



## 暗环境适应性的基于SLAM的煤矿井下机器人定位方法

江松 崔智翔 代碧波 饶彬舰 何润丰 王浩宇

### 引用本文:

江松, 崔智翔, 代碧波, 等. 暗环境适应性的基于SLAM的煤矿井下机器人定位方法[J]. 煤炭科学技术, 2025, 53(5): 349–361.

JIANG Song, CUI Zhixiang, DAI Bibo. SLAM-based localization method of coal mine underground robot with adaptability to dark illumination environment[J]. Coal Science and Technology, 2025, 53(5): 349–361.

在线阅读 View online: <https://doi.org/10.12438/cst.2024-0181>

### 您可能感兴趣的其他文章

#### Articles you may be interested in

#### 煤矿井下移动机器人激光标靶定位方法研究

Research on laser target positioning method for underground mobile robot in coal mine

煤炭科学技术. 2024, 52(11): 60–73 <https://doi.org/10.12438/cst.2024-1008>

#### 煤矿巷道机器人管线视觉辅助定位与导航方法研究

Study on pipeline vision-aided positioning and navigation method for coal mine tunnel robot

煤炭科学技术. 2020, 48(7) <http://www.mtkxjs.com.cn/article/id/01ed6eb5-0a6a-4459-a2fa-e6cea335abaf>

#### 煤矿机器人智能安全充电系统设计

Design of intelligent safety charging system for coal mining robot

煤炭科学技术. 2020, 48(2) <http://www.mtkxjs.com.cn/article/id/46ff2825-4997-4d33-9cce-9a72781ae5e3>

#### 煤矿机器人视觉系统除尘方法研究

Research on dust removal method for vision system of coal mine robot

煤炭科学技术. 2020, 48(7) <http://www.mtkxjs.com.cn/article/id/5466aaaa-b323-4339-92be-207e52e90944>

#### 基于激光雷达的煤矿井下车场地图融合构建方法研究

Lidar based map construction fusion method for underground coal mine shaft bottom

煤炭科学技术. 2023, 51(8): 219–227 <https://doi.org/10.13199/j.cnki.cst.2022-1111>

#### 煤矿带式输送机巡检机器人关键技术研究

Research on key technology of inspection robot for coal mine belt conveyor

煤炭科学技术. 2022, 50(5) <http://www.mtkxjs.com.cn/article/id/9cb74dfd-f1b2-4afc-89b2-2a92684bdaa2>



关注微信公众号, 获得更多资讯信息



移动扫码阅读

江 松, 崔智翔, 代碧波, 等. 暗环境适应性的基于 SLAM 的煤矿井下机器人定位方法[J]. 煤炭科学技术, 2025, 53(5): 349–361.

JIANG Song, CUI Zhixiang, DAI Bibo, *et al.* SLAM-based localization method of coal mine underground robot with adaptability to dark illumination environment[J]. Coal Science and Technology, 2025, 53(5): 349–361.

## 暗环境适应性的基于 SLAM 的煤矿井下机器人定位方法

江 松<sup>1,2,3</sup>, 崔智翔<sup>1,2</sup>, 代碧波<sup>3</sup>, 饶彬舰<sup>2,4</sup>, 何润丰<sup>2,4</sup>, 王浩宇<sup>1</sup>

(1. 西安建筑科技大学 资源工程学院, 陕西 西安 710055; 2. 西安市智慧工业感知、计算与决策重点实验室, 陕西 西安 710055;  
3. 金属矿山安全与健康国家重点实验室, 安徽 马鞍山 243000; 4. 西安建筑科技大学 管理学院 陕西 西安 710055)

**摘 要:** 在智慧矿山建设的背景下, 智能化设备的应用日益成为矿山智慧化改造的主要内容, 用于巡检、危险区域勘测等任务的煤矿井下智能机器人运行依赖于数字地图构建和机器人自身定位, 但大多数传统的定位方法在煤矿井下出现了低效甚至失效的情况, 同步定位与建图技术 (Simultaneous Localization and Mapping, SLAM) 成为了煤矿井下智能机器人定位方法的较优选择。然而, 受制于激光雷达的高成本, 以及相机在井下的低光照环境性能不佳, 需要设计一种兼顾低成本和具有井下低光照环境适应性的 SLAM 定位方法, 故提出了一种具有井下暗光照适应性煤矿井下机器人定位方法。首先, 采集了陕西省宝鸡市凤县某煤矿井下的实景图像和 SLAM 所需的相机与 IMU 数据, 根据图像制作了非匹配的暗光与正常光数据集, 经过数据扩增达到 3 560 张图像。设计了结合自注意力模块的 EnlightenGAN 图像增强网络, 在不依赖配对数据集的情况下兼顾图像不同区域的依赖关系应对图像光照不均区域。在 ORB-SLAM3 框架的基础上, 引入全局部图像检测对输入图像进行筛分, 引入基于解析解的 IMU 初始化改进策略提高初始化速度, 并引入了改进的图像增强网络对低光照以及光照不均的图像进行增强处理。在 EuRoC 数据集上的试验表明, 基于图像增强的煤矿井下智能机器人定位方法能够在低光照环境下降低 13.7% 的  $E_{RMS}$  和 15.24% 的  $E_{SD}$ 。在 2 个实际煤矿巷道场景中, 系统能够识别低光照环境、增加 SLAM 系统提取的特征点数量, 减少定位轨迹的漂移现象, 最终改善系统在巷道低光照区域的定位效果。

**关键词:** 同步建图与定位; 井下煤矿; 煤矿机器人; 图像增强

中图分类号: TD67; TP242

文献标志码: A

文章编号: 0253-2336(2025)05-0349-13

### SLAM-based localization method of coal mine underground robot with adaptability to dark illumination environment

JIANG Song<sup>1,2,3</sup>, CUI Zhixiang<sup>1,2</sup>, DAI Bibo<sup>3</sup>, RAO Binjian<sup>2,4</sup>, HE Runfeng<sup>2,4</sup>, WANG Haoyu<sup>1</sup>

(1. School of Resources Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China; 2. Key Laboratory of Perception, Computing and Decision Making for Intelligent Industry, Xi'an 710055, China; 3. State Key Laboratory of Safety and Health for Metal Mines, Maanshan 243000, China; 4. School of Management, Xi'an University of Architecture and Technology, Xi'an 710055, China)

**Abstract:** Under the background of intelligent mine construction, the application of intelligent equipment has increasingly become the main content of mine intelligent transformation. Intelligent robots in coal mine that are designed for inspecting and dangerous area surveying and doing other tasks depends on the construction of digital map of underground coal mine and the localizing of the robot itself. But most of the traditional localizing methods are inefficient or even ineffective in the underground. Simultaneous Localization and Mapping (SLAM) has become a better choice for underground intelligent robot localization methods. However, due to the high cost of lidar and the poor performance of camera in low illumination environment, it is necessary to design a SLAM localization method that takes into ac-

收稿日期: 2024-02-03 策划编辑: 常 琛 责任编辑: 钱小静 DOI: 10.12438/cst.2024-0181

基金项目: 国家自然科学基金青年基金资助项目 (52104146); 国家自然科学基金面上资助项目 (52374136)

作者简介: 江 松 (1990—), 男, 江西鄱阳人, 教授, 博士后。E-mail: jiangsong@xauat.edu.cn

通讯作者: 崔智翔 (2000—), 男, 陕西西安人, 硕士研究生。E-mail: czx0317@foxmail.com

count both low cost and adaptability to low illumination environment. Therefore, a localization method of robot with underground dark light environment adaptability in coal mine is proposed. Firstly, the real images of the gallery of a coal mine in Fengxian County, Baoji City, Shaanxi Province and the dataset of the camera and IMU required for SLAM were collected. According to the images, non-matching dark light and normal light dataset was made, and 3 560 images were obtained after data amplification. An EnlightenGAN image enhancement network combined with self-attention module is designed, which takes into account the dependence of different regions of the image without relying on the paired dataset. Based on the ORB-SLAM3 framework, the whole local image detection is introduced to screen the input image, and an improved IMU initialization strategy based on analytical solution is introduced to improve the initialization speed, and the improved image enhancement network is transplanted to enhance the low illumination and uneven illumination images. Experiments on the EuRoC dataset show that the image enhancement-based underground coal mine robot localization method can reduce  $E_{RMS}$  by 12.17% and  $E_{SD}$  by 14.35% in low-light environments. In two actual coal mine roadway scenarios, the low-light environment can be identified, and the increasing number of feature points are extracted and the drift phenomenon of positioning trajectory is reduced by the SLAM system and. Finally, the localizing effect of the system is improved in the dark area of the roadway.

**Key words:** simultaneous localization and mapping; underground coal mine; coal mine robot; image enhancement

## 0 引言

随着智能矿山、智慧矿山建设理论的提出,传统煤矿开采进入了智能化和智慧化转型阶段。环保、智能化装备和低碳、无人化流程逐渐渗透到采矿工程的各个环节之中,推动了采矿设计、计划、生产、调度及决策等过程的智能化进程。智能机器人技术在采矿工程中的应用主要集中在挖掘、地面运输、钻孔和炸药部署作业等,其能够有效提高生产率、安全性,通过长期应用可以达到降低生产成本的效果。特别是对于黑暗、充满扬尘、地形崎岖和泥土覆盖面积大的井下煤矿环境而言,部署自动化、智能化机器人能够有效应对井下工作场地巡检<sup>[1]</sup>、未知环境探勘<sup>[2]</sup>、危险区域救援<sup>[3]</sup>等重要工作。

在煤矿巷道、采空区等这种不具有可预测性的复杂环境中,现有的机器人定位方法受到限制:GPS信号无法到达;恶劣的环境导致射频识别定位、Zig-Bee定位等主流定位技术在井下失效或者效果不佳;在煤矿灾害现场,甚至失去了先验路标和地图的可靠性。基于以上问题,亟需机器人利用依靠多传感器和周围环境信息来对自身进行定位的SLAM技术来解决机器人在煤矿井下无网络条件下的数字地图构建和定位问题。以相机作为主传感器的视觉SLAM(Visual SLAM)虽然成本可观,但对暗光照、光照变化剧烈、动态环境等事件敏感,需要针对煤矿井下环境提出相应的解决方案。随着深度学习在计算机视觉领域的突破,SLAM系统能够借助深度学习框架克服系统原有的不足<sup>[4]</sup>,从而提供更具有鲁棒性的定位方案。

矿山井下场景图像往往会出现对比度低、色彩失真、噪点等多种退化现象。图像增强的目的是在原始图像的基础上通过灰度变换、滤波等方法选择

性的突出图像中感兴趣的区域,抑制噪声和不感兴趣的区域,以提高图像质量<sup>[5]</sup>。LORE等<sup>[6]</sup>首次提出端到端的深度学习方法来增强低照度图像,但增强后的图像雾化现象明显。ZHANG等<sup>[7]</sup>基于分解的学习方法,将图像分解为反射率分量和光照分量解决图像伪影问题,但却加重了图像的模糊度。孔二伟等<sup>[8]</sup>设计了融合特征提取模块、增强模块的卷积神经网络(Convolutional Neural Networks, CNN),在提高煤矿井下低照度图像的同时抑制了曝光过度和噪声。大多数基于深度学习的图像增强算法严重依赖配对的数据集,而在弱光和正常光照条件下收集同一场景的配对图像存在一定难度,于是一些采用无监督学习方法的图像增强任务逐渐被研究人员重视。MENG等<sup>[9]</sup>基于GAN<sup>[10]</sup>网络利用对抗损失,感知损失和总变化损失作为约束建立网络,搭建了夜间图像增强框架。JIANG等<sup>[11]</sup>采用注意力引导的U-net为生成器,并使用对偶判别器来引导全局和局部信息,实现包括照明增强和噪声抑制,以完全无监督的方式增强现实世界的低光图像,在保持模型轻量的同时,避免了对配对数据集的依赖。

SLAM系统利用移动机器人自身搭载的传感器获取环境信息,并构建数字地图,以此对环境进行映射;同时再利用这些信息进行自主定位,以服务于后续的自主导航等工作。视觉SLAM一般使用单目相机、双目相机、深度相机(RGB-D)三大类视觉传感器作为主传感器,以拍摄的视频或连续帧作为输入数据。2007年,KLEIN等<sup>[12]</sup>提出了第1个正式的单目视觉SLAM,启发了后来的多种相机SLAM<sup>[13]</sup>、多线程SLAM<sup>[14]</sup>等研究。但单个运作的传感器极易受到环境干扰,导致定位失败,由加速度计和陀螺仪组成的惯性测量单元(Inertial Measurement Unit, IMU)能够补偿视觉SLAM缺失的尺度因子并计算自身相

对运动,提高算法前后端性能。MUR-ARTALD 等<sup>[15]</sup>在文献 [16] 的基础上引入了双目和 RGB-D 相机,但存在对噪声敏感的问题,特征点容易跟踪丢失。

在矿山场景下,郭科等<sup>[16]</sup>利用匹配特征在像素坐标系上的平均移动来计算并评判  $E_{BL}$  参数以减小模糊帧对前端的影响,但该方法中的帧移除算法会剔除过多的图像,可能导致系统跟踪失败。ZHU 等<sup>[17]</sup>改进了 ORB 特征和直线特征进行特征匹配,以应对场景结构退化和光照不足的情况,减少了由于快速运动而造成的特征损失。高扬等<sup>[18]</sup>将 RFAST 模块融入 VINS-Mono 框架中,在夜间的汽车定位精度取得了显著提高。CHEN 等<sup>[19]</sup>基于局部残差运动模糊判别网络检测模糊图像,QUAN 等<sup>[20]</sup>利用 3D CNN 提高视觉 SLAM 的特征提取和匹配质量,均证明了基于深度学习的图像增强能够提高 SLAM 系统准确性和稳定性。

鉴于以上研究,笔者基于具有较强鲁棒性的 ORB-SLAM3,提出适用于煤矿井下的 FitCoalMine-SLAM(FCM-SLAM)。为解决视觉里程计类算法因煤矿井下暗光照环境导致的特征不充分、图像匹配失败甚至跟踪丢失等问题,选用自注意力模块改进的无监督学习的 EnlightenGAN 作为系统图像增强模块,同时可以减小对成对数据集的依赖并保证轻量化。引入基于解析解的 IMU 初始化方法以优化系统在煤矿井下环境下的响应速度。最终,提升视觉 SLAM 算法在煤矿井下的适用性。

## 1 基于 ORB-SLAM3 改进的 FCM-SLAM 算法

FCM-SLAM 主要包含 4 个模块:图像增强、跟踪、局部建图和回环检测。在户外场景中,原本的 ORB-SLAM3 框架可以达到很高的定位精度,其通过提取 ORB 特征,利用对极约束原理利用两张图像来求得转移矩阵  $T$ (包括了旋转矩阵  $R$  和平移矩阵  $t$ ) 以获得相机位姿,如图 1 所示。通过三角测量将相机位姿结合帧间像素坐标计算出 3D 点坐标,以获得整体的位姿信息和地图点。在后续的跟踪、定位流程中,关键帧所包含的位姿和地图点信息就尤为重要,较低质量的描述子将严重影响系统的定位精度。而在煤矿井下等极端环境(易出现暗光照、光照不均和粉尘等现象)中,输入系统的图像极易出现纹理信息缺失的现象,导致 SLAM 系统前端的特征提取困难,关键帧之间的匹配效果较差,最终致使系统的定位精度降低。

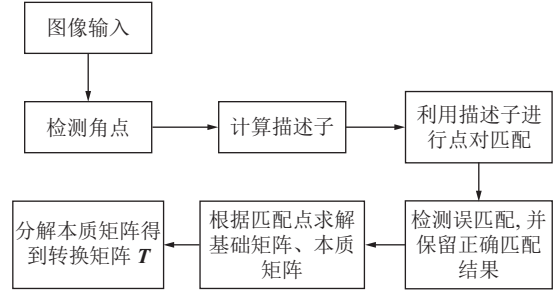


图 1 对极约束求得相机位姿流程

Fig.1 Polar constraint to obtain the camera pose process

原本的 ORB-SLAM3 系统主要通过视觉传感器与 IMU 实现进行定位,不依赖于先验地图信息。然而,在实际煤矿井下的运行中,机器人在移动时未能有良好的运动激励,即在  $xyz$  三轴上的运动不够充分。此外,为了使 IMU 拥有较好初始参数,原系统整个 IMU 初始化以及视觉惯性里程计优化 (Visual-Inertial Bundle Adjustment, VIBA) 最少需要 15 s 才能完成初始化。这 2 个原因导致系统经常面临初始化重置的情况,如图 2 所示。



图 2 ORB-SLAM3 系统初始化失败后重置

Fig.2 ORB-SLAM3 system's reset after initialization failure

为了改善视觉 SLAM 系统在煤矿井下出现的以上问题,本文基于 ORB-SLAM3 框架,融入了图像亮度检测和融合自注意力模块的 EnlightenGAN 图像增强模块以改善特征提取效果差的情况。同时在系统 IMU 初始化部分引入解析解方法求解初始化参数,以改善 SLAM 系统在煤矿井下的定位性能。FCM-SLAM 整体框架如图 3 所示。

### 1.1 基于 EnlightenGAN 的图像增强模块

#### 1.1.1 生成式对抗网络 (Generative Adversarial Networks, GAN)

GAN 为 10 a 以来最具前景的无监督学习方法之一,模型框架灵感来自于纳什均衡,通过两个互相博弈的模块:生成模型 (Generative Model, G) 和判别模型 (Discriminative Model, D) 之间的互相博弈学习产生输出,其中判别模型用于判断对象真假,即是否由生成器生成;生成模型用于生成对象,最终目的是






图 4 图像亮度检测过程  
Fig.4 Image brightness detection process

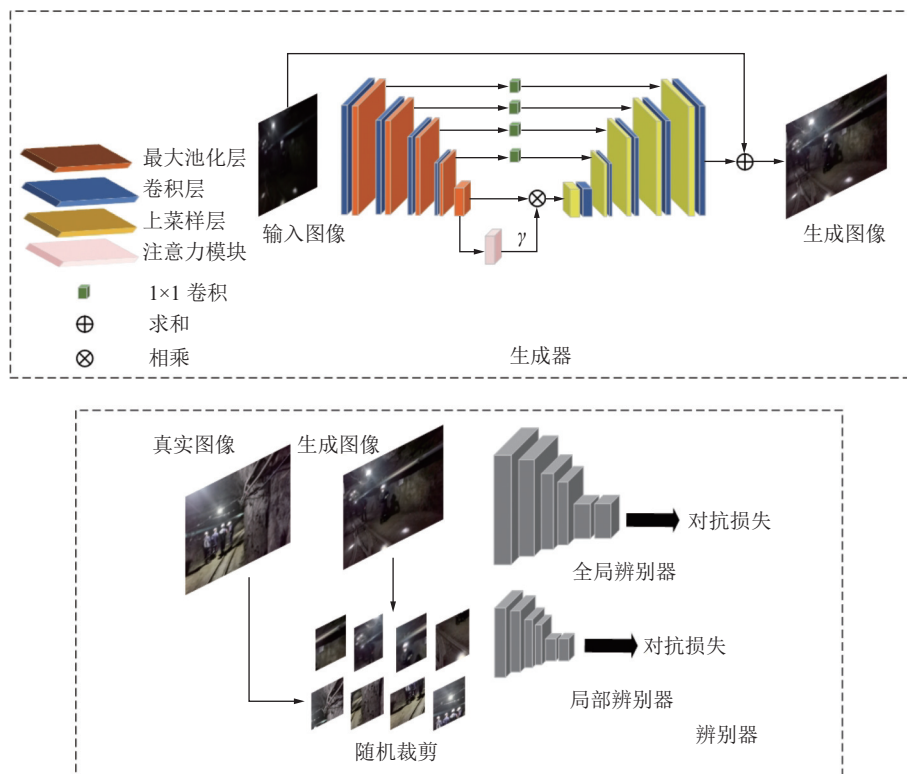


图 5 改进的 EnlightenGAN 网络结构  
Fig.5 Improved EnlightenGAN network structure

输入的暗光图像;  $W_{ij}$  和  $H_{ij}$  为提取的特征图的大小。

网络判别器采用双尺度判别器引导全局和局部信息,除了将真实图像和生成图像作整张图像的对抗损失外,也将 2 张图像进行随机裁剪,以改善网络

在光照不均情况下的图像增强能力,全局判别器损失函数  $L_D^{Global}$ 、局部判别器损失函数  $L_D^{Local}$  为

$$L_D^{Global} = E_{x_r \sim P_{real}} [(D_{Ra}(x_r, x_f) - 1)]^2 + E_{x_r \sim P_{fake}} [D_{Ra}(x_r, x_r)]^2 \quad (6)$$

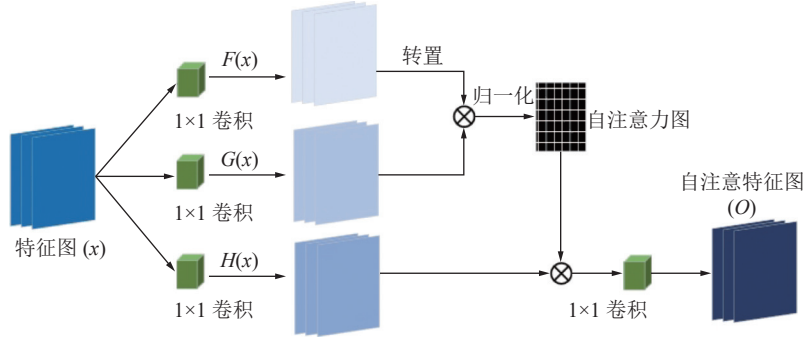


图 6 自注意力模块

Fig.6 Self-attention module

$$L_D^{\text{Local}} = E_{x_i \sim P_{\text{real\_patches}}} [(D(x_i) - 1)]^2 + E_{x_i \sim P_{\text{fake\_patches}}} [(D(x_i) - 0)]^2 \quad (7)$$

自注意力模块中, 自注意力图

$$\beta_{ji} = \frac{\exp(s_{ij})}{\sum_{i=1}^N \exp(s_{ij})}, \text{ where } s_{ij} = F(x_i)^T G(x_j) \quad (8)$$

式中:  $\beta_{ji}$  为合成第  $j$  个区域时, 模块对第  $i$  个位置的关注程度。

借此与原特征图做内积, 即将图像全局空间信息和局部信息整合到一起, 得到

$$O_j = \sum_{i=1}^N \beta_{ji} H(x_i) \quad (9)$$

最后, 如图 5 所示,  $\gamma$  为尺度参数, 初始值为 0, 令网络先学习局部特征, 在后续的训练中再逐步增加权重以学习全局特征。最终得到的输出为

$$\gamma O_i + x_i \quad (10)$$

## 1.2 基于解析解的 IMU 初始化方法

本文引入基于解析解的 IMU 初始化方法<sup>[22]</sup>, 以最大似然 (Maximum Likelihood Estimation, MLE) 框架而非迭代求得加速度计偏置、重力方向和尺度因子, 以求更高效地求得 IMU 初始化参数、完成整个系统的初始化。

首先根据陀螺仪测量值和  $k$ 、 $k+1$  时刻关键帧方向估计陀螺仪偏差, 定义预积分残差为

$$r_k^s(x) = \log \left[ \left( \Delta R_{k,k+1} \exp(J_{\Delta R}^s x) \right)^T R_k^T R_{k+1} \right] \quad (11)$$

其中,  $\log()$  为 SO(3) 指数映射的逆;  $\Delta R_{k,k+1}$  为通过预积分得到的  $k$  到  $k+1$  时刻的旋转测量值;  $R_k$  和  $P_k$  分别为 IMU 在关键帧  $k$  时的旋转和位姿;  $J_{\Delta R}^s$  为旋转预积分相对于陀螺仪偏差的雅可比矩阵。然后, 通过 g2o 迭代求解优化问题为

$$X_g^* = \operatorname{argmin}_{b^s} \sum_{k \in \mathcal{K}} r_k^s(b^s) \sum_k \quad (12)$$

其中,  $\sum_k$  为协方差矩阵。得到陀螺仪偏置  $b^s$ 。

然后, 从测量的加速度和相对姿态中找到加速度计偏差  $b^a$ 、重力方向  $g$  和重建的尺度因子  $s$ , 且考虑 3 个连续关键帧以降低复杂度。定义加速度计残差为

$$r_k^a(x) = \begin{bmatrix} \alpha_k & A_k & B_k \end{bmatrix} x - \pi_k \quad (13)$$

其中,

$$x = [s, b^a, g]^T \quad (14)$$

$$A_k = \frac{R_{k-1} J_{\Delta p_{k-1,k}}^a}{\Delta t_{k-1,k}} - \frac{R_k J_{\Delta p_{k,k+1}}^a}{\Delta t_{k,k+1}} - R_{k-1} J_{\Delta v_{k-1,k}}^a \quad (15)$$

$$B_k = -\frac{1}{2} (\Delta t_{k-1,k} + \Delta t_{k,k+1}) I_{3 \times 3} \quad (16)$$

$$\alpha_k = \frac{\bar{p}_{k+1} - \bar{p}_k}{\Delta t_{k,k+1}} - \frac{\bar{p}_k - \bar{p}_{k-1}}{\Delta t_{k-1,k}} \quad (17)$$

$$\pi_k = \frac{R_k \Delta p_{k,k+1}}{\Delta t_{k,k+1}} - \frac{R_{k-1} \Delta p_{k-1,k}}{\Delta t_{k-1,k}} + R_{k-1} \Delta v_{k-1,k} + \frac{(\bar{R}_k - \bar{R}_{k-1}) t_{CB}}{\Delta t_{k-1,k}} - \frac{(\bar{R}_{k+1} - \bar{R}_k)}{\Delta t_{k,k+1}} \quad (18)$$

式 (13) 展开后分别代表旋转、速度和位姿的残差。其中,  $a$  为加速度计;  $\bar{p}_k$  为关键帧  $k$  时刻的位姿;  $\Delta t$  为积分时间;  $J_{\Delta p_{i,j}}^a$  和  $J_{\Delta v_{i,j}}^a$  分别为位姿预积分和速度预积分相对于加速度计偏置的雅可比矩阵;  $\Delta p_{k,k+1}$  为通过预积分得到的  $k$  到  $k+1$  时刻的位姿测量值;  $I_{3 \times 3}$  为  $3 \times 3$  的单位矩阵;  $\Delta v_{k,k+1}$  为通过预积分得到的  $k$  到  $k+1$  时刻的速度测量值;  $\bar{R}_k$  为由视觉系统估计的关键帧  $k$  时刻的旋转方向;  $t_{CB}$  为外参标定参数 (相机相对于机器人主体)。

最后, 以重力向量  $G$  已知为 9.81 的情况下, 通过矩阵计算和拉格朗日乘子法将约束优化问题

$$X_a^* = \operatorname{argmin}_x \sum_{k \in K} \|r_k^a(x)\|_{\Sigma_k}^2 \quad \text{subject to } |g| = G \quad (19)$$

转化为求解多项式的根得到加速度计偏差  $b^a$ ，重力方向  $g$  和尺度因子  $s$ 。

## 2 试验与分析

本文通过将 EuRoC 数据集、实际煤矿井下场景作为试验环境，以验证基于 FCM-SLAM 算法在煤矿井下的定位性能。

自主搭建的煤矿用智能机器人平台如图 7 所示，配备极摩客 M2，内置 i7 11390H CPU、16 G 内存，相机传感器为 OAK-D-PRO-W。操作系统为 Uuntu-20.04，程序在机器人操作系统 ROS(Robot Operation System) 的 Noetic 版本下运行。

### 2.1 图像增强试验验证

#### 2.1.1 图像增强效果分析

为了训练针对煤矿井下的无监督 EnlightenGAN 算法，本文构建了非成对的煤矿井下图像数据集，数据采集于陕西省宝鸡市某煤矿井下。图像数据集由 HuaWei P30Pro 拍摄，分辨率为  $2\,340 \times 1\,080$  像素，在平硐内 1 500 m 范围各个场景进行拍摄，场景包括但不限于巷道、硐室、井下电机车等，并在各个角度以及目标远近进行采样拍摄，确保数据集的真实性。为了优化和扩增数据集，首先人工筛选去除过曝和模糊的图像，再将图像裁剪为  $600 \times 400$  尺寸的



图 7 煤矿用智能机器人平台

Fig.7 Intelligent robot platform for coal mine

图像，尽可能的包含各个场景的图像，并将图像进行  $90^\circ/180^\circ$  翻转、镜像翻转，最终得到 3 560 张图像，从中随机选择光照较暗的 160 张图像作为测试集，剩下的图像组成光照较暗的 trainA 和光照正常的 trainB，数据集部分图像如图 8 所示。网络训练参数见表 1。

为了对比改进后 EnlightenGAN 算法的效果，选取了基于 Retinex 理论的 MSRCR 和卷积神经网络模型 RetinexNet<sup>[23]</sup>、同样轻量不需要配对训练的 Zero-DCE<sup>[24]</sup>、原版 EnlightenGAN 进行对比，选取煤




图 8 井下图像数据集部分图像展示

Fig.8 Partial image display of downhole image dataset

表 1 改进的 EnlightenGAN 训练参数  
Table 1 Improved EnlightenGAN training parameter table

参数	图像尺寸	批量大小	优化器	初始学习率	学习率衰减策略	预训练模型	训练轮数
取值	600×400	16	AdamW	$10^{-4}$	Linear	vgg16	200

矿井下数据测试集的图像进行测试,部分效果图如图 9 所示。所选取测试集存在暗光、光照不均等情况,经过 5 种方法均可以提高图像的亮度,但效果存在差异。MSRCR 方法存在明显的失真,在暗光处也存在较多的噪点。而 RetinexNet 方法出现了对比度严重下降,导致弱化了垃圾桶的边缘特征,在第 2、

第 3 组尤为明显,这显然不利于 SLAM 中的特征点提取。原始的 EnlightenGAN 在处理部分阴影时存在一些明显的噪点,如第 3 组所示。而对比于 Zero-DCE,改进的 EnlightenGAN 算法能够更好地调节曝光细节,满足煤矿井下智能机器人定位系统对输入图像的质量要求。




图 9 不同算法增强效果对比

Fig.9 Comparison of enhancement effects of different algorithms

2.1.2 特征点数量分析

EuRoC 数据集是用微型飞行器上的相机和 IMU 组成的视觉惯性系统收集而得,包含 2 场景子集工业场景 Machine Hall(MH)和房间 Vicon Room(V),常用于特征点提取和 SLAM 系统定位效果的测试,

其中一些子集存在暗光照及光照不均场景,能够检测 FCM-SLAM 对这些场景的适应性。其中 MH04\_difficult、MH05\_difficult 存在正常光照(图 10a)、暗光照(图 10b)部分,以及煤矿井下真实场景(图 10c、图 10d)。如表 2 和图 10 所示,可以发现当环境光照




图 10 特征点提取对比

Fig.10 Comparison of feature point extraction

强度充足时, 图 10a 图像提取到的特征点未发生明显变化, 证明系统在正常光照下能维持稳定的工作性能; 而当环境光照强度较弱时, 图像增强模块大幅改善了低光照下的图像细节不足问题, 使得融合改进的 EnlightenGAN 的 SLAM 系统能够提取的特征点数量明显增加, 这点在暗光环境的井下场景 (图 10c) 较为明显, 这将提高 SLAM 系统的特征匹配精度, 进而提高系统的定位性能。

表 2 特征点数量对比

Table 2 Comparison of the number of feature points

序列	暗光照下平均特征点提取个数		提升幅度/%
	原始图像	增强图像	
MH04	158	225	42.41
MH05	146	230	57.53
井下场景(图10c)	42	119	183.33
井下场景(图10d)	171	212	23.97

## 2.2 SLAM 定位试验验证

### 1) 公开数据集试验验证

EuRoc 数据集的子集 MH 根据微型飞行器的移动速度、环境光照条件分为简单、中等、困难 3 个类型的数据, 共 5 个不同的数据集序列, 对数据集的详细描述如表 2、表 3 所示。

表 3 EuRoc 数据集 MH 子集序列描述  
Table 3 Description of MH subset sequence in EuRoc dataset

数据集序列名称	描述	采集距离/m
MH01_easy	正常运动, 正常光照	80.6
MH02_easy	正常运动, 正常光照	73.5
MH03_medium	快速运动, 存在暗光照	130.9
MH04_difficult	快速运动, 存在暗光照	91.7
MH05_difficult	快速运动, 存在暗光照	97.6

本小节主要验证的是本文算法在暗光条件下的 SLAM 系统定位效果。在公开数据上的测试均在配备 Intel i7 CPU、RTX3060 GPU 和 16 GB 内存的计算机上进行, 软件环境仍为 Uuntu20.04, ROS 版本为 Noetic。图 11、图 12 分别展示了 FCM-SLAM 和原版 ORB-SLAM3 算法在 MH04\_difficult、MH05\_




图 11 MH04 序列运行轨迹对比

Fig.11 Comparison of MH04 sequence trajectory




图 12 MH05 序列运行轨迹对比

Fig.12 Comparison of MH05 sequence trajectory

difficult 子集场景下的运行轨迹对比,其中虚线代表 groundtruth(即实际轨迹),蓝色曲线代表本文算法轨迹,绿色曲线代表原版 ORB-SLAM3 算法运行轨迹。可以看出:本文算法在运动轨迹上更贴近真实轨迹,而原版 ORB-SLAM3 算法在存在暗光条件的区域发生了一定的偏移。

为了定量评估本文算法的优势,使用表示轨迹全局一致性的绝对轨迹误差 (Absolute Trajectory Error,  $E_{AT}$ ) 来评估系统的整体性能,其思想是先将运动轨迹进行对齐,再求取每个状态的均方根误差 (Root Mean Square Error,  $E_{RMS}$ ) 和标准差 (Standard Deviation Error,  $E_{SD}$ )。其中,  $E_{RMS}$  比均值和中位值更能反映系统的准确性和鲁棒性,  $E_{SD}$  能反映系统的稳定性。  $E_{AT}$  定义如下:

$$F_i = Q_i^{-1} S P_i \quad (20)$$

$$E_{RMS}(F_{1:n}) = \sqrt{\left( \frac{1}{n} \sum_{i=1}^n \|\text{trans}(F_i)\|^2 \right)} \quad (21)$$

式中:  $F_i$  为第  $i$  帧的  $E_{AT}$ ;  $Q_i$  为第  $i$  帧真实位姿;  $P_i$  为第  $i$  帧算法估计位姿;  $S$  为从估计位姿到真实位姿的相似转换矩阵;  $\text{trans}(F_i)$  为  $E_{AT}$  中的平移部分。

定量分析选取了同样在视觉 SLAM 领域常用

的 ORB-SLAM2、VINS-Fusion 和原版 ORB-SLAM3 做对比,以量化本文算法在暗光条件下的改进效果,且均采用双目+IMU 模式 (ORB-SLAM2 仅有双目模式)。本文通过对每个序列分别运行 5 次取平均值,得到  $E_{AT}$  的  $E_{RMS}$  和  $E_{SD}$ ,来判断定位精度和系统稳定性。各算法对比结果和本文算法较原版 ORB-SLAM3 的提升见表 4、表 5。可知,算法运行在存在暗光照条件的 MH03\_medium、MH04\_difficult、MH05\_difficult 序列上,  $E_{RMS}$  和  $E_{SD}$  均有了明显的下降,  $E_{RMS}$  平均下降 13.7%,  $E_{SD}$  平均下降 15.24%,充分验证了本文算法在低光照环境下提高系统精度和稳定方面的有效性。而对于正常光照条件下的 MH01\_easy、MH02\_easy 序列,  $E_{RMS}$  和  $E_{SD}$  的变化幅度不大,证明引入的基于解析解的 IMU 初始化方法不会影响 SLAM 的定位性能。

## 2) 实际矿山场景验证

为验证本文算法在井下环境的定位效果,本部分试验数据仍采自于陕西省宝鸡市某煤矿井下,试验平台为图 7 的煤矿用智能机器人平台。试验分为 1、2 两个场景,采集的数据类型为双目视频和 IMU 数据。场景的数据内容均为带有 2 个拐弯处的巷道,其中标记的 A、B、C、D 点为场景中含有的

表 4  $E_{RMS}$  结果对比  
Table 4  $E_{RMS}$  results comparison

序列/算法名称	$E_{RMS}/m$				较ORB-SLAM3 下降幅度/%
	ORB-SLAM2	VINS-Fusion	ORB-SLAM3	FCM-SLAM	
MH01_easy	0.035 8	0.060 2	0.041 4	0.041 5	0.24
MH02_easy	0.018 9	0.066 4	0.034 7	0.033 4	3.75
MH03_medium	0.028 3	0.135 0	0.028 2	0.025 0	11.35
MH04_difficult	0.109 0	0.056 7	0.048 3	0.040 7	15.73
MH05_difficult	0.068 9	0.054 7	0.055 7	0.047 9	14.00

表 5  $E_{SD}$  结果对比  
Table 5  $E_{SD}$  results comparison

序列/算法名称	$E_{SD}/m$				较ORB-SLAM3 下降幅度/%
	ORB-SLAM2	VINS-Fusion	ORB-SLAM3	FCM-SLAM	
MH01_easy	0.020 9	0.097 9	0.015 7	0.014 9	5.10
MH02_easy	0.028 7	0.028 0	0.019 6	0.019 0	3.06
MH03_medium	0.025 5	0.013 9	0.012 8	0.011 4	10.94
MH04_difficult	0.039 9	0.023 0	0.024 2	0.020 1	16.94
MH05_difficult	0.040 2	0.030 2	0.028 6	0.023 5	17.83

暗光照或者光照不均位置,其易导致系统识别到的特征点减少,致使系统跟踪丢失,反映到稀疏点云地图上产生了空白区域,最终导致定位轨迹发生偏移。

如图 13 所示,在 A 点,3 组 SLAM 系统定位效果差异不大,仅 VINS-FUSION 的轨迹发生了一些波动,这是由于 VINS-FUSION 抗干扰能力较差引起的。在 B 点,ORB-SLAM3 较 FCM-SLAM 发生了轨迹偏移,且由于 FCM-SLAM 能够均衡地提高暗光图像亮度,帮助特征点提取模块提取更多的特征

点,反映在稀疏点云上比 ORB-SLAM3 做到了明显的补全效果。而 VINS-FUSION 在经过 B 点后轨迹产生了较明显且危险的漂移现象,偏离机器人真实运动轨迹。由图 14 可知,ORB-SLAM3 在暗光照的 C 点直接发生了严重的漂移,导致整个场景定位失败。VINS-FUSION 虽然未在 C 点发生严重漂移,但也存在定位轨迹的明显波动,经过 D 点时较场景 2 地图相比也发生了明显的偏移。而 FCM-SLAM 在场景 2 下定位轨迹更接近真实运行轨迹,更能满足煤矿井下机器人定位精度的需求。

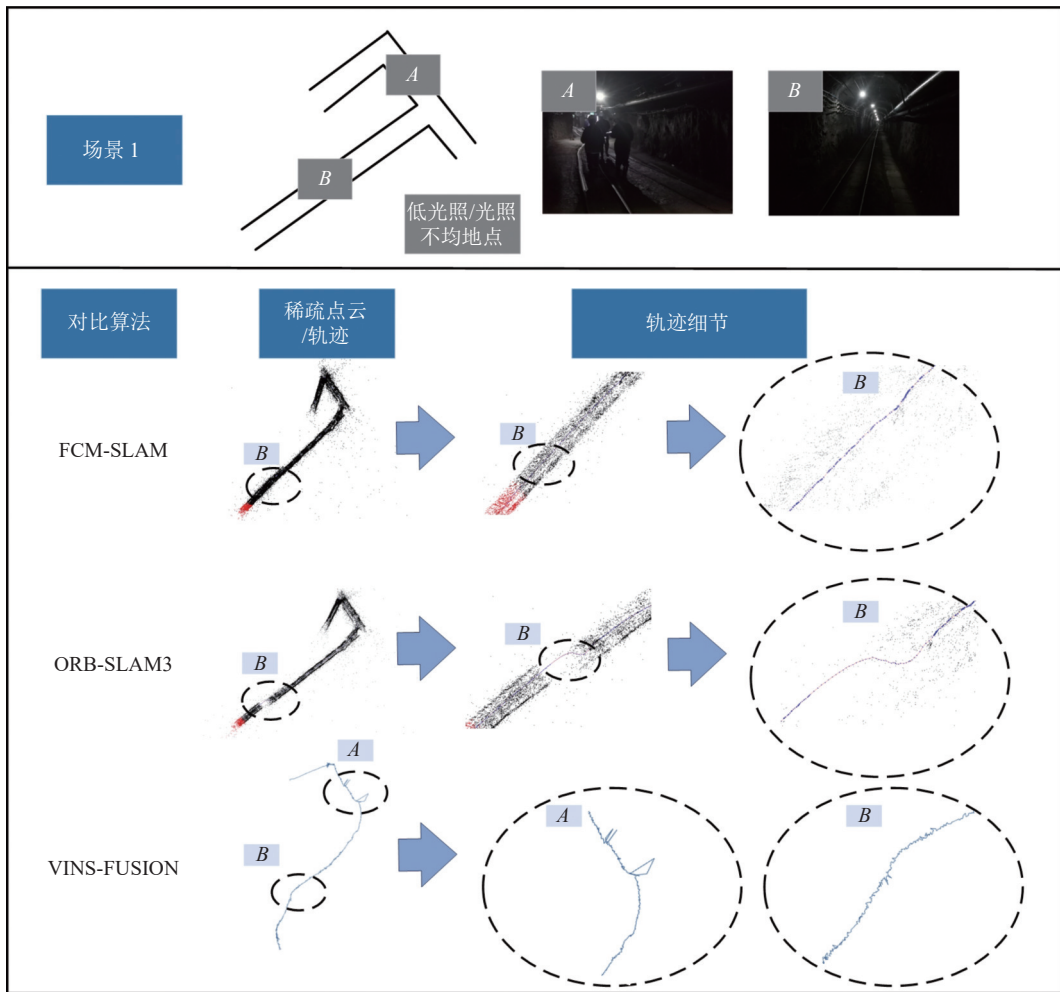


图 13 不同算法在场景 1 的定位轨迹效果对比

Fig.13 Comparison of positioning trajectory effects of different algorithms in scene 1

### 2.3 系统响应速度验证

原版 ORB-SLAM3 在巷道内开始运行时,由于巷道内纹理较弱,且煤矿用智能机器人的运动激励有限,出现了 IMU 初始化激励不足,系统反复重启的情况(受制于原版算法的设计),5 次初始化时间测试平均初始化时间在 17.7 s。而 FCM-

SLAM 引入基于解析解的 IMU 初始化方法使得初始化得以更快运行,先进行纯视觉优化,再将初始化完毕的 IMU 与视觉一起做联合初始化优化。在与图 1 的同一场景下,系统能够正常初始化,如图 15 所示。5 次初始化时间测试平均初始化时间在 7.5 s。

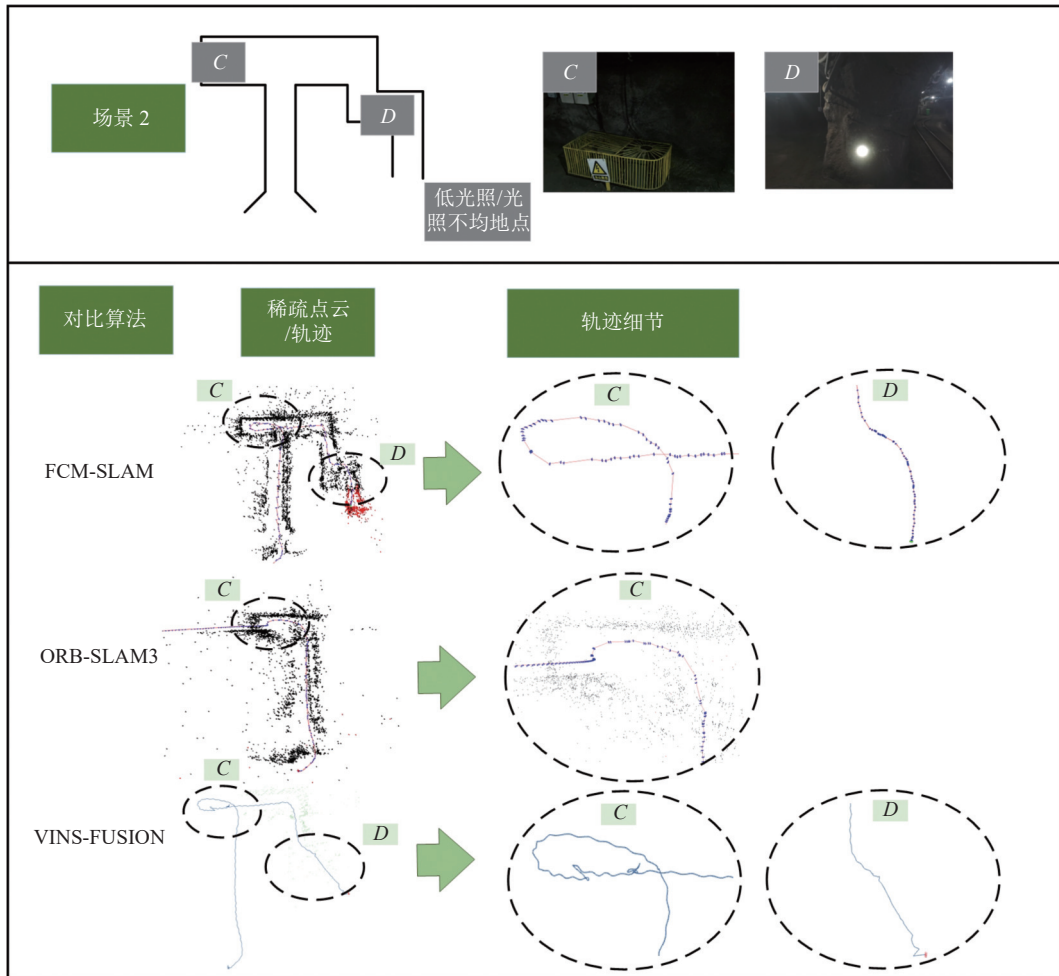


图 14 不同算法在场景 2 的定位轨迹效果对比

Fig.14 Comparison of positioning trajectory effects of different algorithms in scene 2



图 15 FCM-SLAM 系统初始化正常运行

Fig.15 FCM-SLAM system initializes normal operation

### 3 结 论

1) 提出了一种应用于井下暗光照环境的煤矿井下机器人定位方法 FCM-SLAM。以 ORB-SLAM3 为主体框架,设计了全局部亮度检测以筛分图像,引入了融合自注意力的 Enlighten 图像增强模块以复原井下图像,其中自注意力模块能够建立暗光图像不同区域的依赖关系以提高模块对光照不均图像的增

强能力。在初始化部分,引入了基于解析解的 IMU 初始化策略,使系统更快地进入 SLAM 后续线程中,且不影响定位精度。

2) 通过试验分析表明,本文提出 FCM-SLAM 算法在煤矿井下暗光环境中具有良好的定位性能,在 EuRoC 数据集暗光序列下  $E_{RMS}$  和  $E_{SD}$  平均下降 13.7% 和 15.24%;在存在暗光环境的真实巷道场景内,也更好地恢复了机器人运行轨迹,体现了算法定位性能的优势。

3) 文章还存在一定的局限性,在实际运行中,发现视觉 SLAM 在井下巷道这类弱纹理环境下也易产生特征点较少的情况,在图 10 中较为明显,此现象亦会影响系统后续定位精度。此外,在井下试验中发现,当机器人运行在较为颠簸路段和视野内快速大面积物体经过的情况下,产生的模糊画面易使视觉 SLAM 跟踪失败。下一步工作应集中于改善 SLAM 在井下弱纹理环境和模糊场景中性能下降的问题,为井下机器人提供更精准的定位效果。

## 参考文献(References):

- [1] 张守祥, 张学亮, 张磊, 等. 综采巡检机器人关键技术研究[J]. 煤炭科学技术, 2022, 50(1): 247–255.  
ZHANG Shouxiang, ZHANG Xueliang, ZHANG Lei, et al. Research on key technology of patrol robot in fully-mechanized mining face[J]. Coal Science and Technology, 2022, 50(1): 247–255.
- [2] TOPOLSKY D, TOPOLSKAYA I, PLAKSINA I, et al. Development of a mobile robot for mine exploration[J]. *Processes*, 2022, 10(5): 865.
- [3] CHANG Y, EBADI K, DENNISTON C E, et al. LAMP 2.0: A robust multi-robot SLAM system for operation in challenging large-scale underground environments[J]. *IEEE Robotics and Automation Letters*, 2022, 7(4): 9175–9182.
- [4] MOKSSIT S, LICEA D B, GUERMAH B, et al. Deep learning techniques for visual SLAM: A survey[J]. *IEEE Access*, 2023, 11: 20026–20050.
- [5] 刘毅, 贾旭芬, 田子建. 一种基于同态滤波原理的井下光照不均图像处理方法[J]. 工矿自动化, 2013, 39(1): 9–12.  
LIU Yi, JIA Xufen, TIAN Zijian. A processing method for underground image of uneven illumination based on homomorphic filtering theory[J]. Industry and Mine Automation, 2013, 39(1): 9–12.
- [6] LORE K G, AKINTAYO A, SARKAR S. LLNet: A deep auto-encoder approach to natural low-light image enhancement[J]. *Pattern Recognition*, 2017, 61: 650–662.
- [7] ZHANG Y H, GUO X J, MA J Y, et al. Beyond brightening low-light images[J]. *International Journal of Computer Vision*, 2021, 129(4): 1013–1037.
- [8] 孔二伟, 张亚邦, 李佳悦, 等. 面向煤矿井下低光照图像的增强方法[J]. 工矿自动化, 2023, 49(4): 62–69, 85.  
KONG Erwei, ZHANG Yabang, LI Jiayue, et al. Enhancement methods for low-light images in coal mines[J]. Industrial and Mining Automation, 2023, 49(4): 62–69, 85.
- [9] MENG Y Y, KONG D Q, ZHU Z F, et al. From night to day: GANs based low quality image enhancement[J]. *Neural Processing Letters*, 2019, 50(1): 799–814.
- [10] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139–144.
- [11] JIANG Y F, GONG X Y, LIU D, et al. EnlightenGAN: Deep light enhancement without paired supervision[J]. *IEEE Transactions on Image Processing*, 2021, 30: 2340–2349.
- [12] KLEIN G, MURRAY D. Parallel tracking and mapping for small AR workspaces[C]//2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality. Piscataway, NJ: IEEE, 2007: 225–234.
- [13] ENGEL J, SCHÖPS T, CREMERS D. LSD-SLAM: Large-scale direct monocular SLAM[M]. Cham: Springer International Publishing, 2014: 834–849.
- [14] MUR-ARTAL R, MONTIEL J M M, TARDÓS J D. ORB-SLAM: A versatile and accurate monocular SLAM system[J]. *IEEE Transactions on Robotics*, 2015, 31(5): 1147–1163.
- [15] MUR-ARTAL R, TARDÓS J D. ORB-SLAM2: An open-source SLAM system for monocular, stereo, and RGB-D cameras[J]. *IEEE Transactions on Robotics*, 2017, 33(5): 1255–1262.
- [16] 郭科, 方俊永, 王潇, 等. 一种视觉 SLAM 中运动模糊应对方法[J]. 哈尔滨工业大学学报, 2019, 51(11): 116–121.  
GUO Ke, FANG Junyong, WANG Xiao, et al. Algorithm for dealing with motion blur in visual SLAM[J]. Journal of Harbin Institute of Technology, 2019, 51(11): 116–121.
- [17] ZHU D X, JI K K, WU D, et al. A coupled visual and inertial measurement units method for locating and mapping in coal mine tunnel[J]. *Sensors*, 2022, 22(19): 7437.
- [18] 高扬, 曹王欣, 夏洪垚, 等. 低能见度环境下基于同步定位与构图的无人驾驶汽车定位算法[J]. 交通运输工程学报, 2022, 22(3): 251–262.  
GAO Yang, CAO Wangxin, XIA Hongyao, et al. A driverless vehicle localization algorithm based on simultaneous localization and mapping in low visibility environment[J]. Journal of Transportation Engineering, 2022, 22(3): 251–262.
- [19] CHEN J H, SHEN Y H, ZHU Q X, et al. Motion blur processing method for visual SLAM system based on local residual blur discrimination network[J]. *Journal of Mechanical Science and Technology*, 2022, 36(7): 3653–3666.
- [20] QUAN Y Z, FU D, CHANG Y F, et al. 3D convolutional neural network for low-light image sequence enhancement in SLAM[J]. *Remote Sensing*, 2022, 14(16): 3985.
- [21] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks[EB/OL]. (2019–01–14) [2023–09–09]. <https://arxiv.org/abs/1805.08318>.
- [22] ZUÑIGA-NOËL D, MORENO F A, GONZALEZ-JIMENEZ J. An analytical solution to the IMU initialization problem for visual-inertial systems[EB/OL]. 2021: 2103.03389. <https://arxiv.org/abs/2103.03389v1>.
- [23] WEI C, WANG W J, YANG W H, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. 2018: 1808.04560. <https://arxiv.org/abs/1808.04560v1>.
- [24] GUO C, LI C, GUO J, et al. Zero-reference deep curve estimation for low-light image enhancement[EB/OL]. (2020–01–19) [2023–09–09]. <https://arxiv.org/abs/2001.06826v2>.