

DOI: 10.19650/j.cnki.cjsi.J2107149

融合深度学习与粒子滤波的移动机器人重定位方法^{*}

杨傲雷^{1,2}, 金宏宙¹, 陈 灵³, 费敏锐^{1,2}

(1. 上海大学机电工程与自动化学院 上海 200444; 2. 上海市电站自动化技术重点实验室 上海 200444;
3. 湖南师范大学工程与设计学院 湖南 410081)

摘 要:为有效解决移动机器人重定位问题,提出一种融合深度学习和粒子滤波的机器人重定位方法。首先,提出了3自由度移动机器人重定位方法架构,主要包含重定位模型构建和机器人在线重定位两个递进阶段;其次,在PoseNet基础上提出并构建了针对3自由度移动机器人的重定位网络模型G_PoseNet,并将由G_PoseNet预测的位姿结果作为粒子滤波定位算法的初始化状态,支撑后续重定位过程;然后,提出了一种基于数据模型的机器人绑架状态判定方法,以确定是否启动重定位过程;最后,在公开数据集上与实际环境中做了大量实验验证了此方法,结果表明:G_PoseNet模型能够保证一定的位置预测精度并提升了姿态角预测精度,机器人重定位成功率达到87%。

关键词:深度学习;位姿回归;粒子滤波定位;机器人绑架;重定位

中图分类号: TP391 TH86 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Mobile robot relocalization method fusing deep learning and particle filtering

Yang Aolei^{1,2}, Jin Hongzhou¹, Chen Ling³, Fei Minrui^{1,2}

(1. School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200444, China;
2. Shanghai Key Laboratory of Power Station Automation Technology, Shanghai 200444, China;
3. College of Engineering and Design, Hunan Normal University, Hunan 410081, China)

Abstract: In order to effectively solve the relocalization problem of mobile robot, a robot relocalization method fusing deep learning and particle filtering is proposed. Firstly, a 3-DOF mobile robot relocalization framework is proposed, which mainly includes two progressive stages: relocalization model construction and robot online relocalization. Secondly, a 3-DOF mobile robot relocalization network model, G_PoseNet, is proposed and constructed based on PoseNet. The pose result predicted by G_PoseNet is used as the initialization state of particle filter localization algorithm to support the subsequent relocalization process. Then, a data model based kidnapping state judging method is proposed to determine whether to start the relocalization process. Finally, a large number of experiments on public datasets and real environment were performed to verify the proposed method. The result shows that the G_PoseNet model can guarantee a certain degree of location prediction accuracy and improve the pose angle prediction accuracy, the success rate of robot relocalization achieves 87%.

Keywords: deep learning; pose regression; particle filter localization; robot kidnapping; relocalization

0 引 言

对于需要自主执行任务的机器人来说,定位问题至关重要^[1]。作为移动机器人的基础功能,定位是其协同控制^[2]、自主避障^[3]等功能的核⼼。移动机器人定位问

题可以分为全局定位、位姿跟踪和绑架后重定位问题。重定位是指其在自主导航定位过程中由于未知外部因素影响或者定位算法长期运行后位姿失效而重新恢复位姿的过程。

在移动机器人定位领域,基于粒子滤波的定位算法应用最为广泛。粒子滤波因其具有多模态分布特性,适

收稿日期:2020-11-18 Received Date: 2020-11-18

^{*} 基金项目:上海市自然科学基金(18ZR1415100)、国家自然科学基金(61703262)项目资助

用于解决全局定位和位姿跟踪问题。但是,在粒子滤波方法中,状态空间中粒子的多样性会随着重采样的进行而逐渐减少,从而导致粒子在全局范围内的多模态分布失效,难以解决机器人被绑架后的重定位问题。Villacres等^[4]提出了一种基于强化学习的粒子重采样机制,其可在一定程度上解决绑架问题,但是定位误差相对较大。文献[5]的策略是在检测到绑架后重启粒子滤波算法,使状态空间中的粒子均匀分布,然而由于没有先验信息,粒子收敛速度慢,在环境较为复杂的情况下会定位失败。

近几年,基于视觉信息的定位方法受到深入研究,而视觉图像信息具有丰富的纹理特征,更适用于解决机器人重定位问题^[6]。采用视觉图像特征匹配的方法解决重定位的思路是通过检索机器人当前观测到的图像与预先构建的带有位姿信息的图像数据库之间的相似性^[7],重新确定机器人在全局空间中的位姿。基于内容的图像检索方法^[8]主要分为基于传统的视觉检索方法和基于深度学习的视觉检索方法。文献[9]提出在建图时融合视觉信息构建关键帧全局描述子,然后使用基于聚类的方法进行重定位,但由于其采用的是人为构建的特征描述子,难以应对实际环境中的复杂状况。

近年来,随着深度学习方法在计算机视觉领域取得巨大成功,也出现了一些基于深度学习的视觉定位系统。Kendall等^[10]提出的 PoseNet 是一种端到端的完全基于深度学习的相机重定位系统。该系统通过大量带有位姿标签数据的图片训练后能够实现输入一张 RGB 图片,输出拍摄该图片时相机的绝对位姿。Abhinav等^[11]提出了学习与绝对位姿共享特征表达的 VLocNet 系统,该系统可以同时学习绝对位姿估计和相对位姿估计任务。Xu等^[12]提出了一种基于 LSTM 的移动机器人重定位模型。针对 PoseNet 系统的过拟合问题,Walch等^[13]提出 PoseLSTM,该系统是在 PoseNet 最后的全连接层后加入四层 LSTM,限制模型的上下左右四个方向上执行回归。文献[14]提出通过 PoseNet 深度学习网络将图像数据回归得到初始位姿并在流形空间中初始化分布粒子再利用 3D-Lidar 结合粒子滤波定位得到最终的 6D 位姿。然而,上述系统都是针对 6 自由度全向移动的机器人运动场景,对于只有 3 自由度的地面移动机器人定位问题具有一定的冗余性,不能很好的应用于地面移动机器人的定位任务。

为使移动机器人在遭遇绑架后能够快速精确的重新定位,本文提出了一种融合深度学习和粒子滤波“由粗至精”的重定位方法。本文提出的重定位方法架构主要包含重定位模型构建和机器人在线重定位两个递进阶段。首先利用 SLAM 方法获得环境空间地图并采集位姿数据训练 G_PoseNet 系统以构建重定位模型;其次,设计了基于状态空间粒子集合权重的绑架判定方法,根据判定结

果选择是否进行位姿预测;然后,将位姿预测结果作为粒子滤波定位的先验信息对状态空间中的粒子进行初始化分布,进一步得到精确的重定位结果;最后,通过大量的实物平台实验,验证所提方法的可行性与有效性。

本文的主要贡献说明如下:

1) 提出了一种根据移动机器人平台特征而改进的深度学习位姿重定位系统 G_PoseNet。与原始 PoseNet 定位系统相对比,该系统可以在平面运动场景中保证一定的位置预测精度,并提升姿态角预测精度。

2) 提出了一种融合深度学习与粒子滤波定位的移动机器人重定位系统框架以及基于数据模型的主动式绑架状态判定方法,可有效地判定并解决移动机器人绑架后的重定位问题。

1 问题描述及方法架构

1.1 移动机器人绑架及其重定位问题

移动机器人位姿的参数化描述方式可不失一般性地定义为如下形式:

$${}^W_R P = (x, y, \theta) \quad (1)$$

其中, $\{W\}$ 表示机器人运动环境中的世界坐标系, $\{R\}$ 表示机器人本体坐标系,机器人在世界系下的位姿 ${}^W_R P$ 由 3 个变量 $\{x, y, \theta\}$ 定义。 (x, y) 代表机器人在 $\{W\}$ 系下的位置, θ 是世界系下机器人的前向与 x 轴的夹角。如图 1 所示。




图1 移动机器人位姿描述与重定位示意图

Fig. 1 Illustrations of pose description and relocation of mobile robot

移动机器人重定位是指机器人在遭遇绑架后位姿恢复的过程,其需要仅根据当前时刻传感器信息重新确定自身位姿。绑架与重定位问题的说明如图 1 所示:机器人在世界坐标系 $\{W\}$ 中自主运动,从 0 时刻至 t 时刻机器人依靠自身传感器信息能正确定位 ${}^W_R P_0 \rightarrow {}^W_R P_t$,然而在 $t+1$ 时刻机器人被绑架至 ${}^W_R P_{t+1}$,从 $t+1$ 时刻开始移动机器人确定其全局位姿的过程即为绑架后的重定位问题。在基于粒子滤波定位的机器人定位系统中,绑架问题会使得机器人丢失 t 时刻至 $t+1$ 时刻的传感器信息,

但同时又保留了先前时刻的定位信息 wP_R , 因此重定位问题从另一个角度来看是一个带有错误先验信息的全局定位问题。

1.2 重定位方法与架构

针对机器人重定位问题, 本文提出的整体方法架构如图2所示, 主要包括: 重定位模型构建阶段和机器人在线重定位阶段。




图2 融合深度学习与粒子滤波的重定位方法架构

Fig. 2 Relocalization method framework combining deep learning and particle filtering

机器人在线重定位阶段主要由两部分组成: 基于激光数据模型的绑架检测模块, 融合深度学习模型与粒子滤波的重定位模块。在基于激光数据模型的绑架检测模块中, 移动机器人通过接收激光观测数据, 并根据其观测模型, 计算当前状态下传感器数据与地图的匹配程度 δ_t , 然后根据 δ_t 的变化程度判断机器人是否处于绑架状态。若检测到处于绑架状态, 系统将当前时刻的图像数据输入至预先训练好的 G_PoseNet 模型, 该模型将粗略地预测此时机器人的全局位姿 ${}^w\hat{P}_R$ 。为了得到更为精确的重定位结果, 定位系统将进一步以 ${}^w\hat{P}_R$ 为粒子集合均值, 并以一定的方差初始化粒子滤波定位算法。将分布在状态空间中的粒子调整至预测位姿附近, 加快粒子收敛速度, 得到精确的定位结果 wP_R 。

2 重定位系统中 G_PoseNet 模型构建

G_PoseNet 模型是在 PoseNet 模型基础上针对平面 3 自由度机器人优化得到的重定位系统。如图3所示, 其模型构建主要包括数据预处理、特征提取、特征映射和位姿回归 4 个部分。

首先是数据预处理, 其中原始图像数据首先需要做零均值化处理, 该操作是指将训练集中的每一张样本图像 I_i 的对应像素位置的数据进行求和取平均后得到一张

重定位模型构建阶段主要是构建 G_PoseNet 网络模型。G_PoseNet 是在 PoseNet 网络基础上针对平面 3 自由度移动平台进行优化改进后得到的网络。此阶段需要将粒子滤波的定位数据与视觉相机采集的图像系列数据进行匹配, 构建带位置标签的定位图像样本集, 并据此对 G_PoseNet 网络进行模型训练, 最后将训练得到的满足性能要求的网络模型进行部署。




图3 G_PoseNet 模型构建流程

Fig. 3 The model construction process of G_PoseNet

均值图像 I_{mean} , 然后将原始图像数据与对应像素位置的均值图像数据做差后得到零均值化的样本数据。零均值化操作可以将部分图像的模糊数据带来的影响均匀分布到样本集的每一处像素上, 进而提高模型的鲁棒性。然

后将得到的图像数据进行裁剪操作得到 $224 \times 224 \times 3$ 大小的模型输入数据。

然后是特征提取阶段,主要是生成能代表图像样本数据的特征向量,也是网络模型的核心,此处的特征提取网络使用的是 GoogLeNet。它是一个深度卷积神经网络模型,由“基础神经元”inception 模块构成,这种设计方式可以兼顾性能与计算效率,可以降低深层网络模型训练过程中的模型参数数量。特征提取过程将原始图像数据映射到隐层特征空间,经过 inception5b 层之后产生一个 $7 \times 7 \times 1024$ 维的特征向量来代表原始图像数据 I_c 。

特征映射是将上一阶段得到的特征向量从隐层特征空间映射到样本标记空间,即机器人位姿空间 ${}^w_R P = (x, y, \theta)$ 。在 inception4b、inception4e 和 inception5b 层后使用全连接映射,并将映射得到的位姿结果以大约 3 等分的贡献(0.3, 0.3, 1.0)累积到总体误差中。采用这种从中间层输出并进行误差反向传播的方式可以有效防止优化过程中因网络层数较多而导致的梯度消失问题。

在位姿回归过程中, PoseNet 网络模型的系统状态为 ${}^w_R P = (x, y, z, q_0, q_1, q_2, q_3)$, 这对于只有 3 自由度 ${}^w_R P = (x, y, \theta)$ 的移动机器人系统来说是状态冗余的, 多余的自由度参数会在网络训练过程中使网络模型更加复杂, 增加网络训练时间, 降低系统预测精度。另外 PoseNet 系统需要在损失函数中增加对四元数的归一化约束这种额外的约束条件不利于优化过程的进行。

因此, 针对平面 3 自由度移动机器人平台重定位问题, 本文提出使用 (x, y, θ) 作为系统状态参数, 将 6 自由度参数优化为适应于平面场景的 3 自由度参数, 姿态角的数值选取在 $[-\pi, \pi)$ 的区间内:

$${}^w_R P = (x, y, \theta) \begin{cases} x, y \in \mathbb{R} \\ \theta \in [-\pi, \pi) \end{cases} \quad (2)$$

其中, (x, y) 表示移动机器人在平面状态空间中的位置, θ 表示移动机器人的姿态角或朝向角。相应地, 本文使用随机梯度下降的方法训练网络, 并将回归层的损失函数设计为式(3)。

$$loss = \|\hat{\mathbf{x}} - \mathbf{x}\|_2 e^{-\alpha} + \alpha + \|\hat{\theta} - \theta\|_2 e^{-\gamma} + \gamma \quad (3)$$

由于 (x, y) 与 θ 具有不同的物理意义和数值范围, 而在该网络模型中, 位置和姿态角引起的预测误差是同时被优化的。位置误差由环境大小决定, 为了控制损失函数的规模, 在损失函数式(3)中, 根据文献[15]使用可学习参数 φ 和 γ 来平衡位置误差和姿态角误差, 与通过网格搜索方法设置固定超参数的方式相比, 该方法可根据场景规模自适应地调整误差函数规模而不需要大量的调参工作。与原始 PoseNet 网络模型相比, G_PoseNet 系统的状态变量维数减少, 一方面降低了网络的复杂度, 可以加速网络训练过程, 另一方面损失函数中的姿态部分不再使用归一化的球面距离, 而直接采用状态空间的欧

氏距离, 有利于网络模型的优化收敛。

3 重定位中的绑架判定方法

当机器人发生绑架后, 为了保证系统重定位的实时性, 需要及时检测出绑架事件。本文提出一种基于已有数据模型的绑架判定方法, 通过实时计算激光点云数据与地图匹配程度突变情况, 以判断是否发生机器人绑架事件。

算法 1: 重定位系统中的绑架判定方法

输入:

N_{t_j} : 当前时刻状态空间中的粒子总数;

χ_{t_i} : 上一时刻状态空间中的粒子集合;

χ_{t_j} : 当前时刻状态空间中的粒子集合;

u_{t_j} : 当前时刻的里程计信息;

z_{t_j} : 当前时刻的激光观测信息;

算法步骤:

1. 读取 t_j 时刻状态空间粒子总数 $N = N_{t_j}$;

2. 从 $idx = 1$ 开始, 至 $idx = N$:

输入当前时刻里程计信息 u_{t_j} 和上一时刻粒子集合中的位姿信息 $(p_{t_i}^{idx} | \chi_{t_i})$, 由运动模型采样更新当前时刻粒子位姿信息 $(p_{t_j}^{idx} | \chi_{t_j})$;

输入当前时刻激光观测信息 z_{t_j} 和当前时刻粒子位姿信息 $(p_{t_j}^{idx} | \chi_{t_j})$, 由观测模型更新当前时刻的粒子权重 $(w_{t_j}^{idx} | \chi_{t_j})$, 得到 χ_{t_j} ;

3. 根据得到的粒子权重 $w_{t_j}^{idx}$ 计算总体权重:

$$\partial_{t_j} = \sum_{idx=1}^N w_{t_j}^{idx}, \partial_{t_i} = \sum_{idx=1}^N w_{t_i}^{idx}$$

计算当前时刻权重变化率 Δw :

$$\Delta w = \frac{|\partial_{t_j} - \partial_{t_i}|}{\partial_{t_i}}$$

4. 计算当前时刻的绑架概率 $P(t_j) = \min(\Delta w, 1)$;

如果 $P(t_j) > 0.5$, 则机器人处于绑架状态:

$$kidnapping = 1;$$

否则:

$$kidnapping = 0;$$

5. 返回 kidnapping 标志位;

算法 1 描述了重定位系统中的绑架判定的计算步骤。在基于似然域的激光观测模型中, 若只考虑测量误差 d_{dist} , 其似然域观测模型为零均值的高斯分布模型, 当

测量误差 d_{dist} 表示为其绝对值形式 $d = |d_{dist}|$ 时, d 与激光观测数据概率模型 P_{hit} 之间的反比例关系可以表示为:

$$d \propto \frac{1}{P_{hit}(z_t^k | x_t, m)} \quad (4)$$

式(4)说明当机器人被绑架后,其当前时刻的测量误差变大,将导致粒子滤波的状态空间中粒子观测似然概率变小,粒子权重 w_t^i 也相应变小。因此可将当前时刻的激光点云数据与地图的匹配程度 ∂_t 定义为:

$$\partial_t = \sum_{i=1}^N w_t^i \quad (5)$$

其中, N 为集合中粒子总数。粒子集合权重的累加和 ∂_t 可用来表示当前时刻定位状态与地图的匹配程度。根据 ∂_t 的变化率 Δw 判断当前时刻机器人是否被绑架,即

$$kidnapping = \begin{cases} 1, P(t) > 0.5 \\ 0, P(t) \leq 0.5 \end{cases} \quad (6)$$

当概率值 $P(t)$ 大于阈值 0.5 时,即可认为移动机器人发生绑架问题,应进行及时的重定位;

4 实验数据准备

4.1 OpenLORIS 数据集

为了验证 G_PoseNet 系统在室内移动场景中的定位精度,本文使用 OpenLORIS-Scene 公开数据集^[16]进行模型训练和测试。该数据集全部由真实机器人在真实场景中采集,适用于室内移动机器人 SLAM 算法评估,包含办公室、走廊、家庭、咖啡厅和超市 5 类场景的多种传感器数据,以及由动作捕捉系统或高精度激光雷达提供的机器人轨迹真值。OpenLORIS-Scene 最大的特点在于“场景重入”,即同一场景会有多段数据,录制时间从半天到几周不等,因此其中包含了日常生活中常见的明暗变化和动态场景,适用于验证定位算法的鲁棒性。

为测试 G_PoseNet 系统的相机重定位精度,选取 OpenLORIS-Scene 数据集中 3 种场景下的 6 组数据序列,如图 4 所示,分别为咖啡厅场景中的 Cafe1-1 序列和 Cafe1-2 序列,该场景中包含了人员的动态变化现象;家庭场景中的 Home1-1 序列和 Home1-2 序列,该场景中包含了常用物品的位置变化现象;走廊场景中的 Corridor1-1 序列和 Corridor1-2 序列,该场景中包含了光照亮度的变化。所有图像数据的分辨率均为 $840 \times 480 \times 3$ 。然后按照 7:3 的比例将上述每一组数据序列划分为训练集和测试集。

4.2 机器人重定位实验数据

本文采用配置有 Kinect 相机、2D 激光雷达 (RPLIDAR-A2) 和轮式里程计的 ROS 机器人平台进行重定位实验。



图 4 OpenLORIS-Scene 数据集场景

Fig. 4 OpenLORIS-Scene dataset scenes

为了获取机器人的位姿信息,首先利用 SLAM 的方式建立实验环境地图,如图 5 所示,实验环境为学院大楼走廊空间,然后控制机器人在环境中进行多个方向多个位置的移动,采集位姿数据。




图 5 SLAM 建立的走廊地图与机器人行驶轨迹

Fig. 5 Corridor map created by SLAM and robot walking trajectory

通过 ROS 系统控制机器人在实验环境中运动,所采集的训练样本数据与测试样本数据应存在一定程度的共视,但不完全一致。同样要求按照 7:3 的比例构建样本训练集和测试集。该阶段共采集训练样本 2 016 张,测试样本 864 张。

5 网络模型训练评估与实验

5.1 G_PoseNet 系统实验评估

为了测试 G_PoseNet 网络的位置和姿态角预测精度,本文选择与 PoseNet 和 PoseLSTM 两个重定位系统做对比实验。本文中所有网络模型的训练过程均采用统一

的计算平台,配置显卡为 NVIDIA GeForce GTX 1080, CPU 为 3.6 GHz Intel Core i7-7700。所有系统均在

PyTorch 平台上搭建训练,使用 Adam 优化器,学习率设置为 $5e^{-4}$,初始训练参数 $\alpha_0 = \gamma_0 = 0$ 。




图6 重定位系统在各数据集上的误差累计直方图

Fig. 6 Cumulative error statistic histogram of the relocation system in various datasets

基于深度学习的相机重定位系统的实验评估指标为位置预测误差 ΔP (单位:m)和角度预测误差 $\Delta \theta$ (单位: $^{\circ}$)。由于 G_PoseNet 系统是 3 自由度系统,而 PoseNet 和 PoseLSTM 是 6 自由度系统, ΔP 和 $\Delta \theta$ 的计算方式要根据系统状态量的具体形式确定。对于 6 自由度系统,误差指标的计算方式为:

$$\Delta P = \sqrt{(\hat{x} - x)^2 + (\hat{y} - y)^2 + (\hat{z} - z)^2} \quad (7)$$

$$\Delta \theta = \frac{2 \times 180}{\pi} \cos^{-1}(\hat{\mathbf{q}} \cdot \mathbf{q}) \quad (8)$$

其中,姿态角预测量 $\hat{\mathbf{q}}$ 与真值 $\mathbf{q}$ 的点乘描述了两个四元数之间的差异。3 自由度系统的误差指标计算方式为:

$$\Delta P = \sqrt{(\hat{x} - x)^2 + (\hat{y} - y)^2} \quad (9)$$

$$\Delta \theta = |\hat{\theta} - \theta| \times \frac{180}{\pi} \quad (10)$$

每一组测试数据中包含了许多的 ΔP 和 $\Delta \theta$, 为了避免极端异常值对测试结果的影响,本文选取中位数指标衡量模型的预测精度。如表 1 所示,分别计算了 3 个重定位系统在 6 组数据集上的位置误差和姿态角误差。在 6 组数据集测试中, G_PoseNet 系统的平均姿态角预测误差为 1.08° , 平均位置预测误差为 0.38 m。从图 6 的误差累计直方图中可以看出 G_PoseNet 系统在位置预测精

度上位于次优水平,在姿态角预测精度上要优于 PoseLSTM 和 PoseNet 系统。实验表明 G_PoseNet 系统在保证了相似的位置预测精度的同时,提升了姿态角预测精度。

表 1 重定位系统在多个数据集上的对比实验

Table 1 Comparative experiments of the relocation system in various datasets

数据集	各系统重定位实验结果中位数对比		
	PoseNet	PoseLSTM	G_PoseNet
Cafe1-1	0.47 m, 1.33 $^{\circ}$	0.22 m, 1.30 $^{\circ}$	0.46 m, 1.04 $^{\circ}$
Cafe1-2	0.23 m, 1.77 $^{\circ}$	0.21 m, 2.76 $^{\circ}$	0.30 m, 0.92 $^{\circ}$
Home1-1	0.19 m, 1.22 $^{\circ}$	0.60 m, 1.58 $^{\circ}$	0.22 m, 1.29 $^{\circ}$
Home1-2	0.29 m, 1.49 $^{\circ}$	0.35 m, 1.92 $^{\circ}$	0.21 m, 1.09 $^{\circ}$
Corridor1-1	0.40 m, 1.45 $^{\circ}$	0.65 m, 2.04 $^{\circ}$	0.51 m, 1.15 $^{\circ}$
Corridor1-2	0.35 m, 1.16 $^{\circ}$	0.37 m, 2.08 $^{\circ}$	0.59 m, 0.99 $^{\circ}$
平均值	0.32 m, 1.40 $^{\circ}$	0.40 m, 1.95 $^{\circ}$	0.38 m, 1.08 $^{\circ}$

5.2 机器人在线重定位实验

本小节验证了该重定位方法在实际机器人平台上的重定位能力,首先使机器人正确定位,在定位过程中通过

接收激光数据并根据其观测模型实时计算当前状态下激光数据与地图的匹配程度 δ_t , 然后判断机器人是否处于绑架状态。若处于绑架状态, 机器人系统将当前状态下的图像数据输入至预先训练好的 G_PoseNet 模型, 模型将粗略预测该状态下移动机器人位姿 ${}^w_R\hat{P}_t$, 然后系统以预测位姿 ${}^w_R\hat{P}_t$ 为粒子集合均值初始化分布粒子滤波定位模块, 并利用粒子滤波定位方法实现精确的重定位。

本文选取自适应蒙特卡洛定位方法 (AMCL) 作为在线重定位实验的对比方法。AMCL 是一种成熟的基于粒子滤波的机器人定位算法, 被广泛应用于平面移动机器人定位领域。该算法可通过在全局状态空间均匀分布粒子的方式实现全局定位, 并且在重采样过程中会向状态空间加入一定数目的随机粒子, 具有一定的重定位能力。并且为了增加 AMCL 重定位的成功率, 使其进行全局定位, 即在全局空间均匀分布粒子后进行采样定位。

为了验证所构建重定位模型预测的准确性和有效性, 本文将融合深度学习的重定位模型在实际移动平台上进行部署, 并进行了如图 7 所示的实验验证。首先控制移动机器人在地图中的 A 点、C 点、E 点和 H 点实现正确定位, 然后人为地将机器人分别绑架至 B 点、D 点、G 点、F 点和 I 点后, 进行在线重定位测试, 每组实验重复进行 20 次, 统计 5 组实验平均定位时间与定位成功率, 并对比本文提出的重定位方法与 AMCL 定位方法的效果。




图 7 移动机器人在线重定位实验

Fig. 7 Mobile robot online relocalization experiment

实验结果统计数据如表 2 所示: 在 5 组重定位测试中, 本文的方法在 AB 组数据重定位过程中平均定位时长为 11.26 s, 成功定位 20 次, 成功率为 100%, 而 AMCL 对照组的平均定位时长为 23.2 s, 成功率只有 70%; CD 组为近距离绑架实验, 本文提出的方法用时 10.23 s, AMCL 系统用时 21.42 s; 在 EF 组实验中, 由于 F 点位置处于结构特征不明显的直线走廊中, AMCL 的全局定位基本失效, 因只有 15% 的成功率, 而本文的方法可以根据 G_PoseNet 的预测结果有效地初始化粒子滤波定位算法使其重定位成功, 成功率达到 80%。

综合实验测试数据表明, 在本文提出的融合深度学习与粒子滤波的移动机器人重定位方法中, 机器人能以 87% 的成功率从绑架中恢复自身位姿, 平均定位用时 10.12 s。

表 2 在线重定位实验统计

Table 2 Online relocalization experiment statistics

实验组	G_PoseNet+粒子滤波		AMCL 全局定位	
	平均用时/s	成功率	平均用时/s	成功率
AB 组	11.26	20/20	23.2	14/20
CD 组	10.23	15/20	21.42	10/20
CG 组	10.15	18/20	41.25	9/20
EF 组	7.5	16/20	32.40	3/20
HI 组	11.46	18/20	35.71	8/20
平均值	10.12	87%	30.80	44%

6 结 论

本文提出了一种融合深度学习和粒子滤波的移动机器人绑架后重定位方法, 克服了单纯使用粒子滤波无法有效进行绑架后重定位的缺陷。在 PoseNet 的基础上提出了针对平面移动机器人平台的重定位网络模型 G_PoseNet, 以及基于数据的机器人绑架判定方法。验证结果表明, 绑架后机器人重定位成功率达到 87%, 充分验证了本文所提方法的可行性与有效性。

参考文献

- [1] 吕攀, 辛越, 张恒, 等. 基于 MSCKF 的 IMU 与激光雷达紧耦合定位方法 [J]. 仪器仪表学报, 2020, 41(8): 13-20.
LYU P, XIN Y, ZHANG H, et al. Tightly coupled localization of IMU and lidar based on MSCKF [J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 13-20.
- [2] YANG A, NAEEM W, IRWIN G W, et al. Stability analysis and implementation of a decentralized formation control strategy for unmanned vehicles [J]. IEEE Transactions on Control Systems Technology, 2014, 22(2): 706-720.
- [3] YANG A, NAEEM W, FEI M, et al. A co-operative formation-based collision avoidance approach for a group of autonomous vehicles [J]. International Journal of Adaptive Control & Signal Processing, 2016, 31(4): 489-506.
- [4] VILLACRES J L C, ZHAO Z L, BRAUN T, et al. A particle filter-based reinforcement learning approach for reliable wireless indoor positioning [J]. IEEE Journal on Selected Areas in Communications, 2019, 37(11): 2457-2473.
- [5] XIE H W, GU T, TAO X P, et al. A reliability-augmented particle filter for magnetic fingerprinting based

- indoor localization on smartphone[J]. IEEE Transactions on Mobile Computing, 2016, 15(8):1877-1892.
- [6] MICHAEL H, RALF M. Visual place recognition for autonomous mobile robots[J]. Robotics, 2017, 6(2):9.
- [7] 曹风魁, 庄严, 闫飞, 等. 移动机器人长期自主环境适应研究进展和展望[J]. 自动化学报, 2020, 46(2):205-221.
- CAO F K, ZHUANG Y, YAN F, et al. Long-term autonomous environment adaptation of mobile robots: State-of-the-art methods and prospects [J]. Acta Automatica Sinica, 2020, 46(2):205-221.
- [8] GEZAWA A S, ZHANG Y, WANG Q. A review on deep learning approaches for 3D data representations in retrieval and classifications[J]. IEEE Access, 2020, 8: 57566-57593.
- [9] SU Z, ZHOU X, CHENG T, et al. Global localization of a mobile robot using LiDAR and visual features[C]. IEEE International Conference on Robotics and Biomimetics, 2017:2377-2383.
- [10] KENDALL A, GRIMES M, CIPOLLA R. PoseNet: A convolutional network for real-time 6-dof camera relocalization[C]. IEEE International Conference on Computer Vision (ICCV), 2015:2938-2946.
- [11] ABHINAV V, NOHA R, WOLFRAM B. Deep auxiliary learning for visual localization and odometry[C]. IEEE International Conference on Robotics and Automation (ICRA), 2018:6939-6946.
- [12] XU S, CHOU W, DONG H. A robust indoor localization system integrating visual localization aided by CNN-based image retrieval with Monte Carlo localization [J]. Sensors, 2019, 19(2):249.
- [13] WALCH F, HAZIRBAS C, LEAL-TAIXE L. Image-based localization using LSTMs for structured feature correlation [C]. IEEE International Conference on Computer Vision (ICCV), 2017:627-637.
- [14] JO H, KIM E. New monte carlo localization using deep initialization: A three-dimensional LiDAR and a camera fusion approach [J]. IEEE Access, 2020, 8: 74485-74496.
- [15] KENDALL A, CIPOLLA R. Geometric loss functions for camera pose regression with deep learning [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017:5974-5983.
- [16] SHI X, LI D, ZHAO P, et al. Are we ready for service robots? The OpenLORIS-Scene datasets for lifelong SLAM [C]. International Conference on Robotics and Automation (ICRA), 2020:3139-3145.

作者简介



杨傲雷, 2004 年于湖北工业大学获得学士学位, 2009 年于上海大学获得硕士学位, 2012 年于英国女王大学获得博士学位, 现为上海大学副教授, 主要研究方向为多智能体协同控制、智能机器人与视觉学习系统、无人机群协同编队与控制等。

E-mail: aolei@shu.edu.cn

Yang AoLei received his B. Sc. degree in 2004 from Hubei University of Technology, M. Sc. degree in 2009 from Shanghai University and Ph. D. degree in 2012 from Queen's University Belfast, UK. Now, he is an associate professor in Shanghai University. His main research interest includes multi-intelligence cooperative control, intelligent robot and visual learning system, UAV group cooperative formation and control, etc.



陈灵 (通信作者), 2008 年于中南大学获得学士学位, 2010 年于中南大学获得硕士学位, 2014 年于英国埃塞克斯大学获得博士学位, 现为湖南师范大学副教授, 主要研究方向为计算机视觉、机器人定位与导航。

E-mail: lcheno@hunnu.edu.cn

Chen Ling (Corresponding author) received his B. Sc. degree in 2008 and M. Sc. degree in 2010 both from Central South University, received his Ph. D. degree in 2014 from University of Essex, UK. Now, he is an associate professor in Hunan Normal University. His main research interest includes computer vision and robot localization and navigation.