移动扫码阅读

王宏伟, 李　进, 闫志蕊, 等. 基于图像与点云融合的巷道锚护孔位识别定位方法[J]. 煤炭科学技术, 2024, 52(5): 249−261.

WANG Hongwei, LI Jin, YAN Zhirui, *et al*. Roadway anchor hole recognition and positioning method based on image and point cloud fusion[J]. Coal Science and Technology, 2024, 52(5): 249−261.

基于图像与点云融合的巷道锚护孔位识别定位方法

王宏伟[1,2,3], 李　进[1,2], 闫志蕊[1,2], 郭军军[1,2], 张夫净[2,3], 李　超[1,2]

(1. 太原理工大学 机械与运载工程学院, 山西 太原　030024; 2. 太原理工大学 山西省煤矿智能装备工程研究中心, 山西 太原　030024; 3. 太原理工大学 矿业工程学院, 山西 太原　030024)

摘　要: 煤矿掘进巷道锚护位置的精准识别与定位是钻锚机器人实现智能永久支护亟需突破的关键技术。笔者提出一种基于视觉图像与激光点云融合的巷道锚护孔位智能识别定位方法，包括图像目标识别、点云图像特征融合和定位坐标提取 3 个步骤：①针对煤矿井下低照度、水雾和粉尘等环境因素导致的锚孔轮廓成像模糊的问题，采用 IA(Image-Adaptive)-SimAM-YOLOv7-tiny 网络对巷道待锚护孔位进行视觉识别，该网络能够自适应地增强图像亮度和对比度，恢复锚孔边缘的高频信息，并使模型重点关注锚孔特征，提高锚孔检测的成功率；②求解激光雷达和工业相机联合标定的外参矩阵，将图像检测的锚孔边界框通过透视投影关系生成锥形感兴趣区域(Region Of Interest，ROI)，获得对应的目标点云团簇；③采用点云处理算法提取锚护孔位边界点云，获得孔位中心坐标及其法向量，并通过坐标深度差比较判断锚孔识别的正确性。文中搭建了锚杆台车机械臂钻孔定位系统，对算法自主定位的精度以及准确度进行验证，试验结果表明：IA-SimAM-YOLOv7-tiny 模型的平均精度均值(Mean Average Precision，mAP)为 87.3%，较 YOLOv7-tiny 模型提高了 4.6%；提出的融合算法定位误差为 3 mm，单锚孔情况下系统平均识别时间为 0.77 s，与单一视觉方法相比，采用激光与视觉多源融合不仅可以降低环境和小样本训练对定位性能的影响，而且可以获得锚护孔位的法向量，为机械臂调整钻孔位姿实现精准锚固提供依据。

关键词: 锚孔精准定位; 图像识别; 点云处理; 激光雷达和相机联合标定; 数据融合

中图分类号: TD67　　**文献标志码:** A　　**文章编号:** 0253−2336(2024)05−0249−13

Roadway anchor hole recognition and positioning method based on image and point cloud fusion

WANG Hongwei[1,2,3], LI Jin[1,2], YAN Zhirui[1,2], GUO Junjun[1,2], ZHANG Fujing[2,3], LI Chao[1,2]

(1. *College of Mechanical and Vehicle Engineering*, *Taiyuan University of Technology*, *Taiyuan* 030024, *China*; 2. *Center of Shanxi Engineering Research for Coal Mine Intelligent Equipment*, *Taiyuan University of Technology*, *Taiyuan* 030024, *China*; 3. *College of Mining Engineering*, *Taiyuan University of Technology*, *Taiyuan* 030024, *China*)

Abstract: The accurate identification and positioning of the anchor position of the coal mine tunneling roadway is the key technology that the drilling anchor robot urgently needs to break through to achieve intelligent permanent support. An intelligent identification and positioning method for roadway anchor hole position based on visual image and laser point cloud fusion is proposed, which includes three steps: image target recognition, point cloud image feature fusion, and positioning coordinate extraction: ① In order to solve the problem of blurred image of anchor hole contour caused by environmental factors such as low illumination, water mist and dust in coal mines, the IA (Image-Adaptive)-SimAM-YOLOv7-tiny network was used to visually identify the position of the anchor hole to be anchored in the road-

收稿日期: 2023−07−18　　**责任编辑:** 周子博　　**DOI:** 10.12438/cst.2023-1050

基金项目: 山西省揭榜招标资助项目(20201101008); 山西省基础研究计划资助项目(202203021212275); 山西省重点研发计划资助项目(202102100401015)

作者简介: 王宏伟(1977—), 女, 黑龙江勃利人, 教授, 博士, 博士生导师。E-mail: lntuwhw@126.com

通讯作者: 闫志蕊(1993—), 女, 山西吕梁人, 研究实习员, 博士研究生。E-mail: mjlayue29@163.com

way, which can adaptively enhance the image brightness and contrast, recover the high-frequency information at the edge of the anchor hole, and make the model focus on the characteristics of the anchor hole, so as to improve the success rate of anchor hole detection; ② The Region of Interest (ROI) of image detection is generated by perspective projection relationship to generate a cone-shaped area of interest to obtain the corresponding target point cloud cluster; ③ The point cloud processing algorithm is used to extract the anchor hole boundary point cloud, obtain the central coordinates of the hole position and its normal vector, and judge the correctness of the anchor hole recognition by comparing the coordinate depth difference. In this paper, a drilling and positioning system for bolting trolley manipulator is built to verify the accuracy and accuracy of the algorithm's autonomous positioning, and the experimental results show that the mean average precision (mAP) of the IA-SimAM-YOLOv7-tiny model is 87.3%, which is 4.6% higher than that of the YOLOv7-tiny model. Compared with the single vision method, the fusion algorithm proposed in this paper has a positioning error of 3 mm, and the average recognition time of the system in the case of a single anchor hole is 0.77 s, compared with the single vision method, the fusion of laser and visual multi-source can not only reduce the influence of environment and small sample training on positioning performance, but also obtain the normal vector of the anchor hole position, which provides a basis for the manipulator to adjust the drilling posture to achieve accurate anchoring.

Key words: accurate positioning of anchor hole；image recognition；point cloud processing；joint calibration of lidar and camera；data fusion

0　引　　言

为了加快煤矿智能化建设，国家出台了《关于加快煤矿智能化发展的指导意见》，国内外学者针对煤矿智能化开采技术与装备进行了深入的研究和探索，有效缓解了采掘失衡问题。然而，在掘进巷道锚杆支护工艺方面仍存在复杂性高、作业时间长以及掘快支慢等难题[1-3]。为提高支护效率，国内外已成功研发了具备自主行走、自动钻孔等功能的钻锚机器人，并取得了自动化钻锚技术的重大进展。但由于我国煤层地质环境复杂，大多数煤矿顶板条件较差，需要利用锚梁支护，即钢带+锚网配合锚杆以实现锚固；煤矿井下环境因素造成的干扰，加大了锚护孔位（以下简称锚孔）的识别定位难度[4]，无法保证安全打钻从而极易发生设备损坏，造成严重的安全事故，所以目前只能通过人工的方式实现锚孔的定位以及钻臂姿态的调节[5-6]。因此，深入研究钻锚机器人锚护位置智能识别定位技术，是实现钻锚机器人智能支护的前提和关键[7-8]。

目前国内外针对煤矿井下巷道锚护位置识别的研究还较少，且多数是基于机器视觉实现。乔佳伟[9]提出采用 YOLOv5 算法识别锚孔，识别速度快，准确率高达 96%，但该方法在小孔、光照条件差的情况下易发生锚孔定位位置偏移的问题。为了解决上述问题，张夫净等[10]提出采用 RGB-D 方法识别定位锚孔，该方法基于 YOLOv5 架构，借助超分辨率重构技术增加锚孔图像的清晰度，并在骨干网络中添加坐标注意力机制，在一定程度上提高了锚孔识别的准确率。然而实际煤矿井下环境复杂、光照度差，相机作为被动传感器，成像效果受光线情况影响大，仅通过机器视觉的方法难以满足巷道锚孔高精度定位需求[11]。

多传感器融合可以弥补单一传感器信息的局限，提高数据冗余度和容错性，进而提升检测精度。目前，基于激光雷达和工业相机的融合方法在目标识别与定位领域应用较为广泛。工业相机获取的图像具有丰富的语义信息，深度学习图像目标检测算法成熟且实时性高，而激光雷达获取的点云可以提供丰富的几何、尺度信息和精确的距离信息[12-13]。为充分利用视觉图像丰富语义特征信息和激光点云高精度定位性能，发挥多源融合优势，作了如下研究：搭建了水雾和粉尘环境下钢带锚孔数据采集平台，模拟综掘工作面水雾及粉尘环境，采集了综掘工作面的锚孔图像数据，制作锚孔数据集；为提高图像检测网络性能，研究在 YOLOv7-tiny 网络中引入自适应图像增强（Image-Adaptive, IA）模块和引入 SimAM 注意力机制前后识别效果的影响；考虑到井下各种因素的影响，以致外参发生变化，采用了基于初始标定结果的无目标在线标定方法，可以在不需要人为干预的情况下校准外参，完成在线标定；通过研究视觉图像与激光点云融合方法，设计了用于煤矿掘进巷道支护锚孔识别定位的算法框架；最后通过搭建锚杆台车机械臂钻孔定位系统进行试验验证，试验结果表明笔者所提模型可以实现巷道支护锚孔智能精准识别定位，为完善煤矿巷道锚杆支护智能寻孔定位技术提供新的思路。

1　图像与点云融合定位方法

文中提出图像与点云融合的方法以实现煤矿掘进巷道支护锚孔识别与定位，该方法由锚孔视觉识别检测、图像点云特征融合、获取锚孔定位信息 3 个步骤组成，相机与激光雷达融合算法流程图如图 1 所示。

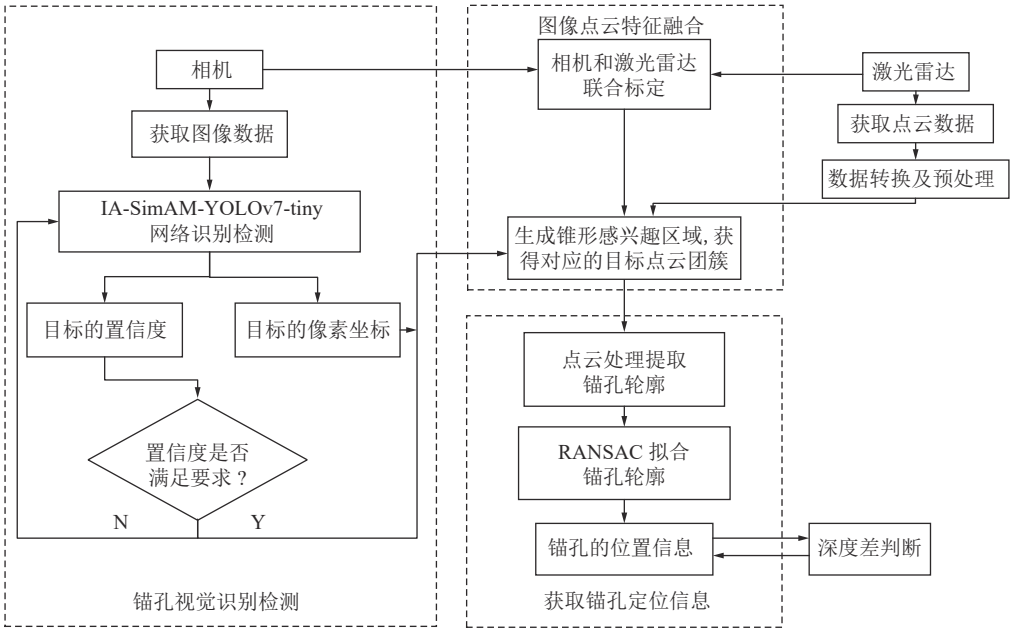

图 1　相机与激光雷达融合算法流程

Fig.1　Algorithm flow of camera and lidar fusion

使用 IA-SimAM-YOLOv7-tiny 目标检测网络对相机实时拍摄的图像进行检测，得到锚孔边界框和置信度；对相机和激光雷达的相对位置进行联合标定，以硬同步的方式实现激光雷达和相机的时间对齐，求解相机的内参矩阵以及相机与激光雷达之间的外参矩阵，确保点云数据和图像数据融合的重投影误差满足精度要求；根据图像识别得到的锚孔位置，将锚孔的图像特征与点云特征进行融合，获取到点云的感兴趣区域[14]，对每一簇点云进行预处理、提取并拟合得到锚孔的三维坐标和法向量，通过比较锚孔中心坐标与相邻坐标的深度差判断锚孔的真实性，保存锚孔的位置信息。

1.1　基于 IA-SimAM-YOLOv7-tiny 的锚孔目标检测算法

1.1.1　数据集构建

深度学习网络的训练需要大量的样本数据，笔者通过从煤矿掘进工作面巷道和实验室模拟巷道拍摄自制形成锚孔数据集。使用本安型工业相机在山西杜儿坪矿掘进工作面拍摄的部分巷道顶板，如图 2 所示。实验室模拟巷道以玻璃钢、塑钢为材料，用遮光涂料进行遮光，模拟巷道环境，基本还原了井下密闭、低照度环境特点，另外，为模拟井下水雾和粉尘环境，在巷道侧帮以及顶帮安装喷水装置，安装风机，还原井下掘进工作面的真实场景，水雾和粉尘环境下钢带锚孔数据采集平台如图 3 所示，采用工业相机（海康 MV-CA050-20UC）在模拟巷道中对数据进行采集。为保证数据集的多样性，分别从不同钢带、曝光或低照度、是否铺设锚网、运动模糊以及水雾粉尘环境的不同尺度、不同角度方面考虑并采集锚孔数据，最后，对采集到的样本图像进行数据处理以扩充样本数量，数据集总共由 7 000 张图像构成，并按照 6∶2∶2 比例划分形成训练集、验证集和测试集，井下锚孔数据集如图 4 所示。

图 2　煤矿掘进工作面拍摄的部分巷道顶板

Fig.2　Part of the roadway roof photographed at the excavation face of a mine

1.1.2　IA-SimAM-YOLOv7-tiny 模型

锚孔视觉识别任务具有目标小、照度低、辨识度低（粉尘和水雾遮挡）、精度要求高等特点。为了解决煤矿井下复杂环境导致的锚孔特征信息显著度低的问题，使用 YOLOv7-tiny 作为目标检测框架，添加 IA 模块进行去雾降噪处理，添加 SimAM 注意力机制以强调被检测目标图像的语义信

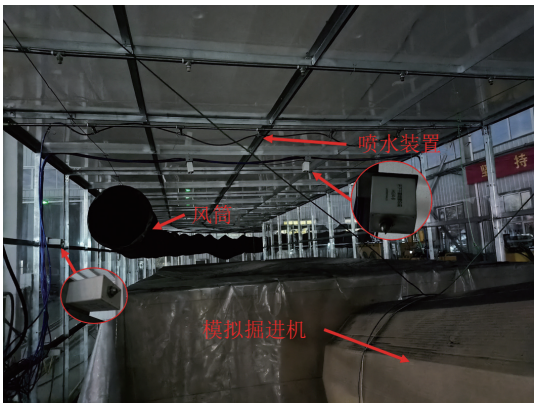

图 3　水雾和粉尘环境下钢带锚孔数据采集平台

Fig.3　Data acquisition platform for steel strip anchor holes in water mist and dust environment

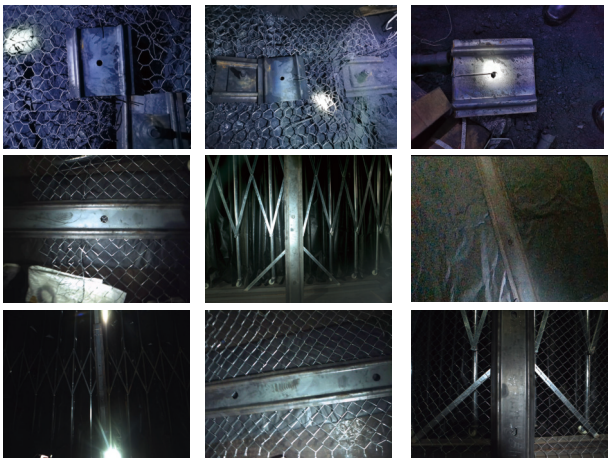

图 4　锚孔数据集

Fig.4　Anchor hole dataset

息。这 3 种技术的有机结合，在一定程度上消除了因低照度、水雾和粉尘遮挡而导致的图像模糊和噪声，充分保留图像的整体空间结构，突出并强化图像中与锚孔相关的特征信息，同时减少其他区域的干扰，从而实现局部区域的信息聚焦和全局信息的综合利用，使模型更加适用于复杂环境下的实际应用场景[15-18]。IA-SimAM-YOLOv7-tiny 检测网络流程如图 5 所示。

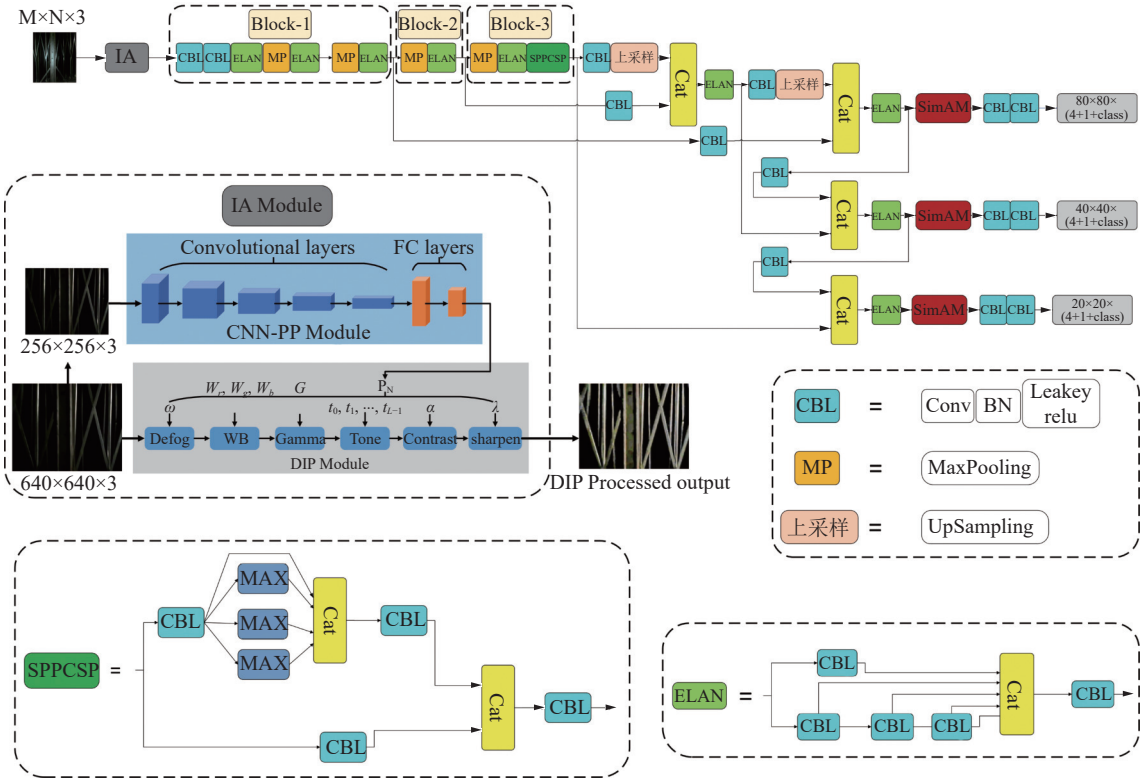

图 5　IA-SimAM-YOLOv7-tiny 模型结构

Fig.5　IA-SimAM-YOLOv7-tiny model structure

YOLOv7-tiny 采用了基于级联的模型缩减策略，并对高效长程聚合网络（Efficient Long-Range Attention Network, ELAN）进行了改进，在保证目标检测准确性的同时，提高计算效率和可靠性。YOLOv7-tiny 网络结构主要包括：Input 层、Backbone 层和 Head 层。其中 Input 层为输入层，对输入的图片进行预处理后输入到 Backbone 层；Backbone 层使用 28 个不同的卷积组合模块提取 3 种不同大小的目标信息特征，分别在 14、21、28 层输出 80×80×128、40×40×256、20×20×512 特征图到 Head 层；Head 层

主要融合 Backbone 层输出的特征并经过一系列卷积和池化操作，在第 57 层、第 65 层以及第 73 层输出 80×80×128、40×40×256、20×20×512 的特征图，最终输出 3 个不同大小的预测结果，方便算法后续部署。

为了提高模型的细节过滤能力和重要特征筛选能力，笔者在 YOLOv7-tiny 模块的 Input 层中引入了 IA 模块，该模块主要是对水雾、粉尘及低照度环境下的图像进行处理，用于提高图像的清晰度，突出锚孔边缘的高频信息，加强网络对图像的特征提取和分析的能力，具体架构如图 5 所示。IA 模块包括可微分图像滤波器（differentiable image processing module, DIP）和基于神经网络的小参数预测器（CNN-based parameter predictor, CNN-PP）。DIP 模块由 6 个可微过滤器组成，包括去雾（Defog）、白平衡（White Balance, WB），伽玛（Gamma），对比度（Contrast），色调（Tune）和锐化（Sharpen），通过调节这些超参数从而提高低照度水雾和粉尘环境下锚孔的可分辨程度。CNN-PP 模块通过了解图像的全局内容，如亮度，颜色和色调来预测 DIP 的参数。网络通过双线性插值下采样至 256×256 分辨率，使用 5 个步长为 2 的 3×3 卷积块和一个 Leaky Relu 层，输出通道数依次为 16、32、32、32 和 32，再经过两个全连接层输出用于增强图像的 15 个超参数，训练 CNN-PP 和 SimAM-YOLOv7-tiny 模型并优化权重，以寻找合适的 DIP 超参数和模型结构。

由于锚孔较小且易受环境影响，其特征容易被忽略或丢失，笔者基于 YOLOv7-tiny 这一轻量级网络，在 Head 区域添加 SimAM 注意力机制，具体添加位置如图 5 所示。在实际锚孔检测过程中，即使锚孔在图像中所占比例较小，SimAM 仍然可以通过评估每个神经元的重要性，从而提高局部感知能力以帮助网络更好地捕捉锚孔的语义特征，提高锚孔检测的精度和成功率；同时，SimAM 机制通过调整特征图的尺寸和通道权重相互关系，利用锚孔特征对相似的特征图进行识别，并加强相似的特征图之间的关联性，在不增加模型参数量的前提下，实现模型的自适应特征选择。

1.1.3　消融试验

首先选取了 Faster-RCNN, YOLOv5 和 YOLOv7 三种深度学习模型进行对比分析，训练过程的损失函数和平均精度（Mean Arerage Precision, mAP）值变化规律如图 6 所示。由图 6a 的损失函数训练曲线、图 6b 的 mAP 训练曲线可以看出，YOLOv7-tiny 收敛速度快、损失函数值小、mAP 值高。综合分析，效果更好的 mAP 和检测速度对于锚孔识别本身更为重要，因此选用 YOLOv7-tiny 模型作为视觉检测网络。

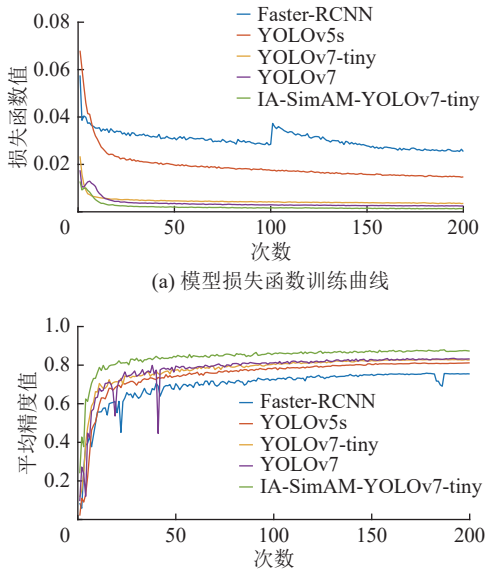

(a) 模型损失函数训练曲线

(b) 模型 mAP 训练曲线

图 6　模型训练效果

Fig.6　Model training effect

其次，为验证改进 YOLOv7-tiny 模型的检测效果，消融试验见表 1，结果表明：YOLOv7 的 mAP 较 YOLOv7-tiny 仅上升了 0.5%，但模型大小以及推理速度上明显逊于 YOLOv7-tiny，不利于部署到边缘计算设备；IA-YOLOv7-tiny 模型的 mAP 较 YOLOv7-tiny 模型提高了 2.1%，说明试验模拟的低照度、水雾粉尘环境影响了锚孔识别，也表明建立的低照度、水雾粉尘环境下加入 IA 模块在识别优化方面的提升效果显著；SimAM-YOLOv7-tiny 模型的 mAP 较 YOLOv7 -tiny 模型的上升了 2.8%，说明 SimAM 注意力机制通过评估每个神经元的重要性，将更多的关注

表 1　消融试验结果

Table 1　Results of the ablation test

模型	精度值/%	召回率/%	mAP/%	参数量/MB	检测速度/(s·img^{-1})
YOLOv7-tiny	94.1	93.3	82.7	12.3	0.08
Faster-RCNN	76.3	98.2	75.5	113.4	0.45
YOLOv5s	92.3	93.5	81.2	14.4	0.14
YOLOv7	95.1	95.4	83.2	74.8	0.19
IA-YOLOv7-tiny	95.4	95.6	84.8	12.5	0.25
SimAM-YOLOv7-tiny	96.1	96.5	85.5	12.3	0.09
IA-SimAM-YOLOv7-tiny	97.2	98.6	87.3	18.4	0.27

点放在目标特征所在的区域，增强了锚孔的特征显著性，进而提升了检测效果。另外在试验中对比了将 SimAM 加入不同 Block 区域后的检测效果，见表 2，结果表明在 YOLOv7-tiny 的 Head 区域添加 SimAM 注意力机制后，模型训练时更加关注锚孔的特征，减少特征提取网络卷积操作时目标特征的丢失；IA-SimAM-YOLOv7-tiny 模型的 mAP 较 YOLOv7-tiny 模型上升了 4.6%，在 YOLOv7-tiny 中引入 IA 模块和 SimAM 模块后，损失函数值减小，收敛速度依然很快。可以看出所提出的检测模型达到了较好的训练结果且改进后的 IA-SimAM-YOLOv7-tiny 的 mAP 明显高于其他网络。

表 2　SimAM 注意力机制的添加位置效果对比

Table 2　Comparison of the addition position effect of SimAM's attention mechanism

融合方式	不同评价方式下检测效果/%		
	精度值	召回率	mAP
Baseline	94.1	93.3	82.7
Block-1	94.8	95.4	83.3
Block-2	93.6	93.1	82.1
Block-3	95.3	95.9	84.1
Ours	96.1	96.5	85.5

1.1.4　检测效果验证

笔者分别从粉尘水雾、低照度以及运动模糊等实际工况分别对 IA-SimAM-YOLOv7-tiny 和 YOLOv7-tiny 两种模型的检测效果进行测试，如图 7 所示。第 1 组和第 2 组试验为光照条件变化工况，在光照强度低的区域，锚孔与背景环境灰度值较为接近，且锚孔在图像中的像素占比小，利用 YOLOv7-tiny 算法检测时均存在漏检，而本文算法增强了图像的对比度和亮度，增强了锚孔的特征表达能力，使检测网络注意力重点关注锚孔区域，进而能够有效地检测出所有锚孔；第 3 组和第 4 组试验为光照条件变化与粉尘水雾组合工况，锚孔的高频信息会被粉尘水雾遮挡，锚孔边缘特征模糊，锚孔区域灰度值与周围环境接近，导致卷积网络难以提取到锚孔的特征信息，出现漏检问题。而文中算法处理后的图像清晰度明显优于原图，语义特征模糊现象明显减少，模型能够有效地提取到像素级特征信息，在一定程度上可避免由于低照度和水雾造成的漏检。第 5 组试验是由机械臂抖振导致的图像模糊，经多次试验证明，YOLOv7-tiny 和 IA-SimAM-YOLOv7-tiny 均能准确识别锚孔，这是因为 YOLOv7-tiny 算法的检测速度快，而 IA-SimAM-YOLOv7-tiny 能提高图像清晰度，帮助网络捕获锚孔的特征，较好地解决了由于机械臂抖振导致漏检问题。

1.2　相机与三维激光雷达的联合标定

实现图像与点云的特征融合首先需要确保相机和激光雷达的时间和空间对齐。时间对齐即对激光雷达和相机进行时间戳同步，从而获得同一时刻拍摄的点云和图像，如图 8a 所示，相机和激光雷达均

(a) RGB 原图

(b) YOLOv7-tiny 检测结果

(c) IA-SimAM-YOLOv7-tiny 检测结果

图 7　检测效果对比

Fig.7　Comparison of detection effects

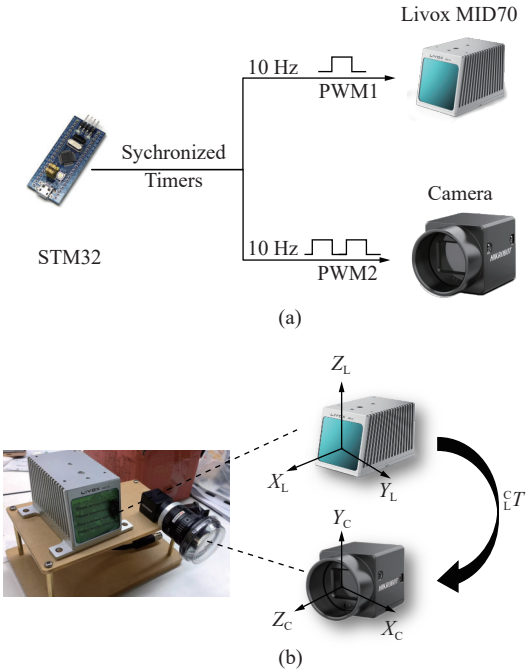

图 8　激光雷达和相机标定模型

Fig.8　Lidar and camera calibration model

通过 STM32 发送 10 Hz 的触发信号进行硬同步[19]。空间对齐即对激光雷达和相机进行联合标定，建立激光雷达和相机坐标系间的转换关系。使用的处理器为 11th Gen Intel(R) Core(TM) i9-11950H @2.60GHz，GPU 为 NVIDIA RTX A3000 Laptop GPU。三维激光雷达型号为 Livox mid-70，工业相机是海康威视 MV-CA050-20UC，软件环境为 Ubuntu18.04 LTS 64-bit 操作系统平台。相机和激光雷达固定安装在支架台上，相机与激光雷达位置关系以及坐标系转换关系如图 8b 所示。

1.2.1　相机内参标定

相机的内参标定即求解相机坐标系和像素坐标系的转换关系以及相机的畸变参数。笔者采用张正友标定法进行内参标定[20]，具体标定过程如下：标定板为黑白棋盘格，棋盘格角点为 9 行×7 列，每个方格的尺寸均为 10 cm×10 cm，用相机在不同角度、不同距离对标定板进行拍摄，然后通过 MATLAB 标定工具箱完成标定过程，标定过程如图 9 所示，重投影误差的结果为 0.06 像素，该误差满足锚孔定位作业的要求，得到的内参矩阵和畸变参数向量如下：

内参矩阵：

$$\begin{bmatrix} f_x & 0 & u_0 \\ 0 & f_y & v_0 \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 1\,763.863\,1 & 0 & 1\,297.124\,7 \\ 0 & 1\,763.607\,5 & 979.857\,9 \\ 0 & 0 & 1 \end{bmatrix}$$

畸变系数：

$$[k_1,k_2,p_1,p_2,k_3] = [-0.121\,1, 0.112\,9, -0.006\,3, 0.000\,7, 0]$$

相机坐标系转换到像素坐标系的转换公式如下：

$$z\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & u_0 \\ 0 & f_y & v_0 \\ 0 & 0 & 1 \end{bmatrix}\begin{bmatrix} X_c \\ Y_c \\ Z_c \end{bmatrix} \tag{1}$$

式中，f_x为 x 轴方向焦距的长度，px；f_y为 y 轴方向焦距的长度，px；(u_0,v_0)为主点的实际位置，px，k_1,k_2,k_3为相机的径向畸变参数；p_1,p_2为相机的切向畸变参数；(X_c,Y_c,Z_c)为相机坐标系下的三维坐标；(u,v)为像素坐标系下的坐标，z为像素点(u,v)的深度。

1.2.2　相机与激光雷达的外参标定

相机与激光雷达融合的外参标定本质上是获取相机与激光雷达的相对位置关系，实现相机坐标系与激光雷达坐标系坐标的转换[21]，激光雷达坐标系到相机坐标系的转换关系为：

$$\begin{bmatrix} X_c \\ Y_c \\ Z_c \\ 1 \end{bmatrix} = \begin{bmatrix} \boldsymbol{R} & \boldsymbol{t} \\ \vec{0} & 1 \end{bmatrix}\begin{bmatrix} X_L \\ Y_L \\ Z_L \\ 1 \end{bmatrix} \tag{2}$$

式中，$\boldsymbol{R}$为激光雷达坐标系到相机坐标系的旋转矩阵；$\boldsymbol{t}$为激光雷达坐标系到相机坐标系的平移矩阵；X_c,Y_c,Z_c分别为相机坐标系下点的三维坐标；X_L，Y_L,Z_L分别为激光雷达坐标系下点的三维坐标。

考虑到实际工作中激光雷达和相机之间的位置关系可能发生偏移或者旋转，会导致初始外参不满

(a) 标定板中距离正角度　(b) 标定板中距离侧角度　(c) 标定板中距离俯角度　(d) 标定板近距离正角度

图 9　相机内参标定过程

Fig.9　Camera parameter calibration process

足融合的重投影精度要求，因此在任务开始前需要基于初始标定结果进行在线标定。笔者所采用的方法不需要借助具有特殊特征的标定物或者人为干预，而是采集现实中一般的线特征作为标定物。另外，该方法提出测量噪声模型，提高了标定精度[22]。该方法提取点云深度连续边缘以及图像边缘，通过网格搜索的方式完成粗校准的过程，精校准过程中加入测量噪声模型，从最大似然估计角度推导当前的迭代策略，并进行迭代更新。精确匹配公式具体推导过程如下：

${}^{L}\boldsymbol{w}_i \sim \mathcal{N}(\boldsymbol{0}, {}^{L}\boldsymbol{\Sigma}_i)$是雷达数据中提取边缘过程中存在的误差，${}^{I}\boldsymbol{w}_i \sim \mathcal{N}(\boldsymbol{0}, {}^{I}\boldsymbol{\Sigma}_i)$是图像数据中提取边缘过程中存在的误差，${}^{L}P_i$是雷达提取的边缘点，$\boldsymbol{n}_i^{\mathrm{T}}, \boldsymbol{q}_i$分别是雷达在图像中对应的边缘法线和边缘上一点，通过误差补偿应满足以下条件：

$$0 = \boldsymbol{n}_i^{\mathrm{T}}\left\{f\left\{\pi\left[{}^{\mathrm{C}}_{\mathrm{L}}\boldsymbol{T}\left({}^{\mathrm{L}}\boldsymbol{P}_i + {}^{\mathrm{L}}\boldsymbol{w}_i\right)\right]\right\} - \left(\boldsymbol{q}_i + {}^{\mathrm{I}}\boldsymbol{w}_i\right)\right\} \tag{3}$$

由于上述方程为非线性的，将上式经过泰勒公式展开进行线性化，简化结果如下：

$$0 = \boldsymbol{n}_i^{\mathrm{T}}\left\{f\left\{\pi\left[{}^{\mathrm{C}}_{\mathrm{L}}\boldsymbol{T}^{\mathrm{L}}\left(\boldsymbol{P}_i + {}^{\mathrm{L}}\boldsymbol{w}_i\right)\right]\right\} - \left(\boldsymbol{q}_i + {}^{\mathrm{I}}\boldsymbol{w}_i\right)\right\} \approx \boldsymbol{r}_i + \boldsymbol{J}_{T_i}\delta\boldsymbol{T} + \boldsymbol{J}_{w_i}\boldsymbol{W}_i \tag{4}$$

其中，$\boldsymbol{r}_i$为外参初值${}^{\mathrm{C}}_{\mathrm{L}}T^{\mathrm{L}}$的近似值；$\boldsymbol{J}_{T_i}$为对外参的导数；$\boldsymbol{J}_{w_i}$为对噪声的导数；$\boldsymbol{W}_i = \begin{bmatrix} {}^{\mathrm{L}}\boldsymbol{w}_i \\ {}^{\mathrm{I}}\boldsymbol{w}_i \end{bmatrix}$。对多个点使用式(4)，可以得到误差函数：

$$-\boldsymbol{J}_{w_i}\boldsymbol{W}_i = \boldsymbol{r}_i + \boldsymbol{J}_{T_i}\delta\boldsymbol{T} \sim \mathcal{N}\left(0, \boldsymbol{J}_{w_i}\Sigma_{w_i}\boldsymbol{J}_{w_i}^{\mathrm{T}}\right) \tag{5}$$

从最小方差最大似然估计的角度，得到目标函数如下：

$$\min_{\delta\mathrm{T}}\sum_{i}^{k}\left\|\boldsymbol{r}_i + \boldsymbol{J}_{\mathrm{T}_i}\delta\boldsymbol{T}\right\|_{\Sigma\boldsymbol{J}_{w_i}\boldsymbol{W}_i} = \sum_{i}^{k}(\boldsymbol{r}_i + \boldsymbol{J}_{T_i})\left(\boldsymbol{J}_{w_i}\sum_{\boldsymbol{W}_i}\boldsymbol{J}_{w_i}^{\mathrm{T}}\right)^{-1}(\boldsymbol{r}_i + \boldsymbol{J}_{T_i}) \tag{6}$$

令上式求导等于 0，即可得到参数$\delta\boldsymbol{T}^*$的最优估计：

$$\delta\boldsymbol{T}^* = -\left(\boldsymbol{J}_T^{\mathrm{T}}\left(\boldsymbol{J}_w\boldsymbol{\Sigma}\boldsymbol{J}_w^{\mathrm{T}}\right)^{-1}\boldsymbol{J}_T\right)^{-1}\boldsymbol{J}_T^{\mathrm{T}}\left(\boldsymbol{J}_w\boldsymbol{\Sigma}\boldsymbol{J}_w^{\mathrm{T}}\right)^{-1}\boldsymbol{r} \tag{7}$$

则目前的更新策略为：

$${}^{\mathrm{C}}_{\mathrm{L}}\overline{\boldsymbol{T}} \leftarrow {}^{\mathrm{C}}_{\mathrm{L}}\overline{\boldsymbol{T}} \oplus \delta\boldsymbol{T}^* \tag{8}$$

进行迭代直到收敛，收敛后的结果${}^{\mathrm{C}}_{\mathrm{L}}\overline{\boldsymbol{T}}$则为最优的外参矩阵。

外参标定流程如下：选择边缘分布均匀的井下场景，对于图像而言，采集一张图像；对于三维激光点云数据而言，则需要采集较长时间的数据，以保证场景的完整性。将采集的数据输入到该方法中进行标定，结果保留 4 位有效数字，得到相机和激光雷达的外参矩阵，如下所示：

$$\boldsymbol{T} = \begin{bmatrix} -0.029\,5 & -0.999\,5 & -0.009\,7 & 0.109\,1 \\ 0.022\,9 & 0.009\,0 & -0.999\,6 & 0.025\,1 \\ 0.999\,2 & -0.029\,7 & 0.022\,6 & -0.026\,8 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

标定结果的平均重投影误差由式(9)计算可得，其中(u_{di}, v_{di})表示图像实际像素坐标，(u_i, v_i)为投影到像素坐标系下的坐标。最后平均重投影计算结果为 1.93 px，对于精密测量来说，误差在 1 ~ 2 个像素左右即满足要求。雷达和相机联合标定效果图如图 10 所示：

$$R_{\mathrm{e}} = \frac{1}{N}\sum_{i=1}^{N}\sqrt{(u_{di} - u_i)^2 + (v_{di} - v_i)^2} \tag{9}$$

1.3　相机与激光雷达数据融合进行目标检测

获取得到时间和空间对齐的相机图像和激光雷达点云数据后，对图像与点云进行特征融合并实现锚孔的识别与定位，流程如图 11 所示，具体步骤如下：

1)基于图像特征获取候选目标点云团簇。通过图像检测模块改进的 YOLOv7-tiny 模型提取图像中的 ROI，然后根据透视投影关系生成 3D 锥形 ROI，获取目标锚孔及其周围点云(图 11A)。在检测过程中，将激光雷达和相机移动到待支护区域的正下方，采集锚孔的图像和点云数据，首先将激光雷达采集的 las 文件数据转换成 pcd 点云数据格式。将采集图像输入到改进的 YOLOv7-tiny 锚孔识别模型进行检测，得到锚孔的置信度和位置信息，当置信度大于最小阈值时，将锚孔图像检测框作为 2D ROI，根据透视投影关系提取包含锚孔及其周围点云的 3D 锥形 ROI，获得从百万级数据量中筛选出千级数据量的锚孔点云，极大降低了点云数据计算量。试验综合考虑识别效率和误检等因素，设置置信度最小值为 0.7。

2)提取锚孔边界点云。使用改进的随机抽样一致性(Random Sample Consensus, RANSAC)对锚孔点云团簇进行平面拟合得到锚孔所在平面点云(图 11B)，使用基于法线估计的边缘轮廓提取方法获取锚孔的边缘点云以及矩形框的边缘点云(图 11C)，并根据视锥体数据冗余的特点，通过缩小矩形框保留锚孔边界点云(图 11D)。在 3D ROI 内使用改进的随机抽样一致性 RANSAC 进行平面拟合去除锚孔孔内的点云，获取到钢带的平面点云。传统 RANSAC

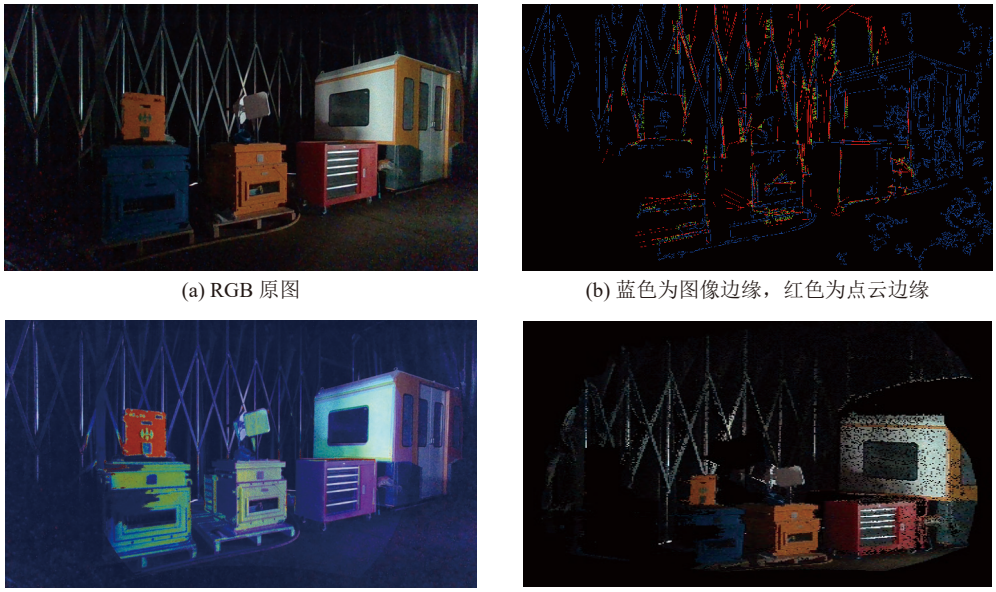

(a) RGB 原图　(b) 蓝色为图像边缘，红色为点云边缘

(c) 投影深度信息到 RGB 图像　(d) 点云上色图

图 10　相机与激光雷达外参标定效果

Fig.10　Camera and external lidar parameter calibration effect

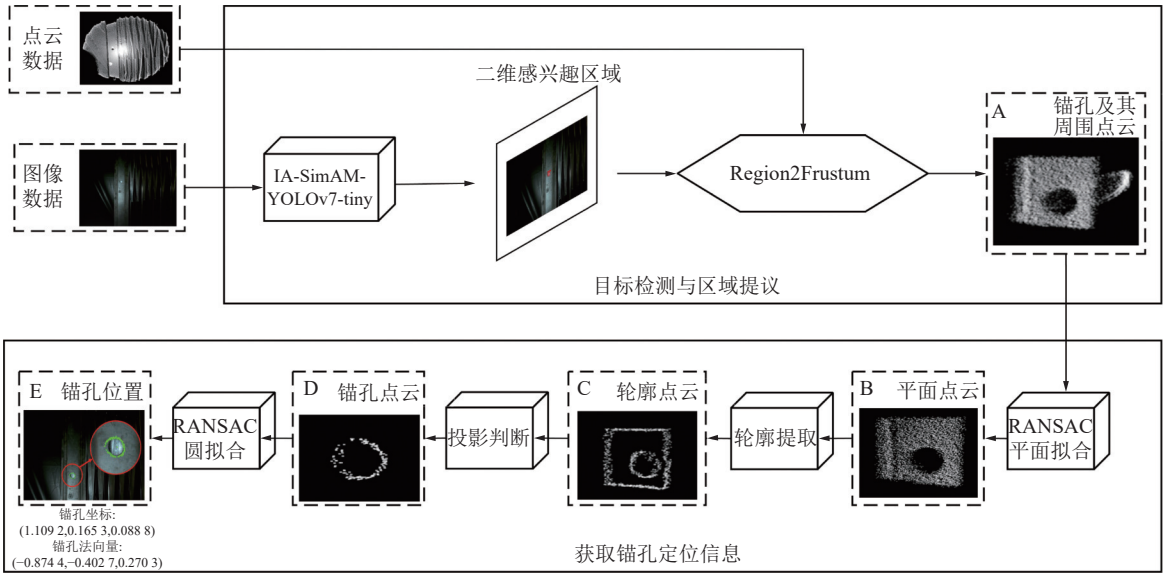

图 11　激光点云和相机图像融合的锚孔定位方法

Fig.11　Anchor hole positioning method for lidar point cloud and camera image fusion

平面拟合选取初始点的方式是从点云数据中随机选取 3 个点，然后使用最小二乘法拟合得到平面，然后根据误差容忍范围内局内点数量判断最优模型，这种取点方式大多数不会满足要求，导致迭代次数增加。为加快拟合速度，从选点方式上提出将随机选取 3 个点改为使用 KD 树存储点云数据，从 KD 树中取 k 近邻（k=3）作为初始点，本试验根据经验值设置误差容忍范围为 0.01。使用基于法线估计的边缘轮廓提取方法获取锚孔的边缘点云以及矩形框的边缘点云，具体实现方法为：①选取点云中的一点 p，选出 p 的 k 邻域组成一个邻域集合 $\boldsymbol{N}$，计算邻域集合 $\boldsymbol{N}$ 的协方差矩阵，邻域微切面的法向量为协方差矩阵奇异值分解后最小特征值对应的特征向量。遍历点云中所有的点，完成点云的法线估计。试验为保证锚孔轮廓提取的准确性和完整性，根据经验值设置 k 邻域搜索范围为 R=0.05。②将采样点投影到微切平面，根据采样点与其 k 近邻所对应的投影点连线的最大夹角是否大于最大阈值 ϕ，判断是否为边界特征。根据经验设置 k 邻域搜索范围为 R=0.05，最大阈值为$\pi/4$。根据视锥体数据冗余的特点，缩小包围锚孔的矩形框剔除矩形框的边缘点云，保留锚孔边缘轮廓点云。

3)获取锚孔中心坐标。使用改进的 RANSAC 拟合圆得到锚孔中心坐标(钢带上的锚孔中心坐标)以及锚孔的法向量(图 11E)。传统的 RANSAC 将三点代入圆的一般方程式求解出圆心和半径,这种方法带有平方运算,耗时较大,改进的 RANSAC 利用圆上弦的中垂线定理能够将二次运算转化为一次运算,从而减少了时间消耗。根据最优模型中的局内点拟合平面得到平面的参数以及法向量即锚孔的法向量。试验为确保锚孔圆拟合的精确性,应使误差容忍范围尽可能小,因此设置误差容忍范围为 0.005。根据锚孔中心的真实坐标到拟合平面的距离判断是否为真正的锚孔,从而避免了图像识别中的误检情况。真假锚孔判断准则为:若锚孔中心的真实坐标到平面点云即图 11B 的距离 $d \geqslant m\sigma$,认为该点不属于钢带平面上的点,则判定为真实锚孔,否则为假锚孔,本试验根据锚孔深度设置 $m = 5$。

最佳平面拟合中误差为:

$$\sigma = \sqrt{\frac{\sum_{i=1}^{n}(z_i - \bar{z})^2}{n-1}} \tag{10}$$

式中,z_i 为点到拟合平面的距离;$\bar{z}$ 为点到拟合平面的平均距离。

以上处理方法都是针对单个锚孔的处理方法,针对多个锚孔的处理方法是在投影过程中将每一个矩形框的点云数据放到不同的 KD 树中,然后按照单个锚孔的处理方法逐个计算。需要注意的是,由于点云数据存在点云不变性,参数的设置不会影响到定位效果。

2　试验结果与分析

2.1　试验部署

根据井下实际情况,搭建模拟巷道,将工业相机、激光雷达和环形光源固定在机械臂上,搭建锚杆台车机械臂锚孔定位试验平台如图 12 所示。将图像与点云融合定位算法部署到边缘计算设备(NVIDIA Jetson Xavier NX),并安装在锚杆台车的控制箱内。通过手眼标定方法确定相机与基座的位置关系,将定位结果转换为基座坐标系下锚孔的坐标,从而控制机械臂进行锚固作业。眼在手上的具体标定过程如下:

由于机器臂基座到标定板的相对位置关系保持不变,因此机械臂基座到标定板的相对位置关系展开均应满足式(11):

$$ {}^{B}_{E_1}\boldsymbol{T}\,{}^{E_1}_{C_1}\boldsymbol{T}\,{}^{C_1}_{O}\boldsymbol{T} = {}^{B}_{E_2}\boldsymbol{T}\,{}^{E_2}_{C_2}\boldsymbol{T}\,{}^{C_2}_{O}\boldsymbol{T} \tag{11}$$

整理得:

$$ {}^{B}_{E_2}\boldsymbol{T}^{-1}\,{}^{B}_{E_1}\boldsymbol{T}\,{}^{E_1}_{C_1}\boldsymbol{T} = {}^{E_2}_{C_2}\boldsymbol{T}\,{}^{C_2}_{O}\boldsymbol{T}\,{}^{C_1}_{O}\boldsymbol{T}^{-1} \tag{12}$$

由于相机到机械臂末端的相对位置 ${}^{E}_{C}\boldsymbol{T}$ 不变,记:

$$\begin{aligned} \boldsymbol{A} &= {}^{E_2}_{E_1}\boldsymbol{T} = {}^{B}_{E_2}\boldsymbol{T}^{-1}\,{}^{B}_{E_1}\boldsymbol{T} \\ \boldsymbol{B} &= {}^{C_2}_{C_1}\boldsymbol{T} = {}^{C_2}_{O}\boldsymbol{T}\,{}^{C_1}_{O}\boldsymbol{T}^{-1} \\ \boldsymbol{X} &= {}^{E}_{C}\boldsymbol{T} = {}^{E_1}_{C_1}\boldsymbol{T} = {}^{E_2}_{C_2}\boldsymbol{T} \end{aligned} \tag{13}$$

其中,下标 i 和 j 表示任一时刻 i 和 j;${}^{B}_{E}\boldsymbol{T}$ 为基座到机械臂末端的转换矩阵;${}^{E}_{C}\boldsymbol{T}$ 为机械臂末端到相机

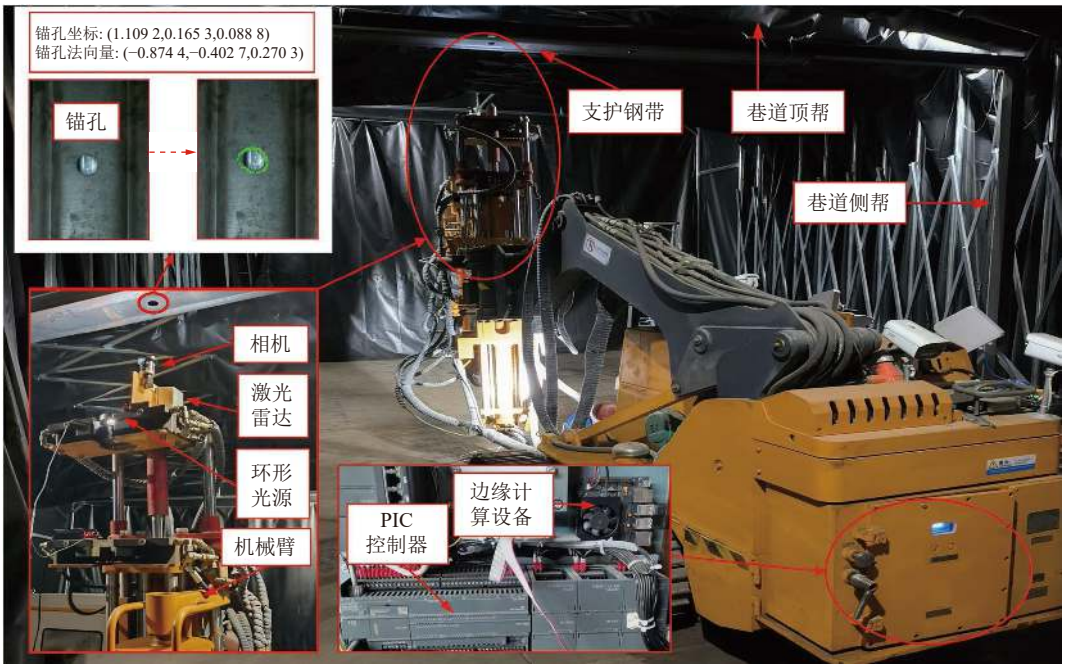

图 12　锚杆台车机械臂锚孔定位试验平台

Fig.12　Anchor trolley mechanical arm anchor hole positioning test platform

的转换矩阵；${}^{C}_{O}\boldsymbol{T}$为相机到标定板的转换矩阵。手眼标定即求机械臂末端到相机的转换矩阵$\boldsymbol{X}$。完成手眼标定后，锚孔到机械臂末端的转换关系为：

$$ {}^{\text{end}}_{\text{hole}}\boldsymbol{T} = {}^{\text{lidar}}_{\text{hole}}\boldsymbol{T}\,{}^{\text{lidar}}_{\text{camera}}\boldsymbol{T}^{-1}\,{}^{\text{end}}_{\text{camera}}\boldsymbol{T} \tag{14} $$

其中，${}^{\text{end}}_{\text{camera}}\boldsymbol{T}$通过手眼标定求得，${}^{\text{lidar}}_{\text{camera}}\boldsymbol{T}$由相机和激光雷达联合标定得出，${}^{\text{lidar}}_{\text{hole}}\boldsymbol{T}$由本文融合算法求出。

试验先利用 C#在 WPF 框架下制作锚杆台车远程控制界面，然后根据相机的图像识别结果完成锚孔的粗定位，使得锚孔位于激光雷达和相机的共视区域，最后利用文中算法对井下锚孔进行智能识别和定位[23]。

2.2　模型试验验证

选取 100 帧在不同光照条件、不同位置的图像和点云进行试验测试，试验结果如图 13 所示。图 13a、13b 和 13c 为 IA-SimAM-YOLOv7-tiny 的检测结果；图 13a 中若光照和位置处于合理情况，视觉检测能精确地定位到锚孔的像素坐标；图 13b 中光照条件差的情况下，视觉检测的锚孔像素坐标发生偏移，导致锚孔定位精度低；图 13c 中设置油液去近似锚孔特征，当环境较暗，仅视觉会根据锚孔的形状及纹理颜色将平面上的油液误检为锚孔。相比而言，笔者采用的相机和激光雷达融合定位方法的检测效果如图 13j、13k 和 13l 所示，在样本 13a、13b 和 13c 所处 3 种环境下均能够得到准确的锚孔中心坐标，这是因为该方法在通过图像检测获得感兴趣区域后，会根据此区域内的三维立体信息判断是否为真正的

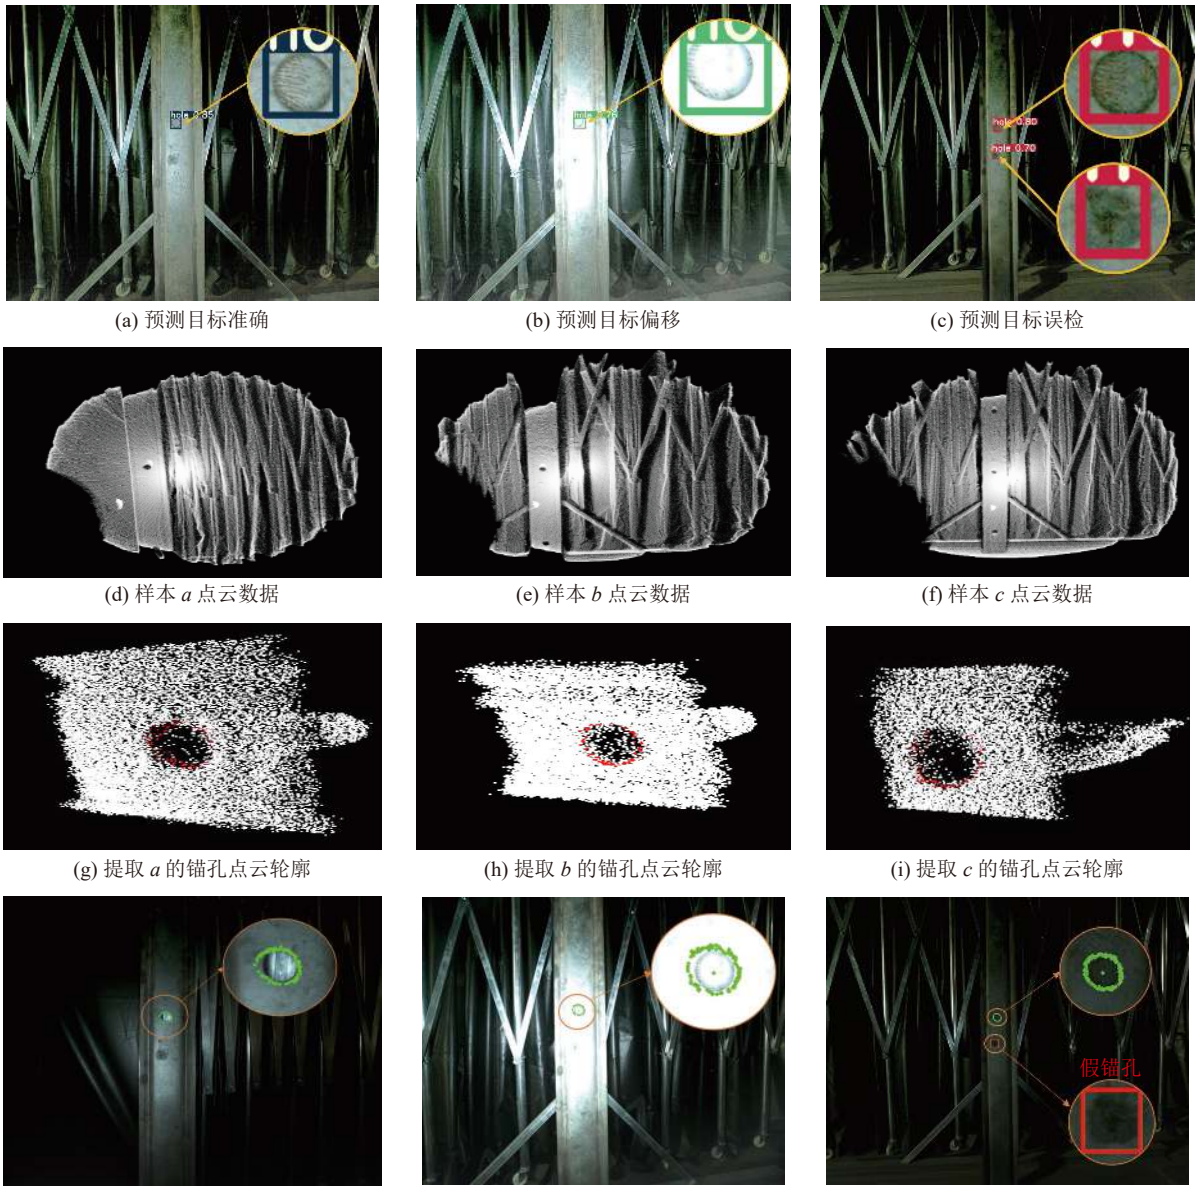

(a) 预测目标准确　(b) 预测目标偏移　(c) 预测目标误检

(d) 样本 *a* 点云数据　(e) 样本 *b* 点云数据　(f) 样本 *c* 点云数据

(g) 提取 *a* 的锚孔点云轮廓　(h) 提取 *b* 的锚孔点云轮廓　(i) 提取 *c* 的锚孔点云轮廓

(j) 样本 *a* 的点云投影　(k) 样本 *b* 的点云投影　(l) 样本 *c* 的点云投影

图 13　锚孔融合检测结果

Fig.13　Fusion test results of steel strip anchor hole

锚孔，然后对真实的锚孔进行定位，且定位过程中因视觉检测偏移而导致的锚孔点云残缺或冗余仍不会影响锚孔定位精度，锚孔定位鲁棒性高。文中方法受外界条件的影响较小，准确率和定位精度更高。

目前常用的单视觉方法采用改进的 YOLOv7-tiny+Depth 实现，该方法先使用改进的 YOLOv7-tiny 检测得到锚孔的中心坐标，然后通过双目定位等方法获取对应的深度信息完成锚孔定位。将单视觉方法和文中方法进行对比，并将 2 种算法部署到边缘计算设备上，测试验证了在多组试验场景下的有效性。表 3 是改进的 YOLOv7-tiny+Depth 定位方法和文中定位算法在不同场景下的检测结果对比，通过计算真实点和测量点的空间直线距离，YOLOv7-tiny+Depth 的平均定位误差为 4.3 mm，而文中算法得到的平均定位误差为 3 mm（钢带锚孔直径为 40 mm，根据锚护工艺的要求，锚孔定位精度在 4 mm 以内即可满足要求）；文中方法的平均识别时间与视觉检测到的锚孔数量相关，点云处理每个锚孔的平均检测时间约为 0.5 s，而视觉识别检测的平均时间为 0.27 s，故对于单锚孔系统的识别检测时间为 0.77 s。相比而言，文中方法的定位精度和鲁棒性更高，尤其是在当锚孔孔径小和外界干扰导致位置偏差的情况下，基本能够消除外界干扰的影响，但相应地对每一帧数据的处理时间较长。对于锚孔定位这一实时性要求不高的任务来说，锚孔定位精度和识别准确是更加重要的问题。

另外，锚杆实际长度较长，若锚固作业过程中没有指定机械臂的锚固姿态，则锚杆无法沿着锚孔方向顺利打入，易发生安全事故。而文中方法能获取锚孔的法向量，机械臂轨迹规划时可以根据锚孔的位置和法向量调整锚护位置和姿态。相对地，目前的视觉定位方法仅能获取三维坐标，无法完全实现机械臂自主锚护作业。因此，笔者提出的算法更能满足锚孔定位要求，极大地提高了锚固作业的安全性。

表 3　不同场景下算法定位情况对比

Table 3　Comparison of algorithm positioning accuracy in different scenarios

场景序号	识别算法	实际坐标/m	检测坐标/m	误差/mm	锚孔法向量	识别时间/s
a	改进的YOLOv7-tiny+Depth	(1.110 0,0.134 0,0.098 0)	(1.109 9,0.132 7,0.108 1)	(1.1,1.3,2.1)	—	0.43
	改进的YOLOv7-tiny+Lidar	(1.108 0,0.167 0,0.086 0)	(1.109 2,0.165 3,0.088 8)	(1.2,1.7,1.8)	(−0.874 4,−0.402 7,0.270 3)	0.77
b	改进的YOLOv7-tiny+Depth	(1.127 0,0.130 0,0.126 0)	(1.131 7,0.135 1,0.130 2)	(4.7,5.1,4.2)	—	0.43
	改进的YOLOv7-tiny+Lidar	(1.128 0,0.168 0,0.119 0)	(1.130 2,0.169 5,0.117 6)	(2.2,1.5,1.4)	(−0.987 9,−0.151 8,−0.031 2)	0.75
c	改进的YOLOv7-tiny+Depth	(1.593 0,0.087 0,0.150 0)	(1.595 0,0.085 5,0.151 6)	(2.0,1.5,1.6)	—	0.44
		—	(1.589 3,0,0632,0.619)	—	—	
	改进的YOLOv7-tiny+Lidar	(1.596 0,0.116 0,0.141 0)	(1.594 8,0.117 2,0.142 7)	(1.2,0.8,1.7)	(0.987 4,0.157 9,0)	1.28

3　结　　论

1）基于 YOLOv7-tiny 这一轻量级网络，引入 IA 增强模块和添加 SimAM 机制，降低了水雾粉尘和低照度环境的噪声和干扰，突出了锚孔特征信息，利用锚孔特征来识别相似的特征图，并加强相似的特征图之间的关联性，提高了锚孔在复杂环境下的鲁棒性和检测精度。

2）提出了基于相机图像和激光雷达点云融合的煤矿巷道锚孔定位方法，融合了图像的丰富语义特征和点云的准确空间特征，提高了系统的数据冗余性和容错性。

3）与单一视觉方法相比，激光与视觉多源融合的方法降低环境带来的定位偏差的同时还可以根据深度差判断得到真实锚孔的三维坐标、获取锚孔法向量，用于指导后续机械臂调整作业姿态。

4）将模型部署到锚杆台车机械臂锚孔定位试验平台上进行模拟试验，试验结果表明，通过计算真实锚孔点和测量点的空间直线距离，得到平均定位误差为 3 mm，单锚孔情况下基于激光雷达和相机系统的平均定位时间为 0.77 s，满足井下锚孔定位的要求。

参考文献(References):

[1] 葛世荣，郝尚清，张世洪，等. 我国智能化采煤技术现状及待突破关键技术[J]. 煤炭科学技术，2020，48(7)：28−46.
GE Shirong, HAO Shangqing, ZHANG Shihong, *et al*. Status of intelligent coal mining technology and potential key technologies in China[J]. Coal Science and Technology, 2020, 48(7): 28−46.

[2] 唐恩贤，张玉良，马　骋. 煤矿智能化开采技术研究现状及展望[J]. 煤炭科学技术，2019，47(10)：111−115.
TANG Enxian, ZHANG Yuliang, MA Cheng. Research status and

development prospect of intelligent mining technology in coal mine[J]. Coal Science and Technology, 2019, 47(10): 111−115.

[3] 王步康. 煤矿巷道掘进技术与装备的现状及趋势分析[J]. 煤炭科学技术, 2020, 48(11): 1−11.
WANG Bukang. Current status and trend analysis of readway driving technology and equipment in coal mine[J]. Coal Science and Technology, 2020, 48(11): 1−11.

[4] 康红普. 我国煤矿巷道锚杆支护技术发展 60 年及展望[J]. 中国矿业大学学报, 2016, 45(6): 1071−1081.
KANG Hongpu. Sixty years development and prospects of rock bolting technology for underground coal mine roadways in China[J]. Journal of China University of Mining & Technology, 2016, 45(6): 1071−1081.

[5] 高志强, 郭治富. 国内外自动锚杆钻架类型特点及研究方向[J]. 煤炭科学技术, 2023, 51(3): 212−224.
GAO Zhiqiang, GUO Zhifu. Type characteristics and research direction of automatic bolting frame[J]. Coal Science and Technology, 2023, 51(3): 212−224.

[6] 康红普, 姜鹏飞, 刘 畅, 等. 煤巷锚杆支护施工装备现状及发展趋势[J]. 工矿自动化, 2023, 49(1): 1−18.
KANG Hongpu, JIANG Pengfei, LIU Chang, *et al*. Current situation and development trend of rock bolting construction equipment in coal roadway[J]. Journal of Mine Automation, 2023, 49(1): 1−18.

[7] 马宏伟, 王 鹏, 王世斌, 等. 煤矿掘进机器人系统智能并行协同控制方法[J]. 煤炭学报, 2021, 46(7): 2057−2067.
MA Hongwei, WANG Peng, WANG Shibin, *et al*. Intelligent parallel cooperative control method of coal mine excavation robot system[J]. Journal of China Coal Society, 2021, 46(7): 2057−2067.

[8] 马宏伟, 孙思雅, 王川伟, 等. 多机械臂多钻机协作的煤矿巷道钻锚机器人关键技术[J]. 煤炭学报, 2023, 48(1): 497−509.
MA Hongwei, SUN Siya, WANG Chuanwei, *et al*. Key technology of drilling anchor robot with multi-manipulator and multi-rig cooperation in the coal mine roadway[J]. Journal of China Coal Society, 2023, 48(1): 497−509.

[9] 乔佳伟. 基于机器视觉的煤矿井下锚护作业钢带孔识别研究[D]. 北京: 煤炭科学研究总院, 2022: 39−57.
QIAO Jiawei. Research on the identification of steel belt holes for underground anchoring operations in coal mines based on machine vision[D]. Beijing: China Coal Research Institute, 2022: 39−57.

[10] 张夫净, 王宏伟, 王浩然, 等. 煤矿巷道支护钢带锚孔智能识别与定位[J]. 工矿自动化, 2022, 48(10): 76−81.
ZHANG Fujing, WANG Hongwei, WANG Haoran, *et al*. Intelligent identification and positioning of steel belt anchor hole in coal mine roadway support[J]. Journal of Mine Automation, 2022, 48(10): 76−81.

[11] 雷孟宇, 张旭辉, 杨文娟, 等. 煤矿掘进装备视觉位姿检测与控制研究现状与趋势[J]. 煤炭学报, 2021, 46(S2): 1135−1148.
LEI Mengyu, ZHANG Xuhui, YANG Wenjuan, *et al*. Present situation and trend of research on visual pose detection and control of coal mine tunneling equipment[J]. Journal of China Coal Society, 2021, 46(S2): 1135−1148.

[12] ZHUANG Z W, LI R, JIA K, *et al*. Perception-aware multi-sensor fusion for 3D LiDAR semantic segmentation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada. IEEE, 2021: 16260−16270.

[13] SUBEDI D, JHA A, TYAPIN I, *et al*. Camera-LiDAR data fusion for autonomous mooring operation[C]//2020 15th IEEE Conference on Industrial Electronics and Applications (ICIEA). Kristiansand, Norway. IEEE, 2020: 1176−1181.

[14] QI C R, LIU W, WU C X, *et al*. Frustum PointNets for 3D object detection from RGB-D data[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 918−927.

[15] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[EB/OL]. 2022: 2207.02696. http://arxiv.org/abs/2207.02696v1

[16] 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, 2017, 39(6): 1137−1149.

[17] LIU W Y, REN G F, YU R S, *et al*. Image-adaptive YOLO for object detection in adverse weather conditions[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(2): 1792−1800.

[18] YANG Lingxiao, ZHANG Ruruan, LI Lida, *et al*. SimAM: a simple, parameter-free attention module for convolutional neural networks[C]//Processing of the 38th International Conference on Machine Learning, PMLR, 2021, 139: 11863−11874.

[19] ZHENG C R, ZHU Q Y, XU W, *et al*. FAST-LIVO: fast and tightly-coupled sparse-direct LiDAR-inertial-visual odometry[C]//2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Kyoto, Japan. IEEE, 2022: 4003−4009.

[20] ZHANG Z. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330−1334.

[21] 高 翔, 张 涛, 刘 毅, 等. 视觉 SLAM 十四讲: 从理论到实践 [M]. 北京: 电子工业出版社, 2017: 64−75.

[22] YUAN C J, LIU X Y, HONG X P, *et al*. Pixel-level extrinsic self calibration of high resolution LiDAR and camera in targetless environments[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 7517−7524.

[23] 张改莲. 基于 PLC 的锚杆钻机智能可视化控制系统应用研究[J]. 机床与液压, 2018, 46(16): 130−132, 129.
ZHANG Gailian. Intelligent visualization of anchor drill based on PLC[J]. Machine Tool & Hydraulics, 2018, 46(16): 130−132, 129.