measured data with total station data

可以发现本研究方​​法监测结果与全站仪监测结果虽然存在一定的误差,但基本一致。进一步对本研究所测得的标志物位移变化量与全站仪测得的标志物位移变化量误差进行分析,结果如图 12 所示。

根据两种监测方式的测量结果计算出每个标志物所




图 12 测量数据与全站仪数据误差分析

Fig. 12 Error analysis of measurement data and total station data

在监测点水平和竖直累计位移的绝对误差,并计算水平和竖直方向平均绝对误差 (MAE) 以及本研究监测方​​法相对于全站仪监测的准确率,MAE 定义为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\mu - \tau| \tag{15}$$

式中: *n* 表示标志物总数; μ 表示每个标志物所在监测点本研究方​​法的监测数据; τ 表示每个标志物所在监测点全站仪监测数据。准确率 $AP_{direction}$ 公式为:

$$AP_{direction} = (1 - \frac{MAE}{MAE_{total}}) \times 100 \tag{16}$$

其中, $MAE_{total} = \frac{1}{n} \sum_{i=1}^n |\tau|$,表示全站仪的误差,以其基准值的绝对值为衡量标准。如上图所示,最大绝对误差为 0.05,水平 MAE 和竖直 MAE 都很小,水平准确率为 90.43%,竖直准确率为 91.58%,均达到 90% 以上,表明本研究监测方​​法具备较高的精度,能够充分满足边坡监测对精度的要求。

4 结 论

本研究提出了一种低成本、高精度的边坡位移视觉测量装置及方​​法,通过部署高精度摄像机和特制标志物,结合改进的 YOLOv8-Pose 算法与亚像素提取技术,实现对边坡位移的精确监测。该方​​法能够在复杂环境中以低成本获取高精度的监测数据,充分满足工程实践对于边坡安全评估的需求。本研究针对标志物关键点检测进行优化,通过改进 YOLOv8-Pose 算法提高关键点检测准确性和效率。并利用亚像素提取技术,进一步提升了关键点坐标识别的精度,使得位移计算更为准确。在未来的研究中,可进一步提升算法在动态环境中的适应能力,增强系统的实时数据处理能力,并探讨与其他传感器技术的融合方​​案,从而实现多模态位移监测。同时,扩大实验范围,在多种复杂边坡条件下进行验证,提升方​​法的普适性。

参考文献

- [1] WHITELEY J, INAUEN C, WILKINSON P, et al. Assessing the risk of slope failure to highway infrastructure using automated time-lapse electrical resistivity tomography monitoring[J]. *Transportation Geotechnics*, 2023, DOI: 10.1016/j.trgeo.2023.101129.
- [2] PRASETYA R B, HENDARTO H. Real time monitoring using robotic total station on the outlet slope of the cisumdawu tunnel, west java[C]. *IOP Conference Series: Earth and Environmental Science*, 2023.
- [3] 虎勇, 吕辉岩, 李绍荣, 等. MEMS 姿态传感器在边坡表面位移监测的应用研究[J]. *电子测量与仪器学报*, 2023, 37(7): 53-61.
- HU Y, LYU H Y, LI SH R, et al. Study on application of MEMS attitude sensor in slope surface displacement monitoring[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(7): 53-61.
- [4] MAZZANTI P, CAPOROSSI P, BRUNETTI A, et al. Short-term geomorphological evolution of the poggio baldi landslide upper scarp via 3D change detection [J]. *Landslides*, 2021, 18(7): 2367-2381.
- [5] WANG Y L, SHI B, ZHANG T L, et al. Introduction to an FBG-based inclinometer and its application to landslide monitoring [J]. *Journal of Civil Structural Health Monitoring*, 2015, 5: 645-653.
- [6] ALAMEDA-HERNÁNDEZ P, HAMDOUNI E R, IRIGARAY C, et al. Weak foliated rock slope stability analysis with ultra-close-range terrestrial digital photogrammetry [J]. *Bulletin of Engineering Geology and the Environment*, 2019, 78: 1157-1171.
- [7] WANG G, KEARNS T J, YU J, et al. A stable reference frame for landslide monitoring using GPS in the puerto rico and virgin islands region [J]. *Landslides*, 2014, 11: 119-129.
- [8] MATEOS R M, AZAÑÓN J M, ROLDÁN F J, et al. The combined use of PSInSAR and UAV photogrammetry techniques for the analysis of the kinematics of a coastal landslide affecting an urban area (SE Spain) [J]. *Landslides*, 2017, 14: 743-754.
- [9] XU J K, WANG EN Y, ZHOU R. Real-time measuring and warning of surrounding rock dynamic deformation and failure in deep roadway based on machine vision method [J]. *Measurement*, 2020, 149: 10, DOI: 10.1016/j.measurement.2019.107028.
- [10] MI C, LIU Y, ZHANG Y, et al. A vision-based displacement measurement system for foundation pit[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72:1-15.
- [11] 邝先验, 程福军, 吴翠琴, 等. 基于改进 YOLOv7-tiny 的高效轻量遥感图像目标检测方法[J]. *电子测量与仪器学报*, 2024, 38(7): 22-33.
- KUANG X Y, CHENG F J, WU C Q, et al. Efficient and lightweight target detection method for remote sensing images based on improved YOLOv7-tiny [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(7): 22-33.
- [12] GAO Y, HE J F, ZHANG T ZH, et al. Dynamic keypoint detection network for image matching[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(12):14404-14419.
- [13] LIANG X ZH, WANG L X, CHENG W, et al. ACKSNet: Adaptive center keypoint selection for object detection[J]. *The Visual Computer*, 2023, 39(12): 6073-6084.
- [14] YU L J, ZHI X Y, HU J M, et al. Small-sized vehicle detection in remote sensing image based on keypoint detection[J]. *Remote Sensing*, 2021, 13(21): 4442.
- [15] WANG X L, KONG L K, ZHANG ZH G, et al. Keypoint regression strategy and angle loss based YOLO for object detection [J]. *Scientific Reports*, 2023, 13(1): 20117.
- [16] PRANAVAN V M, SHEKAR M, NGADIRAN R, et al. Fall detection system for monitoring elderly people using YOLOv7-pose detection model [C]. *2023 International Conference on Computer, Electronics & Electrical Engineering & their Applications (IC2E3)*, 2023.
- [17] WANG F, WANG G, LU B L. YOLOv8-Pose boost: Advancements in multimodal robot pose keypoint detection[J]. *Electronics*, 2024, 13(6): 1046.
- [18] YUAN Z J, SHAO P W, LI J R, et al. YOLOv8-ACU: Improved YOLOv8-Pose for facial acupoint detection[J]. *Frontiers in Neurorobotics*, 2024, 18: 1355857.
- [19] 贺强旅, 朱艳春, 李子良, 等. 基于双三次插值和高斯拟合的光条中心亚像素提取方法[J]. *激光杂志*, 2024, 45(6): 100-105.
- HE Q L, ZHU Y CH, LI Z L, et al. An extraction method for the subpixel center line of line structure light strip[J]. *Laser Journal*, 2024, 45(6): 100-105.
- [20] 郑心草, 孙忠贵. 图像超分中双三次插值的非局部拓展[J]. *南京师范大学学报(工程技术版)*, 2023, 23(3): 53-59.
- ZHENG X C, SUN ZH G. Non-local extension of bicubic

interpolation in image super-resolution [J]. Journal of Nanjing Normal University (Engineering and Technology Edition), 2023, 23(3): 53-59.

- [21] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.
- [22] LIU SH, QI L, QIN H F, et al. Path aggregation network for instance segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759-8768.
- [23] ZHU L, DENG Z, HU X, et al. Bidirectional feature pyramid network with recurrent attention residual modules for shadow detection [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018.
- [24] GUPTA S, SHARMA D K, RANTA S. A new hybrid image enlargement method using singular value decomposition and cubic spline interpolation [J]. Multimedia Tools and Applications, 2022, 81(3): 4241-4254.

作者简介



宋旻辰, 2018 年于南京邮电大学获得学士学位, 现为上海海事大学硕士研究生, 主要研究方向为港航交通装备智能感知应用基础研究、深度学习。

E-mail: 202230210126@stu.shmtu.edu.cn

Song Yangchen received his B. Sc. degree from Nanjing University of Posts and Telecommunications in 2018. Now he is a M. Sc. candidate of Shanghai Maritime University. His main research interests include the applied basic research of intelligent perception of port and navigation transportation equipment and deep learning.



宓超, 2007 年于上海海事大学获得学士学位, 2009 年于法国南特大学取得硕士学位, 2010 年于上海海事大学取得硕士学位, 2019 年于上海海事大学取得博士学位, 现为上海海事大学物流工程学院高级工程师/博导, 主要研究方向为港航装备智能化。

E-mail: chaomi@shmtu.edu.cn


Mi Chao received his B. Sc. degree from Shanghai Maritime University in 2007, M. Sc. degree from University of Nantes, France in 2009, M. Sc. degree from Shanghai Maritime University in 2010, and Ph. D. degree from Shanghai Maritime University in 2019, respectively. Now he is a senior engineer/doctoral director in the School of Logistics Engineering of Shanghai Maritime University. His main research interests include intelligentization of port and shipping equipment.



刘熠, 2018 年于上海海事大学获得学士学位, 现为上海海事大学硕士研究生, 主要研究方向为港航交通装备智能感知应用基础研究、深度学习。

E-mail: 202230210013@stu.shmtu.edu.cn

Liu Yi received her B. Sc. degree from Shanghai Maritime University in 2018. Now she is a M. Sc. candidate of Shanghai Maritime University. Her main research interests include the applied basic research of intelligent perception of port and navigation transportation equipment and deep learning.



沈阳 (通信作者), 现为上海海事大学高等技术学院讲师, 主要研究方向为港航物流智慧化。

E-mail: yangshen@shmtu.edu.cn

Shen Yang (Corresponding author) now is a lecturer in the Institute of Higher Technology of Shanghai Maritime University. His main research interests include intelligentization of port and shipping logistics.