

边缘感知增强的煤矿井下视觉SLAM方法

牟琦 梁鑫 郭媛婕 王煜豪 李占利

引用本文:

牟琦, 梁鑫, 郭媛婕, 等. 边缘感知增强的煤矿井下视觉SLAM方法[J]. 煤田地质与勘探, 2025, 53(3): 231–242.

MU Qi, LIANG Xin, GUO Yuanjie, et al. An edge awareness-enhanced visual SLAM method for underground coal mines[J]. *Coal Geology & Exploration*, 2025, 53(3): 231–242.

在线阅读 View online: <https://dx.doi.org/10.12363/issn.1001-1986.24.08.0544>

您可能感兴趣的其他文章

Articles you may be interested in

煤矿井下采掘工作场景非均质图像去雾与增强技术

A dehazing and enhancement algorithm for heterogeneous images of underground mining environments in coal mines

煤田地质与勘探. 2025, 53(1): 245–256 <https://doi.org/10.12363/issn.1001-1986.24.09.0602>

煤矿井下自动加卸钻杆靶标图像清晰化方法研究

Image sharpening method of automatic loading and unloading drill pipe target in underground coal mine

煤田地质与勘探. 2023, 51(5): 180–187 <https://doi.org/10.12363/issn.1001-1986.22.11.0885>

采煤机截割部低照度图像的边缘检测技术

Edge detection of low illumination image in cutting unit of shearer

煤田地质与勘探. 2024, 52(4): 172–178 <https://doi.org/10.12363/issn.1001-1986.23.11.0723>

煤矿井下随钻测斜仪误差联合校正方法

Joint correction method of errors of MWD inclinometer in underground coal mine

煤田地质与勘探. 2020, 48(2): 202–208 <https://doi.org/10.3969/j.issn.1001-1986.2020.02.030>

基于DC-UNet的煤矿掘进巷道断面裂隙图像检测方法

A DC-UNet-based image processing method for detecting fractures along roadway sections of coal mines

煤田地质与勘探. 2024, 52(12): 224–232 <https://doi.org/10.12363/issn.1001-1986.24.08.0509>

煤矿井下硬煤层顺层长钻孔分段压裂强化瓦斯抽采技术及应用

Enhanced gas drainage technology by staged fracturing in long bedding borehole in hard coal bed of underground coal mine and its application

煤田地质与勘探. 2022, 50(8): 72–81 <https://doi.org/10.12363/issn.1001-1986.22.04.0229>



移动阅读

牟琦, 梁鑫, 郭媛婕, 等. 边缘感知增强的煤矿井下视觉 SLAM 方法[J]. 煤田地质与勘探, 2025, 53(3): 231–242. doi: 10.12363/issn.1001-1986.24.08.0544

MU Qi, LIANG Xin, GUO Yuanjie, et al. An edge awareness-enhanced visual SLAM method for underground coal mines[J]. Coal Geology & Exploration, 2025, 53(3): 231–242. doi: 10.12363/issn.1001-1986.24.08.0544

边缘感知增强的煤矿井下视觉 SLAM 方法

牟琦^{1,2}, 梁鑫¹, 郭媛婕¹, 王煜豪¹, 李占利¹

(1. 西安科技大学 人工智能与计算机学院, 陕西 西安 710054;

2. 西安科技大学 机械工程学院, 陕西 西安 710054)

摘要: 【目的】煤矿井下普遍存在低照度、弱纹理和结构化的特征退化场景, 导致视觉 SLAM(visual simultaneous localization and mapping) 系统面临有效特征不足或误匹配率高的问题, 严重制约了其定位的准确性和鲁棒性。【方法】提出一种基于边缘感知增强的视觉 SLAM 方法。首先, 构建了边缘感知约束的低光图像增强模块。通过自适应尺度的梯度域引导滤波器优化 Retinex 算法, 以获得纹理清晰光照均匀的图像, 从而显著提升了在低光照和不均匀光照条件下特征提取性能。其次, 在视觉里程计中构建了边缘感知增强的特征提取和匹配模块, 通过点线特征融合策略有效增强了弱纹理和结构化场景中特征的可检测性和匹配准确性。具体使用边缘绘制线特征提取算法(edge drawing lines, EDLines) 提取线特征, 定向 FAST 和旋转 BRIEF 点特征提取算法(oriented fast and rotated brief, ORB) 提取点特征, 并利用基于网格运动统计(grid-based motion statistics, GMS) 和比值测试匹配算法进行精确匹配。最后, 将该方法与 ORB-SLAM2、ORB-SLAM3 在 TUM 数据集和煤矿井下实景数据集上进行了全面实验验证, 涵盖图像增强、特征匹配和定位等多个环节。【结果和结论】结果表明: (1) 在 TUM 数据集上的测试结果显示, 所提方法与 ORB-SLAM2 相比, 绝对轨迹误差、相对轨迹误差的均方根误差分别降低了 4%~38.46%、8.62%~50%; 与 ORB-SLAM3 相比, 绝对轨迹误差、相对轨迹误差的均方根误差分别降低了 0~61.68%、3.63%~47.05%。(2) 在煤矿井下实景实验中, 所提方法的定位轨迹更接近于相机运动参考轨迹。(3) 有效提高了视觉 SLAM 在煤矿井下特征退化场景中的准确性和鲁棒性, 为视觉 SLAM 技术在煤矿井下的应用提供了技术解决方案。研究面向井下特征退化场景的视觉 SLAM 方法, 对于推动煤矿井下移动式装备机器人化具有重要意义。

关键词: 视觉 SLAM; 特征退化; 边缘感知; 图像增强; 点线特征融合; TUM 数据集

中图分类号: TD67 **文献标志码:** A **文章编号:** 1001-1986(2025)03-0231-12

An edge awareness-enhanced visual SLAM method for underground coal mines

MU Qi^{1,2}, LIANG Xin¹, GUO Yuanjie¹, WANG Yuhao¹, LI Zhanli¹

(1. College of Artificial Intelligence and Computer Science, Xi'an University of Science and Technology, Xi'an 710054, China;

2. College of Mechanical Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: [Objective] Underground coal mines commonly exhibit low illuminance, weak textures, and structuralization-induced feature degradation. These scenes lead to challenges of insufficient effective features and high mismatch rates to the visual simultaneous localization and mapping (SLAM) system, severely compromising its localization accuracy and robustness. [Methods] This study proposed an edge awareness-enhanced visual SLAM method. First, an edge-awareness constrained low-illuminance image enhancement module was developed. Specifically, images with clear textures and uniform illumination were obtained using the Retinex algorithm optimized using an adaptive gradient-domain

收稿日期: 2024-08-23; 接收日期: 2025-02-05

基金项目: 国家重点研发计划项目(2022YFB3304401)

第一作者: 牟琦, 1974 年生, 女, 陕西西安人, 博士, 副教授。E-mail: muqi@xust.edu.cn

© Editorial Office of Coal Geology & Exploration. OA under CC BY-NC-ND

guided filter. This significantly improved feature extraction performance under low and uneven lighting conditions. Second, an edge awareness-enhanced feature extraction and matching module was introduced into the visual odometry. A point and line feature fusion strategy was employed to enhance the detectability and matching accuracy of weak textures and features in structured scenes. Specifically, line features were extracted using the EDLines algorithm, while point features were extracted using the Oriented FAST and Rotated BRIEF (ORB) algorithms. Such feature extraction was followed by precise feature matching achieved using grid-based motion statistics (GMS) and ratio test matching algorithms. Finally, the proposed method, along with the ORB-SLAM2 and ORB-SLAM3 algorithms, was comprehensively verified on the TUM dataset and the dataset of the actual underground coal mine scenes, covering multiple aspects such as image enhancement, feature matching, and localization. **[Results and Conclusions]** The results indicate that on the TUM dataset, the proposed method reduced the root mean square errors (RMSEs) of absolute and relative trajectory errors by 4%–38.46% and 8.62%–50%, respectively compared to ORB-SLAM2 and reduced by 0–61.68% and 3.63%–47.05%, respectively compared to ORB-SLAM3. Experiments on the actual underground coal mine scenes revealed that the location trajectories of the proposed method were aligned with the reference trajectory of camera motion more closely. Furthermore, the proposed method effectively enhanced the accuracy and robustness of the visual SLAM system in the feature degradation scene in underground coal mines, providing a technical solution for its applications in such settings. Research on visual SLAM methods tailored for feature degradation scenes in underground coal mines holds great significance for advancing the roboticization of mobile equipment used in coal mines.

Keywords: visual SLAM; feature degradation; edge awareness; image enhancement; point and line feature fusion; TUM dataset

煤炭是我国重要的工业原料和战略资源^[1]。随着煤矿产业向数字化、无人化和智能化的转型,对复杂井下环境中稳定作业的移动机器人的需求日益增长^[2]。同步定位与建图(simultaneous localization and mapping, SLAM)技术^[3]是移动机器人自主导航的基础,为井下移动机器人、无人驾驶和数字孪生等提供技术支持^[4-5]。然而,煤矿井下普遍存在低照度、弱纹理和结构化的特征退化区域,严重制约了 SLAM 系统的准确性和鲁棒性^[6]。因此,研究适用于井下特征退化场景的 SLAM 技术已成为煤矿机器人领域的热点问题^[6-8]。

SLAM 是指移动机器人在未知环境中,利用所搭载的传感器获取并跟踪场景特征,进而实时估计自身位姿并构建环境地图^[3],可分为激光 SLAM 和视觉 SLAM。激光 SLAM 依靠点云数据描述场景几何结构,但在井下结构化区域,如狭长的巷道等,点云数据可区分性不足,易导致 SLAM 系统定位漂移甚至失败^[9]。视觉 SLAM 通过图像纹理描述场景特征,但在井下低光照与不均匀光照、弱纹理与结构化的区域中,图像纹理辨识度低、有效特征点数量不足或特征描述子高度相似,导致缺乏足够的可辨识有效特征,严重影响了 SLAM 系统的性能和鲁棒性^[6]。近年来,随着计算机视觉技术的快速发展,视觉 SLAM 展现出广阔的改进空间和灵活的适应性,其在煤矿井下环境中的应用受到越来越多的关注^[6,10]。

为解决煤矿井下低照度环境引起的特征退化问题,常用的方法是采用图像增强技术提升低照度区域亮度和纹理细节。基于灰度映射的方法通过特定的映射函

数逐像素调整图像亮度,原理简单、易于实现,但由于未考虑亮度分布的相关性,易出现色彩失真、细节异常和噪声放大等现象^[11-12]。基于 Retinex 理论的方法通过估计和调整图像的光照分量来改善低光照区域亮度,其性能依赖于光照估计的准确性^[13]。经典 Retinex 算法假设光照均匀变化,采用各向同性的高斯滤波器估计光照,但在煤矿井下局部点光源等照明条件下,图像在光照突变区域可能产生光晕和伪影,不利于 SLAM 系统后续的特征提取与匹配。为此,研究者们尝试使用各向异性的滤波器来估计光照^[14-15],并取得了一定的进展。但是,这类方法在 SLAM 场景中尚未得到深入应用。

为解决煤矿井下弱纹理和结构化引起的特征退化问题,一些研究者在传统点特征^[16-17]的基础上,引入更高维的线特征以增强对场景的描述能力^[18-19]。煤矿井下的线型场景如巷道、轨道和液压支架等为线特征的提取提供了有利条件。然而,LSD(line segment detector)^[20]线特征提取算法计算复杂,抗噪能力有限,会在煤岩壁等区域产生大量不稳定的短线段,不利于视觉里程计的特征匹配^[21-22]。为提升结构化区域特征匹配的准确性,一些研究者改进了特征提取和匹配算法^[23-24],提高了特征匹配的精度。

此外,基于深度学习的方法在图像增强、特征提取与匹配领域展现出巨大的潜力^[25-26],但其性能依赖于高质量和多样化的大规模图像数据集,并且对计算资源要求较高,这限制了其在煤矿井下资源受限环境中的应用。

综上所述,为增强视觉 SLAM 在煤矿井下特征退化场景中的性能和鲁棒性,关键在于提升图像特征的可

检测性和匹配的准确性。基于此,提出了一种基于边缘感知增强的煤矿井下视觉 SLAM 方法。首先,通过构建具有边缘感知约束的自适应图像增强模块,提升低照度场景中特征的可检测性。其次,改进视觉里程计,通过融合边缘感知增强的线特征并优化点线特征精匹配策略,提升其在弱纹理和结构化场景中的性能。最后,在 TUM 数据集和煤矿井下实景数据集上验证了所提出方法的有效性。目的是提升视觉感知技术在煤矿智

能化过程中的重要作用,推动面向特征退化场景的视觉 SLAM 技术在井下移动机器人领域的应用价值^[2]。

1 总体方案

基于边缘感知增强的煤矿井下视觉 SLAM 方法总体分为图像增强、特征提取与匹配、位姿估计和后端优化 4 个阶段,如图 1 所示。

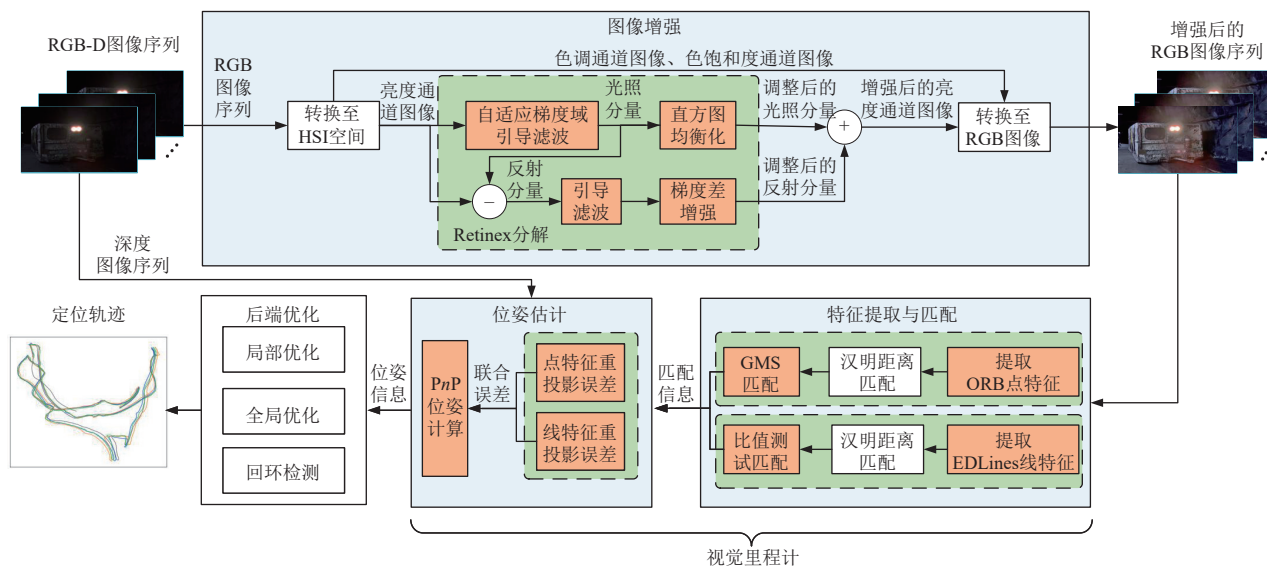


图 1 总体方案

Fig.1 General scheme

(1) 图像增强: 采用自适应尺度的梯度域引导滤波器对 Retinex 算法进行改进, 构建边缘感知约束的自适应图像增强算法, 对井下低光照和不均匀光照环境下的图像进行增强预处理, 获得纹理清晰、光照均匀的图像, 提高特征的可检测性。

(2) 特征提取与匹配: 同时提取 ORB 点特征和 ED-Lines 线特征, 并通过 GMS 和比值测试匹配算法剔除错误匹配, 以提高井下弱纹理和结构化场景中特征的可辨识性和区分能力, 为相机位姿估计提供更有效的匹配特征坐标信息。

(3) 位姿估计: 根据匹配特征的三维坐标构建点线特征联合重投影误差, 估计相机位姿。

(4) 后端优化: 采用与 ORB-SLAM2^[27] 相同的后端优化策略, 对位姿信息进行非线性优化, 进而获得更精准的定位结果。

2 图像增强

在煤矿井下, 由于照明灯和车灯等局部点光源的影响, 图像常呈现低光照或非均匀光照, 并伴有显著噪声。为改进 Retinex 算法对非均匀低光图像的增强效果, 提

出了一种基于边缘感知约束的自适应图像增强方法。通过构建自适应尺度梯度域引导滤波, 并将其作为 Retinex 的环绕函数, 能够更准确地估计非均匀的光照分量, 有效缓解过增强、光晕效应和伪影等问题。此外, 对反射分量采用引导滤波去除噪声后进行细节提升, 进一步增强了图像纹理特征。

2.1 光照估计

为避免图像增强过程中出现色彩失真, 首先将 RGB 图像转换至 HSI 色彩空间, 仅对亮度通道图像 I 进行增强处理。Retinex 理论^[28] 将图像分解为光照分量和反射分量的乘积, 通过估计和调整光照分量来改善低光照区域亮度。因此光照估计的准确性是图像增强性能的关键。为了提高对低照度和非均匀光照条件的适应性, 构建了自适应梯度域引导滤波器, 通过图像尺寸、光照和纹理动态调整滤波半径和平滑因子, 显著提升了对非均匀低照度图像光照估计的精度。

对亮度通道图像 I 采用自适应尺度的梯度域引导滤波进行光照估计, 得到光照分量 L :

$$L(x, y) = \sum_{i=1}^N \gamma f_g(I(x, y), I(x, y), r_i) \quad (1)$$

其中,尺度数 N 由输入图像的尺寸 (m,n) 确定,各尺度数参数 r_i 的计算如下:

$$\begin{cases} r_1 = \frac{\min(m,n)}{2^N} \\ r_N = \frac{\max(m,n)}{2} \\ r_i = \left[r_1 + (i-1) \cdot \frac{r_N - r_1}{N-1} \right], \quad i = 2, 3, \dots, N-1 \end{cases} \quad (2)$$

Retinex 算法采用各向同性的高斯滤波器来估计光照,在处理光照不均匀的煤矿井下图像时,在亮度突变区域会出现梯度反转和光晕,不利于后续视觉里程计的特征提取与匹配。引导滤波^[29]假设引导图像 G 与滤波后结果图像 q 存在局部线性关系:

$$q_i = a_k G_i + b_k, \quad \forall i \in w_k \quad (3)$$

由于 q_i 和 G_i 具有一致的梯度方向,有效避免了因梯度反转而产生的边缘伪影。

构建目标函数 $E(a_k, b_k)$,表示在每个局部窗口内最小化滤波结果图像 q_i 和原图像 I_i 之间的差,从而在整体上保持增强图像的原始特征:

$$E(a_k, b_k) = \sum_{i \in w_k} [(a_k G_i + b_k - I_i)^2 + \varepsilon a_k^2] \quad (4)$$

其中,惩罚系数 ε 作为平滑因子,在所有邻域窗口相同,忽略了图像中不同区域的差异,在光照和纹理变化不均匀的图像中会出现过度平滑或滤波不足。

梯度域引导滤波^[30]引入边缘感知约束动态调整惩罚系数,以实现不同区域的自适应滤波,使用亮度通道图像 I 作为引导图像,得到目标函数:

$$E(a_k, b_k) = \sum_{i \in w_k} \left[(a_k I_i + b_k - I_i)^2 + \frac{\varepsilon}{\hat{F}_G(k)} (a_k - \sigma_k)^2 \right] \quad (5)$$

其中, $\hat{F}_G(k)$ 、 σ_k 为边缘感知约束项:

$$\hat{F}_G(k) = \frac{1}{M} \sum_{i=1}^M \frac{\Psi(k) + \alpha}{\Psi(i) + \alpha} \quad (6)$$

$$\sigma_k = 1 - \frac{1}{1 + \exp\left(\frac{4}{\Psi_u(k) - \Psi_{\min}(k)}\right) [\Psi(k) - \Psi_u(k)]} \quad (7)$$

2.2 光照校正与纹理提升

通过式(1)得到光照分量 L 后,根据 Retinex 理论,可计算得到反射分量 K :

$$K(x, y) = \exp[\ln I(x, y) - \ln L(x, y)] \quad (8)$$

采用直方图均衡化对光照分量 L 进行灰度校正,获得了亮度分布更加均衡的光照分量 L' 。

为避免在纹理增强时噪声被放大,首先使用具有保边平滑特性的引导滤波去除反射分量 K 中的噪声,然后采用梯度差增强^[31]方法提升纹理特征,得到反射分量 K' 。

2.3 色彩恢复

根据 Retinex 理论,融合优化后的光照分量 L' 和反射分量 K' ,得到增强后的亮度通道图像 I' :

$$I'(x, y) = \exp[\ln K'(x, y) + \ln L'(x, y)] \quad (9)$$

增强后的亮度通道图像 I' 仍是灰度图像,将其与原色调通道图像 H 、饱和度通道图像 S 融合,得到增强后的 RGB 图像。

3 特征提取与匹配

视觉里程计通过匹配相邻关键帧中的特征点估计相机位姿,因此特征提取与匹配是影响其定位性能的关键环节。为提高煤矿井下弱纹理和结构化场景中特征提取与匹配的性能,提出了基于边缘感知增强的特征提取与匹配方法,通过点线特征融合和特征精匹配策略,有效改善了弱纹理场景中特征不足和结构化场景中误匹配率高的问题。

3.1 点特征提取与匹配

首先采用 ORB 算法^[17]快速采集大量特征点,为后续的特征匹配提供充足的候选集。然后通过汉明距离度量相邻关键帧间特征点描述子的相似性,初步筛选匹配对。最后采用 GMS^[23]算法剔除错误和重复匹配,完成点特征精匹配。

GMS 算法对图像进行网格化,基于运动一致性原则,运用统计方法计算匹配点在检测邻域内的支持度,从而从粗匹配中快速识别正确匹配,如图 2 所示。在纹理重复的场景中,GMS 算法能够显著提升视角变换的图像帧间特征匹配的准确性。




图 2 GMS 网格匹配

Fig.2 GMS-based gridding and point matching

3.2 线特征提取与匹配

采用 EDLines 算法^[32]提取线特征,通过汉明距离进行粗匹配,采用比值测试匹配算法^[17]进行精匹配。

EDLines 算法是一种基于边缘特征的线特征提取算法,相较于 LSD 线特征,其计算效率和抗噪性能显著提升,能够在连续多帧图像中提取出稳定的长线段,为后续特征匹配提供了可靠的基础。

比值测试匹配算法是一种高效的特征匹配方法,它通过计算特征匹配对之间的最近邻和次近邻距离比,并结合线特征间的相似度关系来剔除错误匹配:

$$\begin{cases} \delta = \delta_i, & \frac{h_1}{h_2} < \beta \\ \delta = \delta_i, & \frac{h_1}{h_2} > \beta \end{cases} \quad (10)$$

4 位姿估计

通过匹配特征的二维坐标与深度图像得到特征三维信息, 采用 PnP 算法^[33] 估计相机位姿。相机位姿由旋转矩阵 \mathbf{R} 和平移矩阵 \mathbf{t} 描述其在水系坐标系中的位置和方向。构建并优化点线特征联合重投影误差, 得到相机位姿。

4.1 点特征重投影误差

计算 F 帧中点特征 P_{c_i} 在 $F+1$ 帧中的投影 P'_{c_i} :

$$P'_{c_i} = \mathbf{C} \cdot (\mathbf{R} \cdot P_{w_i} + \mathbf{t}) \quad (11)$$

随后计算 P_{c_i} 在第 $F+1$ 帧中的匹配点与投影点 P'_{c_i} 的差, 作为点特征重投影误差, 如图 3 所示。




图 3 点特征重投影误差
Fig.3 Reprojection error of a point feature

n 个点特征的重投影误差 ξ_{point} 表示为:

$$\xi_{\text{point}} = \frac{1}{2} \sum_{i=1}^n \|P_{c_i} - P'_{c_i}\|_2^2 \quad (12)$$

4.2 线特征重投影误差

将 F 帧中线段的端点投影到 $F+1$ 帧, 得到端点 \tilde{p}_i 、 \tilde{q}_i , 计算它们到 $F+1$ 帧中匹配线段所在直线 $p_d q_d$ 的距离 d_1 、 d_2 和线性参数 \mathbf{D} :

$$\begin{aligned} d_1 &= E_{\text{pl}}^2(p_d, \mathbf{D}) = \mathbf{D}^T p_d, \\ d_2 &= E_{\text{pl}}^2(q_d, \mathbf{D}) = \mathbf{D}^T q_d, \\ \mathbf{D} &= \frac{p_d^h \times q_d^h}{|p_d^h \times q_d^h|} \end{aligned} \quad (13)$$

对 d_1 、 d_2 加权求和, 得到线特征重投影误差, 如图 4 所示。

n 个线特征的重投影误差 ξ_{line} 表示为:




图 4 线特征重投影误差
Fig.4 Reprojection error of a line feature

$$\xi_{\text{line}} = \sum_{i=1}^n (E_{\text{pl}}^2(p_d, \mathbf{D}) + E_{\text{pl}}^2(q_d, \mathbf{D})) \quad (14)$$

4.3 点线特征联合重投影误差

构建点线特征联合重投影误差 ξ_{total} :

$$\xi_{\text{total}} = \underset{\mathbf{R}, \mathbf{t}}{\operatorname{argmin}} (\xi_{\text{point}} + \xi_{\text{line}}) \quad (15)$$

通过高斯牛顿法等得到当前帧的最优相机位姿。

5 实验结果与分析

使用 TUM 数据集和煤矿井下实景数据集对所提出的方法进行了全面的实验评估。实验内容涵盖图像增强、特征匹配和定位等关键环节。

5.1 实验环境与性能评估指标

1) 实验环境与实验数据

实验在 Ubuntu 18.04-x64bit 操作系统上进行, 使用的 CPU 型号为 Intel(R) Core(TM) i9-12900H 2.50 GHz, 内存为 16 GB, 编程语言为 C++。

TUM 数据集^[34] 是视觉 SLAM 领域中广泛认可的标准数据集, 包含多种场景的视频序列及其对应的相机真实运动轨迹。此外, 在西安科技大学煤炭主体专业综合实验实训中心使用 Kinect V1 相机采集了多组实景数据, 涵盖轨道巷、综采工作面、中央水泵房和中央变电所等主要场景。

2) 性能评估指标

为客观评估图像增强实验的有效性, 采用图像熵、能量梯度、方差作为实验评估指标。

图像熵 $E(o_i)$ 反映图像信息量和细节丰富程度:

$$E(o_i) = - \sum_{i=0}^{A-1} o_i \lg(o_i) \quad (16)$$

能量梯度函数 $F(x, y)$ 反映图像的清晰度:

$$F(x, y) = \sum_x \sum_y \{ [f(x+1, y) - f(x, y)]^2 + [f(x, y+1) - f(x, y)]^2 \} \quad (17)$$

方差函数 $V(x, y)$ 表示图像灰度分布的离散程度:

$$V(x, y) = \sum_x \sum_y \left\{ \left[f(x, y) - \frac{1}{M_s} \sum_x \sum_y f(x, y) \right]^2 \right\} \quad (18)$$

为了客观评估视觉定位实验的精度, 使用绝对轨迹误差 (absolute trajectory error, ATE) 和相对轨迹误差 (relative pose error, RPE) 作为实验评估指标^[34]。

绝对轨迹误差通过比较定位轨迹与相机真实运动轨迹之间的绝对距离来评估全局一致性。绝对轨迹误差 E_{AT} 定义为:

$$E_{\text{AT}} = Q_i^{-1} \mathbf{U} P_i \quad (19)$$

相对轨迹误差通过测量固定时间间隔 Δ 内位姿变化量的差值来评估系统的漂移量。相对轨迹误差 E_{RP} 定义为:

$$E_{RP} = (Q_i^{-1} Q_{i+\Delta})^{-1} (P_i^{-1} P_{i+\Delta})^{-1} \quad (20)$$

5.2 图像增强与特征匹配实验

在煤矿井下实景数据集中选择具有低光照和弱纹理特征的图像序列 L1、L2, 非均匀光照和弱纹理特征的图像序列 L3, 以及弱纹理和结构化特征的图像序列 L4 进行实验。

5.2.1 图像增强

对比表 1 中图像增强前后的客观指标可知, 增强后图像的客观指标均显著提升, 表明所提出的图像增强方法能够有效提升低光照和非均匀光照图像的清晰度, 并增强图像中的细节。

表 1 图像增强前后客观指标

Table 1 Values of objective indicators before and after image enhancement

序列	图像熵	能量梯度/ 10^8	方差/ 10^8
L1	原图	6.30	4.05
	增强后	7.25	115.89
L2	原图	5.89	6.54
	增强后	7.17	299.17
L3	原图	5.66	4.36
	增强后	7.13	109.96

图 5 所示结果表明, 增强后图像的亮度和细节均得到显著改善, 有效增强了退化特征的可检测性。在 L3 序列所示非均匀低光图像中, 光照极低区域(如红色矩形框所示)的亮度得到了显著提升, 且在光照变化区域

未观察到明显的光晕和伪影。这得益于自适应梯度域引导滤波对光照和纹理的局部感知能力。




图 5 图像增强前后对比

Fig.5 Comparison images before and after enhancement

5.2.2 特征匹配实验

图 6 为图像点线特征匹配对比结果。其中, 对比方法(“ORB+汉明距离匹配”和“EDLines+汉明距离匹配”)在弱纹理和结构化场景中, 存在较多杂乱的匹配线段, 表明存在大量错误匹配。而本文方法匹配线段方向基本一致, 说明能有效筛选错误匹配, 匹配精度更高。图 7 为图像增强前后的特征匹配实验结果, 图 8 为图像通过已知的单应性变换 O 后的特征匹配实验结果。与原图像相比, 增强后的图像能够显著提升退化区域特征点的可检测性和匹配准确率。由图 8 结果可知, 本文方法特征匹配精度平均提升 2.37%。

5.3 视觉定位实验

为了检验本文方法在视觉 SLAM 定位任务中的性能, 在 TUM 数据集中选取了 3 组具有弱纹理和结构化

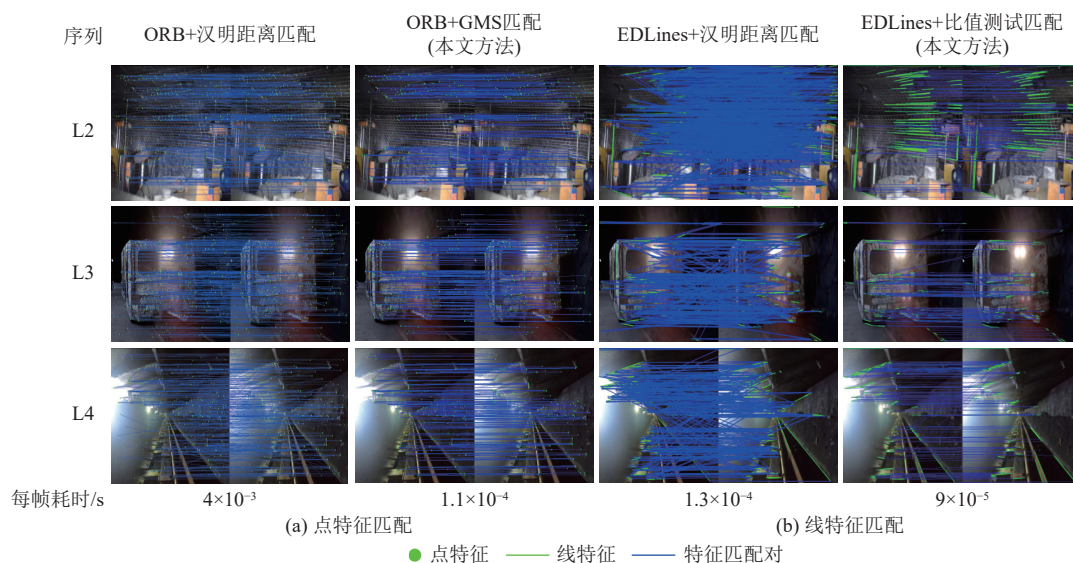


图 6 点线特征匹配对比

Fig.6 Comparison of point and line feature matching results using varying methods

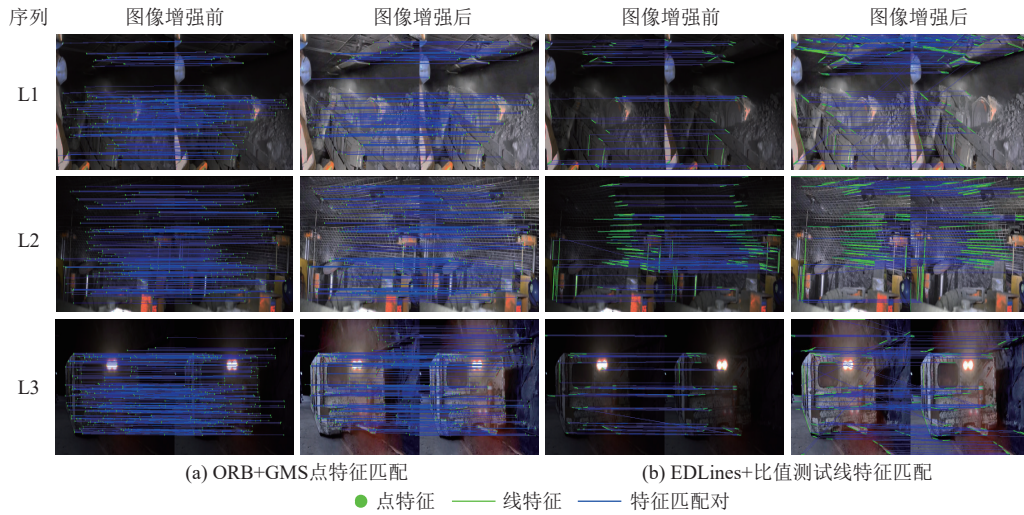


图 7 图像增强前后特征匹配对比

Fig.7 Comparison of point and line feature matching before and after image enhancement




图 8 图像单应性变换后的 ORB+GMS 点特征匹配对比

Fig.8 Comparison of ORB+GMS-based point feature matching results post-homography transformation before and after image enhancement

特征的序列和 5 组具有不同纹理特征的序列进行定位实验,并与 ORB-SLAM2 和 ORB-SLAM3^[35] 进行对比分析。考虑到 SLAM 采用多线程架构,线程调度和执行顺序的随机性可能导致实验结果波动,因此每个序列执行 10 次独立实验,定量分析结果时取其平均值,定性分析时则选取其最佳轨迹误差图。

5.3.1 TUM 数据集定位实验

1) TUM 数据集定量分析实验

TUM 数据集定量分析实验结果见表 2 和表 3。

由结果可知,在绝对轨迹误差、相对轨迹误差的均方根误差和平均值指标中,本文方法均优于对比方法。在 8 个 TUM 序列中,相较于 ORB-SLAM2,本文方法绝对轨迹误差的均方根误差降低了 4%~38.46%,相对轨迹误差的均方根误差降低了 8.62%~50%;相较于

ORB-SLAM3,本文方法绝对轨迹误差的均方根误差降低了 0~61.68%,相对轨迹误差的均方根误差降低了 3.63%~47.05%。特别是在具有显著弱纹理和结构化特征的 fl_floor 序列中,ORB-SLAM2 和 ORB-SLAM3 均出现了跟踪丢失现象。而本文方法在定位过程中能持续跟踪,且定位轨迹和真实估计基本吻合。这得益于在特征提取阶段融合了边缘感知能力更强的 EDLines 线特征,缓解了在弱纹理场景下点特征数量不足的问题;并且通过精匹配策略,提高了匹配精度,缓解了在结构化场景中特征误匹配率较高的问题。

2) 低照度 TUM 数据集定量分析实验

为定量评估图像增强模块对视觉 SLAM 定位性能的提升效果,对 8 组 TUM 序列进行线性变换和直方图调整等处理,以模拟低照度条件,定位实验结果见表 4。

表 2 绝对轨迹误差
Table 2 Absolute trajectory errors

序列名	ORB-SLAM2		ORB-SLAM3		本文方法		本文方法均方根误差降低百分比/%	
	均方根误差/m	平均值/m	均方根误差/m	平均值/m	均方根误差/m	平均值/m	相比ORB-SLAM2	相比ORB-SLAM3
f1_desk	0.019	0.016	0.018	0.016	0.016	0.013	15.78	11.11
f1_desk2	0.025	0.022	0.024	0.022	0.024	0.021	4	0
f1_floor	---	---	---	---	0.166	0.142	---	---
f1_room	0.044	0.039	0.107	0.099	0.041	0.038	6.81	61.68
f2_l_loop	0.143	0.110	0.206	0.146	0.093	0.084	34.96	54.85
f3_ns_far	0.080	0.064	0.075	0.061	0.071	0.057	11.25	5.33
f3_s_t_far	0.013	0.011	0.012	0.010	0.008	0.007	38.46	33.33
f3_s_t_near	0.011	0.010	0.010	0.009	0.009	0.008	18.18	10

注：“---”表示该算法在该序列中出现跟踪丢失，无法进行比较。

表 3 相对轨迹误差
Table 3 Relative trajectory errors

序列名	ORB-SLAM2		ORB-SLAM3		本文方法		本文方法均方根误差降低百分比/%	
	均方根误差/m	平均值/m	均方根误差/m	平均值/m	均方根误差/m	平均值/m	相比ORB-SLAM2	相比ORB-SLAM3
f1_desk	0.019	0.015	0.017	0.013	0.013	0.010	31.57	23.52
f1_desk2	0.019	0.015	0.018	0.014	0.017	0.012	10.52	5.55
f1_floor	---	---	---	---	0.035	0.007	---	---
f1_room	0.022	0.016	0.022	0.015	0.012	0.009	45.45	45.45
f2_l_loop	0.058	0.034	0.055	0.032	0.053	0.031	8.62	3.63
f3_ns_far	0.076	0.052	0.089	0.056	0.052	0.035	31.57	41.57
f3_s_t_far	0.018	0.016	0.017	0.015	0.009	0.007	50	47.05
f3_s_t_near	0.013	0.011	0.012	0.009	0.008	0.007	38.46	33.33

注：“---”表示该算法在该序列中出现跟踪丢失，无法进行比较。

由实验结果可知,在进行图像增强后 8 组实验序列的定位精度均得到明显提升。验证了具有边缘感知约束的

图像增强方法能够为视觉 SLAM 提供高质量的输入,从而获得更准确的定位结果。

表 4 低照度条件下绝对轨迹误差和相对轨迹误差
Table 4 Absolute and relative trajectory errors under low illumination conditions

单位: m

序列名	绝对轨迹误差				相对轨迹误差			
	本文方法未使用图像增强		本文方法		本文方法未使用图像增强		本文方法	
	均方根误差	平均值	均方根误差	平均值	均方根误差	平均值	均方根误差	平均值
f1_desk	0.014	0.012	0.011	0.009	0.013	0.008	0.011	0.008
f1_desk2	0.029	0.024	0.022	0.020	0.015	0.011	0.013	0.010
f1_floor	0.169	0.134	0.146	0.126	0.042	0.007	0.024	0.005
f1_room	0.081	0.075	0.070	0.063	0.013	0.009	0.010	0.008
f2_l_loop	0.214	0.202	0.081	0.071	0.099	0.046	0.038	0.020
f3_ns_far	0.095	0.047	0.042	0.036	0.091	0.044	0.036	0.029
f3_s_t_far	0.008	0.007	0.006	0.005	0.009	0.008	0.006	0.005
f3_s_t_near	0.009	0.009	0.008	0.007	0.008	0.007	0.007	0.006

3)TUM 数据集定性分析实验

部分序列的轨迹误差如图 9 所示。其中,定位轨迹和真实轨迹间的红色区域表示误差,实验结果表明,

本文方法整体红色区域相较于 ORB-SLAM2 和 ORB-SLAM3 更小,说明本文方法的定位轨迹更接近相机真实轨迹,定位结果更准确,性能更好。

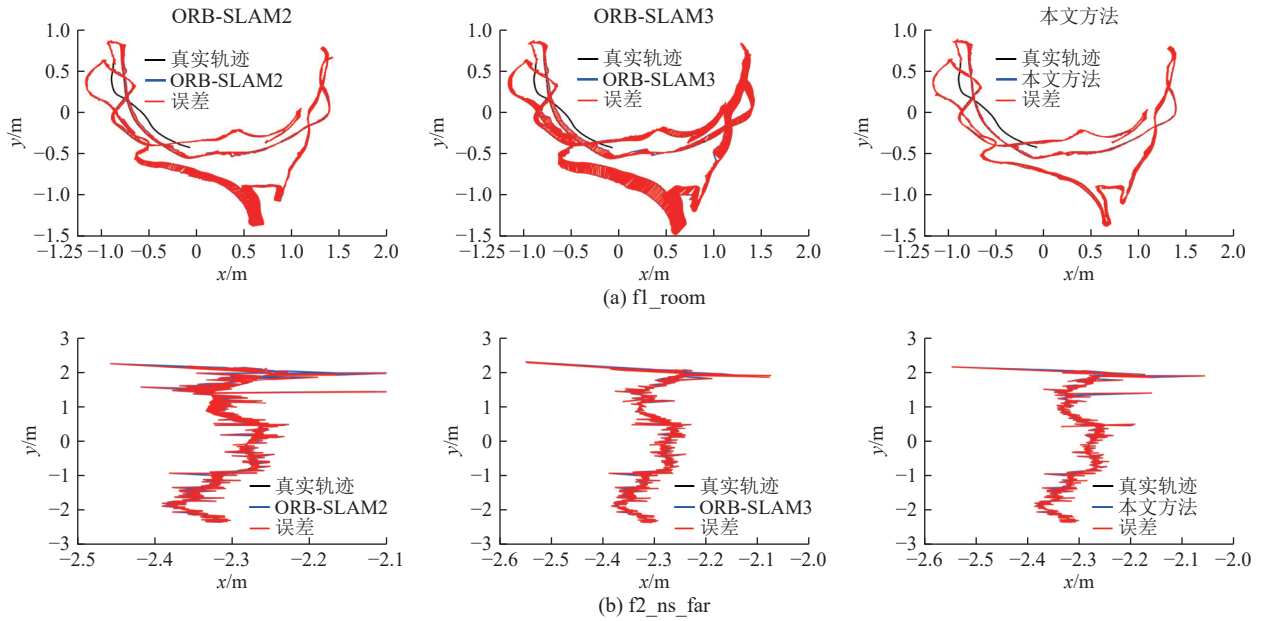


图9 部分序列轨迹误差

Fig.9 Trajectory error of partial sequences

5.3.2 井下实景数据定位实验

为进一步检验本文方法在煤矿井下实景场景中的定位性能和泛化能力,分别在井下水泵房段和井下综采面段进行实验。

1) 井下水泵房段实景定位实验

图10展示了井下水泵房段区域的实际场景,其中包含弱纹理和结构化特征区域。在数据采集过程中,相机沿着图10a中AB段匀速直线运动。




图10 井下水泵房段场景

Fig.10 Scenes of the underground water pump room

图11b为井下水泵房段实景实验定位轨迹。数据采集过程中相机高度保持恒定,因此,仅展示二维轨迹图。由结果可知,ORB-SLAM2和ORB-SLAM3算法在持续定位大约3m后便丢失定位。而本文方法未出现定位丢失现象,不仅能保持稳定的持续定位,而且定位轨迹也更接近相机运动参考轨迹。

2) 井下综采面段实景定位实验

图12展示了井下综采面段区域的实际场景,其中包含低照度和复杂纹理区域。在数据采集过程中,相机同样沿着图12a中AB段匀速直线运动。

图13b为井下综采面段实景实验定位轨迹。实验结果显示,ORB-SLAM2和ORB-SLAM3算法轨迹

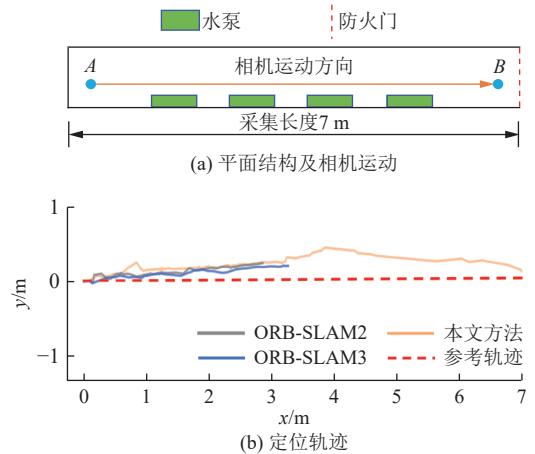


图11 井下水泵房段定位实验

Fig.11 Localization experiment results of the underground water pump room




图12 井下综采面段场景

Fig.12 Scenes of a segment of the underground fully mechanized mining face

基本重叠(如紫色箭头所指的局部放大图所示),均持续定位大约1m后便丢失定位。本文方法不仅能够持续定位,而且定位轨迹也与相机运动参考轨迹保持一致。

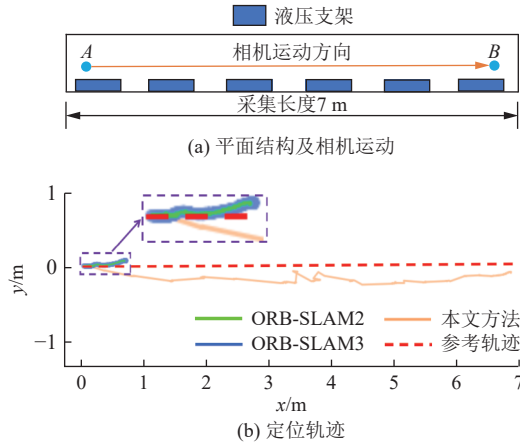


图 13 井下综采面定位实验

Fig. 13 Localization experiment results of the underground fully mechanized mining face

6 结论

(1) 提出了一种基于边缘感知增强的煤矿井下视觉 SLAM 方法。该方法能够有效提高视觉 SLAM 在煤矿井下特征退化场景中的性能和鲁棒性。

(2) 构建了边缘感知约束的自适应图像增强模块,有效增强了煤矿井下低光照和不均匀光照环境下的图像质量,提升了特征的可检测性;构建了边缘感知增强的特征提取与匹配模块,显著提升了视觉 SLAM 在井下弱纹理和结构化场景中的特征提取与匹配性能。

(3) 在 TUM 数据集和煤矿井下实景数据集中与 ORB-SLAM2、ORB-SLAM3 进行对比实验,本文方法在 TUM 数据集上的绝对轨迹误差和相对轨迹误差的均方根误差相较于 ORB-SLAM2 和 ORB-SLAM3 分别降低了 4%~38.46% 和 8.62%~50%, 0~61.68% 和 3.63%~47.05%;在煤矿井下实景实验中,本文方法的定位轨迹相较于 ORB-SLAM2 和 ORB-SLAM3 更接近相机的运动参考轨迹。

(4) 尽管本文方法在煤矿井下特征退化场景中具有较好的性能和泛化能力,并且在煤矿井下实景环境中也具有一定的适用性,但由于引入了计算复杂的线特征和特征精匹配策略,计算复杂度有所增加。未来的研究将聚焦于进一步提升特征提取与匹配效率,引入新型后端优化策略,提升方法的整体性能。

符号注释:

A 为图像灰度级数; a_k 、 b_k 均为线性系数; C 为相机内参矩阵; d_1 、 d_2 分别为端点 \tilde{p}_i 、 \tilde{q}_i 到 $F+1$ 图像帧匹配线段所在直线 $p_d q_d$ 的距离; d'_1 、 d'_2 为匹配线段 $p_d q_d$ 到对应投影线段 $\tilde{p}_i \tilde{q}_i$ 的距离; E_{AT} 为绝对轨迹误差; E_{RP} 为相对轨迹误差; $E(o_i)$ 为图像熵; E_{pl} 为线段的投影端点到图像帧中匹配线段所在直线的距离; $E(a_k, b_k)$ 为目标函

数; f_g 为梯度域引导滤波器; $f(x, y)$ 为该像素点处灰度值; F 、 $F+1$ 为当前图像帧和相邻下一图像帧; $F(x, y)$ 为能量梯度函数; G 为引导图像; G_i 为引导图像中的第 i 个图像块; h_1 为特征匹配对最近邻距离; h_2 为特征匹配对次近邻距离; H 为色调通道图像; O 为单应性变换矩阵; i^1, i^2, \dots, i^9 为像素索引; D 为线性参数; I 为亮度通道图像; I' 为增强后的亮度通道图像; I_i 为亮度通道图像第 i 个图像块; j^1, j^2, \dots, j^9 为像素索引; K 为反射分量; K' 为优化后的反射分量; L 为光照分量; L' 为优化后的光照分量; M 为图像总像素个数; M_s 为图像大小; N 为尺度数; o_i 为图像某个灰度级出现的概率; \tilde{p}_i 为三维空间线段端点的投影点; p_d 为图像帧中线特征的端点; p_d^h 为 p_d 的齐次坐标; P_{w_i} 为三维空间点的坐标; P_{c_i} 为 P_{w_i} 在图像帧 F 上的投影坐标; P'_{c_i} 为 P_{c_i} 在图像帧 $F+1$ 上的投影坐标; P_i 为轨迹估计位姿; q 为引导滤波输出图像; \tilde{q}_i 为三维空间线段端点的投影点; q_d 为图像帧中线特征的端点; q_d^h 为 q_d 的齐次坐标; Q_i 为真实轨迹位姿; r_i 为尺度参数; R 为旋转矩阵; U 为估计位姿到真实位姿的刚体变换矩阵; S 为饱和度通道图像; t 为平移矩阵; $V(x, y)$ 为方差函数; w_k 为滤波窗口; α 为常数; β 为比值测试匹配算法的预设阈值; γ 为每个尺度的加权系数 ($\gamma = 1/N$); $\hat{f}_G(k)$ 为边缘感知约束项; δ 为比值测试匹配结果; Δ 为固定时间间隔; δ_i 为比值测试匹配算法的正确匹配结果; δ_e 为比值测试匹配算法的错误匹配结果; ε 为惩罚系数; ξ_{point} 为点特征重投影误差; ξ_{line} 为线特征重投影误差; ξ_{total} 为点线特征联合重投影误差; σ_k 为边缘感知约束项; $\Psi(k)$ 为引导图像 G 在 3×3 邻域内的方差和以 r 为半径的滤波窗口内方差的乘积; $\Psi(i)$ 为引导图像 G 以像素 k 为中心, $(2r+1)^2$ 窗口内第 i 个像素点与像素点 k 的方差; $\Psi_u(k)$ 和 $\Psi_{min}(k)$ 分别为 $\Psi(k)$ 的均值和最小值; (m, n) 为输入图像的尺寸。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References)

- [1] 王国法, 张建中, 薛国华, 等. 煤矿回采工作面智能地质保障技术进展与思考[J]. 煤田地质与勘探, 2023, 51(2): 12–26.
WANG Guofa, ZHANG Jianzhong, XUE Guohua, et al. Progress and reflection of intelligent geological guarantee technology in coal mining face[J]. Coal Geology & Exploration, 2023, 51(2): 12–26.
- [2] 王海军, 曹云, 王洪磊. 煤矿智能化关键技术研究与实践[J]. 煤田地质与勘探, 2023, 51(1): 44–54.
WANG Haijun, CAO Yun, WANG Honglei. Research and prac-

- tice on key technologies for intelligentization of coal mine[J]. *Coal Geology & Exploration*, 2023, 51(1): 44–54.
- [3] CHEN Weifeng, ZHOU Chengjun, SHANG Guangtao, et al. SLAM overview: From single sensor to heterogeneous fusion[J]. *Remote Sensing*, 2022, 14(23): 6033.
- [4] 葛世荣, 胡而已, 李允旺. 煤矿机器人技术新进展及新方向[J]. *煤炭学报*, 2023, 48(1): 54–73.
- GE Shirong, HU Eryi, LI Yunwang. New progress and direction of robot technology in coal mine[J]. *Journal of China Coal Society*, 2023, 48(1): 54–73.
- [5] 胡博妮, 陈霖, 徐丙立, 等. 基于无人机平台的地表环境实时稠密点云生成与数字模型构建[J]. *遥感学报*, 2024, 28(5): 1206–1221.
- HU Boni, CHEN Lin, XU Bingli, et al. Real-time dense point cloud generation and digital model construction of surface environment based on UAV platform[J]. *National Remote Sensing Bulletin*, 2024, 28(5): 1206–1221.
- [6] 高毅楠, 姚顽强, 蔺小虎, 等. 煤矿井下多重约束的视觉 SLAM 关键帧选取方法[J]. *煤炭学报*, 2024, 49(增刊 1): 472–482.
- GAO Yinan, YAO Wanqiang, LIN Xiaohu, et al. Visual SLAM keyframe selection method with multiple constraints in underground coal mines[J]. *Journal of China Coal Society*, 2024, 49(Sup.1): 472–482.
- [7] HUANG Zenghua, GE Shirong, HE Yonghua, et al. Research on the intelligent system architecture and control strategy of mining robot crowds[J]. *Energies*, 2024, 17(8): 1834.
- [8] LI Menggang, HU Kun, LIU Yuwang, et al. A multimodal robust simultaneous localization and mapping approach driven by geodesic coordinates for coal mine mobile robots[J]. *Remote Sensing*, 2023, 15(21): 5093.
- [9] 薛光辉, 张钰昊, 张桂艺, 等. 煤矿井下点云特征提取和配准算法改进与激光 SLAM 研究[J/OL]. *煤炭科学技术*, 2024: 1–12 [2024-07-23]. <https://kns.cnki.net/kcms/detail/11.2402.TD.20240722.1557.003.html>.
- XUE Guanghui, ZHANG Zhenghao, ZHANG Guiyi, et al. Improvement of point cloud feature extraction and alignment algorithms and LiDAR SLAM in coal mine underground[J/OL]. *Coal Science and Technology*, 2024: 1–12 [2024-07-23]. <https://kns.cnki.net/kcms/detail/11.2402.TD.20240722.1557.003.html>.
- [10] YU Rui, FANG Xinqiu, HU Chengjun, et al. Research on positioning method of coal mine mining equipment based on monocular vision[J]. *Energies*, 2022, 15(21): 8068.
- [11] 王纪武, 万伟鹏, 尚学强, 等. 基于图像增强和自适应阈值的语义视觉 SLAM 系统[J]. *计算机集成制造系统*, 2024, 30(12): 4217–4232.
- WANG Jiwu, WAN Weipeng, SHANG Xueqiang, et al. Semantic visual SLAM system based on image enhancement and adaptive thresholding[J]. *Computer Integrated Manufacturing Systems*, 2024, 30(12): 4217–4232.
- [12] 龚云, 颜昕宇. 基于同态滤波方法的煤矿井下图像增强技术研究[J]. *煤炭科学技术*, 2023, 51(3): 241–250.
- GONG Yun, XIE Xinyu. Research on coal mine underground image recognition technology based on homomorphic filtering method[J]. *Coal Science and Technology*, 2023, 51(3): 241–250.
- [13] 占必超, 吴一全, 纪守新. 基于平稳小波变换和 Retinex 的红外图像增强方法[J]. *光学学报*, 2010, 30(10): 2788–2793.
- ZHAN Bichao, WU Yiquan, JI Shouxin. Infrared image enhancement method based on stationary wavelet transformation and Retinex[J]. *Acta Optica Sinica*, 2010, 30(10): 2788–2793.
- [14] WANG Yifan, WANG Hongyu, YIN Chuanli, et al. Biologically inspired image enhancement based on Retinex[J]. *Neurocomputing*, 2016, 177: 373–384.
- [15] 梅英杰, 宁媛, 陈进军. 融合暗通道先验和 MSRCR 的分块调节图像增强算法[J]. *光子学报*, 2019, 48(7): 0710005.
- MEI Yingjie, NING Yuan, CHEN Jinjun. Block-adjusted image enhancement algorithm combining dark channel prior with MSRCR[J]. *Acta Photonica Sinica*, 2019, 48(7): 0710005.
- [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, RABAUDE V, KONOLIGE K, et al. ORB: An efficient alternative to SIFT or SURF[C]//2011 International Conference on Computer Vision. Barcelona: IEEE, 2011.
- [18] 马艾强, 姚顽强. 煤矿井下移动机器人多传感器自适应融合 SLAM 方法[J]. *工矿自动化*, 2024, 50(5): 107–117.
- MA Aiqiang, YAO Wanqiang. Multi sensor adaptive fusion SLAM method for underground mobile robots in coal mines[J]. *Journal of Mine Automation*, 2024, 50(5): 107–117.
- [19] 张旭辉, 杨红强, 白琳娜, 等. 基于改进 RANSAC 特征提取的掘进装备视觉定位方法研究[J]. *仪器仪表学报*, 2022, 43(12): 168–177.
- ZHANG Xuhui, YANG Hongqiang, BAI Linna, et al. Research on the visual positioning method of tunneling equipment based on the improved RANSAC feature extraction[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(12): 168–177.
- [20] GROMPONE VON GIOI R, JEREMIE J, JEAN-MICHEL M, et al. LSD: A fast line segment detector with a false detection control[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(4): 722–732.
- [21] 姚建均, 李英朝, 吴杨, 等. 融合点线特征的视觉惯性同时定位及建图[J]. *哈尔滨工程大学学报*, 2024, 45(4): 771–778.
- YAO Jianjun, LI Yingzhao, WU Yang, et al. Visual-inertia simultaneous localization and mapping based on point-and-line features[J]. *Journal of Harbin Engineering University*, 2024, 45(4): 771–778.
- [22] 龚坤, 徐鑫, 陈小庆, 等. 弱纹理环境下融合点线特征的双目视觉同步定位与建图[J]. *光学精密工程*, 2024, 32(5): 752–763.
- GONG Kun, XU Xin, CHEN Xiaoqing, et al. Binocular vision SLAM with fused point and line features in weak texture environment[J]. *Optics and Precision Engineering*, 2024, 32(5): 752–763.
- [23] BIAN Jiawang, LIN Wenyan, LIU Yun, et al. GMS: Grid-based motion statistics for fast, ultra-robust feature correspondence[J]. *International Journal of Computer Vision*, 2020, 128(6): 1580–1593.
- [24] 王笛, 胡辽林. 基于双目视觉的改进特征立体匹配方法[J]. *电子学报*, 2022, 50(1): 157–166.
- WANG Di, HU Liaolin. Improved feature stereo matching method based on binocular vision[J]. *Acta Electronica Sinica*, 2022,

- 50(1): 157–166.
- [25] CHEN Xinyu, YU Yantao. An unsupervised low-light image enhancement method for improving V-SLAM localization in uneven low-light construction sites[J]. *Automation in Construction*, 2024, 162: 105404.
- [26] 刘冬, 于涛, 丛明, 等. 基于深度学习图像特征的动态环境视觉 SLAM 方法[J]. *华中科技大学学报(自然科学版)*, 2024, 52(6): 156–163.
- LIU Dong, YU Tao, CONG Ming, et al. Visual SLAM method for dynamic environment based on deep learning image features[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2024, 52(6): 156–163.
- [27] 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.
- [28] LAND E H. The Retinex theory of color vision[J]. *Scientific American*, 1978, 237(6): 108–128.
- [29] HE Kaiming, SUN Jian, TANG Xiaoou. Guided image filtering[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1397–1409.
- [30] KOU Fei, CHEN Weihai, WEN Changyun, et al. Gradient domain guided image filtering[J]. *IEEE Transactions on Image Processing*, 2015, 24(11): 4528–4539.
- [31] XU Xin, YU Zhibin. Low-light image enhancement based on Retinex theory[C]//2023 IEEE 6th International Conference on Electronic Information and Communication Technology (ICEICT). Qingdao: IEEE, 2023.
- [32] AKINLAR C, TOPAL C. EDLines: A real-time line segment detector with a false detection control[J]. *Pattern Recognition Letters*, 2011, 32(13): 1633–1642.
- [33] PUMAROLA A, VAKHITOV A, AGUDO A, et al. PL-SLAM: Real-time monocular visual SLAM with points and lines[C]//2017 IEEE International Conference on Robotics and Automation (ICRA). Singapore: IEEE, 2017.
- [34] STURM J, ENGELHARD N, ENDRES F, et al. A benchmark for the evaluation of RGB-D SLAM systems[C]//2012 IEEE/RSJ International Conference on Intelligent Robots and Systems. Vilamoura-Algarve: IEEE, 2012.
- [35] CAMPOS C, ELVIRA R, RODRÍGUEZ J J G, et al. ORB-SLAM3: An accurate open-source library for visual, visual-inertial, and multimap SLAM[J]. *IEEE Transactions on Robotics*, 2021, 37(6): 1874–1890.

(责任编辑 郭东琼)