

5-15-2024

Deep Learning Based Local Path Planning Method for Moving Robots

Zesen Liu

School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China, ftyg@live.com

Sheng Bi

School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China, picy@scut.edu.cn

Chuanhong Guo

School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China

Yankui Wang

School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Deep Learning Based Local Path Planning Method for Moving Robots

Abstract

Abstract: In order to integrate visual information into the robot navigation process, improve the robot's recognition rate of various types of obstacles, and reduce the occurrence of dangerous events, a local path planning network based on two-dimensional CNN and LSTM is designed, and a local path planning approach based on deep learning is proposed. The network uses the image from camera and the global path to generate the current steering angle required for obstacle avoidance and navigation. A simulated indoor scene is built for training and validating the network. A path evaluation method that uses the total length and the average curvature change rate of path and the distance between robot and obstacle as metrics is also proposed. Experiments show that the proposed approach has good local path generation capability in both simulated and real scenes.

Keywords

robot navigation, path planning, real-time obstacle avoidance, deep learning

Authors

Zesen Liu, Sheng Bi, Chuanhong Guo, Yankui Wang, and Min Dong

Recommended Citation

Liu Zesen, Bi Sheng, Guo Chuanhong, et al. Deep Learning Based Local Path Planning Method for Moving Robots[J]. Journal of System Simulation, 2024, 36(5): 1199-1210.

基于深度学习的机器人局部路径规划方法

刘泽森, 毕盛*, 郭传钰, 王延葵, 董敏

(华南理工大学 计算机科学与工程学院, 广东 广州 510006)

摘要: 为了将视觉信息融入到机器人导航过程中, 提高机器人对各类障碍物的识别率, 减少危险事件的发生, 设计了基于二维CNN及LSTM的局部路径规划网络。提出了基于深度学习的局部路径规划方案。利用机器人视觉信息及全局路径信息推理产生机器人在当前时刻完成避障导航任务所需转向角度; 搭建了用于对规划器核心神经网络进行训练和验证的室内场景; 提出了以路径总长度、平均曲率变化率及机器人与障碍物之间的距离为性能指标的路径评估方案。实验表明: 该方案在仿真环境及真实场景中均体现了较优秀的局部路径生成能力。

关键词: 机器人导航; 路径规划; 实时避障; 深度学习

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2024)05-1199-12

DOI: 10.16182/j.issn1004731x.joss.22-1546

引用格式: 刘泽森, 毕盛, 郭传钰, 等. 基于深度学习的机器人局部路径规划方法[J]. 系统仿真学报, 2024, 36(5): 1199-1210.

Reference format: Liu Zesen, Bi Sheng, Guo Chuanhong, et al. Deep Learning Based Local Path Planning Method for Moving Robots[J]. Journal of System Simulation, 2024, 36(5): 1199-1210.

Deep Learning Based Local Path Planning Method for Moving Robots

Liu Zesen, Bi Sheng*, Guo Chuanhong, Wang Yankui, Dong Min

(School of Computer Science and Engineering, South China University of Technology, Guangzhou 510006, China)

Abstract: In order to integrate visual information into the robot navigation process, improve the robot's recognition rate of various types of obstacles, and reduce the occurrence of dangerous events, a local path planning network based on two-dimensional CNN and LSTM is designed, and a local path planning approach based on deep learning is proposed. The network uses the image from camera and the global path to generate the current steering angle required for obstacle avoidance and navigation. A simulated indoor scene is built for training and validating the network. A path evaluation method that uses the total length and the average curvature change rate of path and the distance between robot and obstacle as metrics is also proposed. Experiments show that the proposed approach has good local path generation capability in both simulated and real scenes.

Keywords: robot navigation; path planning; real-time obstacle avoidance; deep learning

0 引言

机器人自主导航技术是其智能化的重要内容。目前, 移动机器人导航通常采用需要预先构建全

局地图的激光方案。在已知当前环境固定障碍物的情况下, 机器人能够通过安装在其机身上的激光传感器获取周边物体的点云信息, 进而使用自

收稿日期: 2022-12-29

修回日期: 2023-03-06

基金项目: 广东省科技计划(2020A0505100015); 高校教师特色创新研究项目(2022DZXX03); 华南理工大学“百步梯攀登计划”(j2tw202202079)

第一作者: 刘泽森(2001-), 男, 本科生, 研究方向为移动机器人系统。E-mail: ftyg@live.com

通讯作者: 毕盛(1978-), 男, 副教授, 博士, 研究方向为智能机器人。E-mail: picy@scut.edu.cn

适应蒙特卡罗等匹配算法实现在全局地图中的定位。得到当前位姿后,路线的生成工作由全局路径规划器和局部路径规划器完成。全局路径规划器常使用 A*和 Dijkstra 等算法实现,能够规划出用于导航的全局路径。局部路径规划器在全局路径的基础上实现了对导航过程中地图上不存在的动态障碍物的避让。两种规划器互相协作,最终赋予机器人避障导航能力。

目前, DWA(dynamic windows approach)和 TEB(timed elastic band)等常用的局部路径规划算法均以二维栅格地图等信息作为输入,计算在满足各类限制条件下机器人的避障导航路径以及当前所需要的速度和转向角。对于搭载单线激光雷达的机器人,激光雷达提供的点云数据被用于构建和更新地图,使得局部路径规划器能够依此感知周围环境。对于搭载多线激光雷达的机器人,若其构型较为简单,通常的做法是在路径规划阶段将三维点云数据投影至平面上,进而调用上述局部路径规划算法实现避障导航功能。然而,若机器人拥有机械臂等较复杂构型,向二维平面的简单投影可能难以准确反映不同高度障碍物对碰撞的判定。这将使机器人在环境中的可行区域缩小,从而在路径规划中产生次优路径甚至无法产生可行路径。针对此类问题,文献[1]根据机器人的形态使用多层二维栅格图和三维地图的组合来表示环境信息,实现了更为精细的实时碰撞检测和路径规划,提高了此类机器人的效率和实用性。

上述路径规划方法在环境感知准确的情况下均能够实现较好的避障导航效果,但其也不可避免地存在一定的局限性。由于这类算法对环境的探测完全依赖于激光传感器的点云数据,对于低反射率障碍物,单线和多线激光传感器均有漏检和受到干扰的可能。除此之外,考虑到成本问题,目前大部分机器人均采用单线激光实现对环境探测,这意味着低矮障碍物、不平地面等也难以被检出,进而影响算法的性能,甚至导致机器人

与障碍物相撞。

基于深度学习的计算机视觉技术发展迅速,神经网络能够被可靠地用于场景图片的特征提取,从而辅助移动机器人实现对运动指令的决策。与激光传感器在几个切面上的点云数据相比,图像信息能够更全面地反映周边的障碍物情形^[2]。在图像数据上通过深度学习对运动指令进行决策的方案已受到较为广泛的研究,并已在工业及农业无人机^[3-4]、无人潜航器^[5]等实际应用领域进行了一定程度的探索。文献[6]将汽车和自行车在公路上采集的数据集用于对转向角度和碰撞概率模型的训练,得到能够控制无人机运动的模型;文献[7-9]采用示教方式操控机器人在室内环境中运动,训练了能够操控轮式机器人规避障碍物的 CNN 网络;文献[10]设计了从广角图像中预测前方物体距离信息的模型,并用于高速远程小车的自动控制;文献[11]使用强化学习方案,从 RGB 图像中提取深度信息,最终生成机器人小车对于线速度和角速度的决策。此类研究利用神经网络感知图像信息,进而生成能够避开前方障碍物的控制指令。然而,这些方法存在缺失全局目标指引的问题,机器人通常只能沿固定场景的示教路线运动,难以实现向指定目标导航的能力。文献[12]利用单线激光雷达数据和强化学习方法训练了能够用于局部避障导航的网络,在室内环境获得了较好的效果,但其依赖于激光雷达的点云数据,与传统方案一样容易受到障碍物反射率、高度等因素的影响。

本文提出一种基于深度学习的机器人局部路径规划方案。该方案同样需要获取激光传感器信息,但该信息仅用于在全局地图上实现机器人的精确定位。与传统算法不同,该方案在避障以及局部路径的规划(即对机器人底盘的速度指令输出)功能上去除了对激光数据的依赖,完全以 RGB 广角摄像头信息及全局路径规划器的输出数据作为信息来源,输出移动机器人避开局部动态障碍物且跟随全局路径所需的转向角度。在拥有较为优

秀模型的前提下, 其能够更准确地识别出机器人前方的各类障碍, 消除了反射率、障碍物高度对于机器人环境感知的影响, 从而减少机器人漏检障碍物导致碰撞等事故的发生。除此之外, 该方案的主要部分采用神经网络, 将局部路径规划任务转化为网络推理任务, 最大程度地利用了嵌入式开发板上的加速硬件, 有效减轻了处理器的负载, 提高了机器人的灵活性和可靠性。

1 局部路径规划器设计

在机器人操作系统(robot operating system, ROS)中, 机器人的导航由一系列相关的软件包实现。在导航的开始阶段, 全局路径规划器读取地图服务器发送的栅格地图信息, 结合用户指定的目标点位置产生一组路径点。这组路径点是机器人从当前位置前往目标点的最优全局可行路径。在该路径的基础上, 传统的局部路径规划器将获

取激光等传感器的数据, 在避开动态障碍物的同时尽其所能跟随全局路径, 最终生成速度指令发送至机器人底盘执行。

本文提出的局部路径规划器是一个基于 ROS 框架开发的软件包, 其完全兼容 ROS 导航栈, 可以与各类全局路径规划器配合使用。该规划器的结构如图 1 所示。

在导航框架每次请求规划器生成速度指令时, 该软件包采样全局路径规划器产生的路径点, 使用纯追踪算法结合机器人当前位姿计算机器人跟随全局路径所需的转向角。在此之后, 从摄像头获得的图像数据将与该角度一起成为端对端神经网络的两个输入。该网络通过推理输出转向角度指令, 驱动机器人小车运动。在推理部分, 该软件包利用 NVIDIA 的 TensorRT 边缘 AI 计算框架将计算任务加载到对应的专用加速硬件上, 节省了处理器的计算资源。

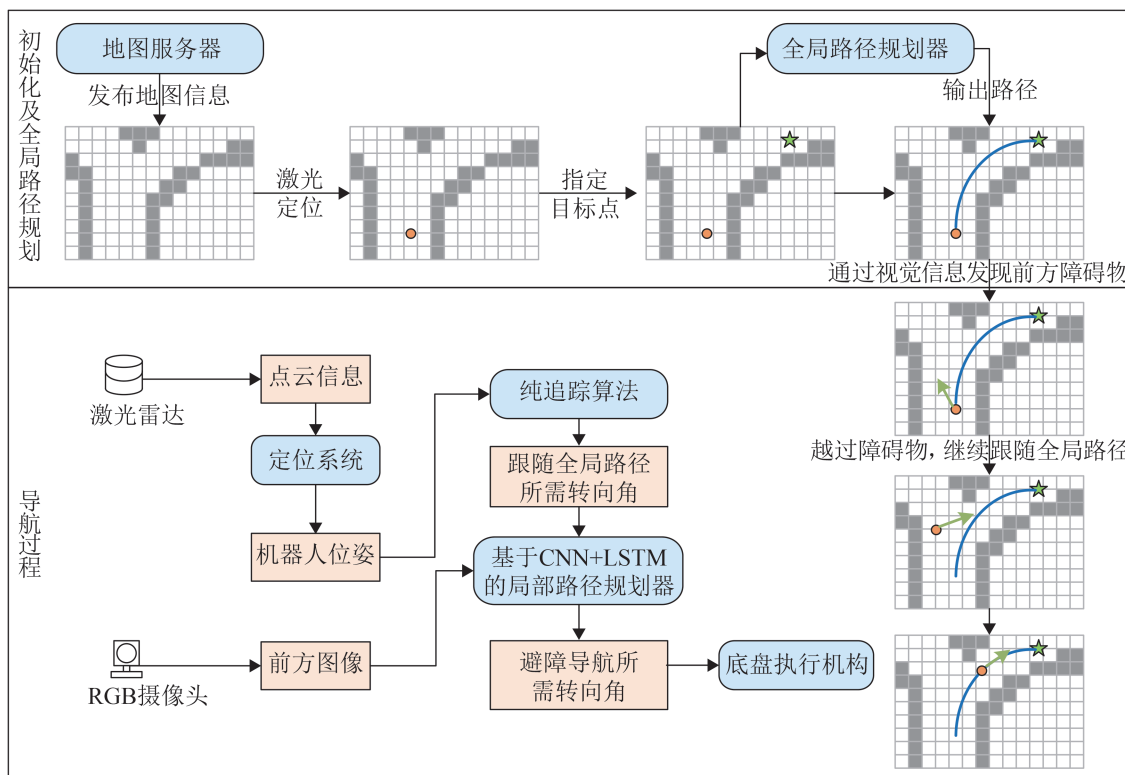


图 1 基于深度学习的局部路径规划器结构
Fig. 1 Structure of deep learning based local path planner

1.1 跟随全局路径的转向角计算

在局部路径规划器被调用的时刻，全局路径已经计算完成，且作为参数传递到规划器中。该路径是地图上的一组离散位点，不包含对应的姿态信息。转向角的计算使用纯追踪算法实现。将全局路径上的每个位点转换到机器人坐标系上，由于位点对于全局路径而言是有序的，故算法从路径的末端向前遍历寻找参考点。第一次找到小于指定前视距离的点时，不再向前遍历，确定以该点作为参考。通过纯追踪算法的计算式可以得到曲率为

$$\gamma = \frac{2x}{d^2} \quad (1)$$

式中： x 为追踪位点在机器人坐标系上的 x 轴坐标； d 为位点与机器人的欧氏距离； γ 为根据位点确定的曲率值。

结合具体机器人的形态和运动方式，即可通过该曲率得到最终需要发送至底盘的角速度指令。算法实现如下。

算法 1 基于纯追踪算法的转向角计算算法 (以两轮模型为例)

输入：全局路径规划器返回的位点序列 $V = \{e_1, e_1, \dots, e_N\}$ 和机器人当前位姿 P

输出：跟随全局路径所需要的转向角

function calculateGlobalPlanAngle(V, P)

botYaw \leftarrow getYaw(P .orientation);

for $j \in \text{reversed}(V)$ do

if getEuclideanDistance(j, P) < lookAhead

Distance then

target $\leftarrow j$;

break;

curvature \leftarrow

$2 * \text{target.x} / \text{getEuclideanDistanceSquared}(\text{target}, P)$;

return arctan(curvature * wheelSeparation)

其中，getEuclideanDistance 函数用于计算两点之间的欧氏距离，lookAheadDistance 为算法的

前视距离参数。在纯追踪算法中，前视距离越大意味着路径的追踪越平滑，与全局路径的偏差程度也可能相应更大；较小的前视距离可以实现对全局路径更细腻的追踪，但其在跟随路线的过程中可能出现轨迹震荡的现象^[13]。

1.2 局部路径规划器网络

本文提出的局部路径规划器基于 CNN 和 LSTM 端对端神经网络实现，其网络结构如图 2 所示。该网络的前端分为视觉感知和全局目标参考两部分。其中，视觉感知部分输入 384×384 尺寸的 RGB 图像信息，而全局目标参考部分输入通过全局路径计算得到的转向角数值。两种类别的信息进行融合并通过网络后端推理，最终输出机器人在避开障碍物的情况下前往导航目标所需的转向角度。由于图像信息与转向角数值属于异构模态数据，该网络使用了多模态方法抽取这两种数据的特征，在模型的中间层次进行两部分信息的融合操作，实现了数据之间的交互。

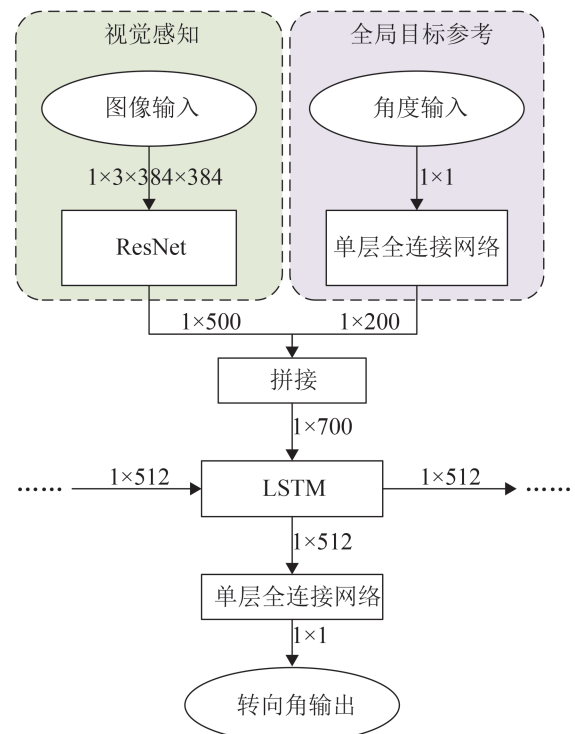


图2 路径规划器神经网络结构图

Fig. 2 Structure of neural network for path planning

多模态融合方法主要用于联合各个模态数据特征, 构建包含各类数据的融合信息, 从而为后续学习和推理提供稳定的表征。目前, 该方法已被广泛应用于视觉与自然语言融合等领域。对于多模态数据, 常见的融合方法有基于简单操作的、基于注意力机制的, 以及基于双线性池化的^[14]。由于角度数据的特征表示相对朴素, 本文提出的网络使用简单拼接操作对视觉感知部分中的图像特征以及全局目标参考部分中的角度特征进行整合, 构建两种数据的融合特征, 并将其作为后续网络的输入。

在视觉感知部分, 本文使用 CNN 网络 ResNet 对机器人摄像头图像进行感知, 该部分输出前方场景对应的特征信息; 在全局目标参考部分, 本文首先利用全局路径信息计算得到转向角, 之后通过单层全连接网络扩展传入的转向角数据的维度, 以此增强该信息对于最终决策的影响, 实现机器人对全局路径的跟随。对这两个部分的输出进行拼接, 构成了机器人在导航过程中的当前状态。

在拥有上述状态信息后, 本文进一步设计了能够根据当前状态信息对机器人此刻的行动做出决策的网络。由于机器人的导航和避障是一个连续的过程, 其在每个时间点的决策都与其之前一段时间的决策相关, 过去一段时间的导航决策是机器人在当前状态下有效避开障碍物的重要参考。因此, 本文提出的局部路径规划器使用 LSTM 实现决策任务。LSTM 是循环神经网络的一种, 能够有选择地记忆和遗忘过去的序列信息^[15]。在实际导航过程中, 该结构有利于保证机器人绕行障碍物路径的连贯性和平滑性。

2 模型实现与仿真

本文提出的基于深度学习的局部路径规划方案对模型提出了较高的要求。该端对端模型直接输出机器人的速度指令, 故模型训练的结果很大

程度影响了导航过程的可靠性。模型的验证流程采用仿真环境完成网络训练。基于 ROS 框架的仿真通常包括 GazeBo 和 Unity 3D 两种方案。GazeBo 是 Open Robotics 开源的一个与 ROS 框架深度绑定的仿真引擎, 提供了一系列的组件和功能, 对于机器人关节运动的物理模拟和相关传感器的仿真完善程度较高^[16]。然而, 其图形渲染能力相对较弱, 无法对真实场景的光影进行较好的仿真, 不利于该局部路径规划方案在真实移动机器人上的验证和部署。Unity 3D 引擎是 Unity Technologies 开发的一个跨平台且应用广泛的实时内容开发工具。在该引擎上有 URP(universal render pipeline)、HDRP(high definition render pipeline)等多种渲染管线可选。其中, HDRP 渲染管线提供了高清图形和真实光照的支持, 能够刻画丰富细致的环境效果, 真实地描绘物理世界中的材质和阴影。Unity 引擎与 ROS 框架的连接需要通过第三方插件 ROS# 实现, 该插件使用 WebSocket 与局域网中的 ROS 节点进行通信, 且具有模拟激光雷达、摄像头等传感器的能力。不少学者在 Unity 3D 和 ROS 结合方面做了一些尝试, 并在自主送货机器人^[17]及水下机器人^[18]仿真上取得了良好的效果。由于本文提出的局部路径规划方案具有部署到真实的移动机器人上的目标, 故整个网络训练以及模型验证流程使用 Unity 3D 引擎以及基于该引擎的 HDRP 渲染管线实现, 以使模型的训练和验证环节更接近于真实世界^[19], 使其能够更好地被用于衡量模型的避障导航性能。

相较于使用真实机器人在实际场景中进行训练, 使用虚拟仿真环境具有以下优点。①训练耗时短: 在真实环境中, 机器人的速度受到底盘电机以及物理规律的限制, 每次数据收集过程耗时间较长, 不利于模型的快速迭代训练和收敛。仿真环境则克服了以上问题, 对于机器人移动速度的限制仅与仿真引擎的画面渲染速度有关。②灵活性强: 在仿真环境中, 机器人机身摄像头的位置、视场角、曝光程度可以随机调整, 从而

模拟在安装有不同型号摄像头的真实机器人的导航效果。

本文针对提出的局部路径规划方案设计了完整的模型实现与仿真流程，技术路线如图3所示。

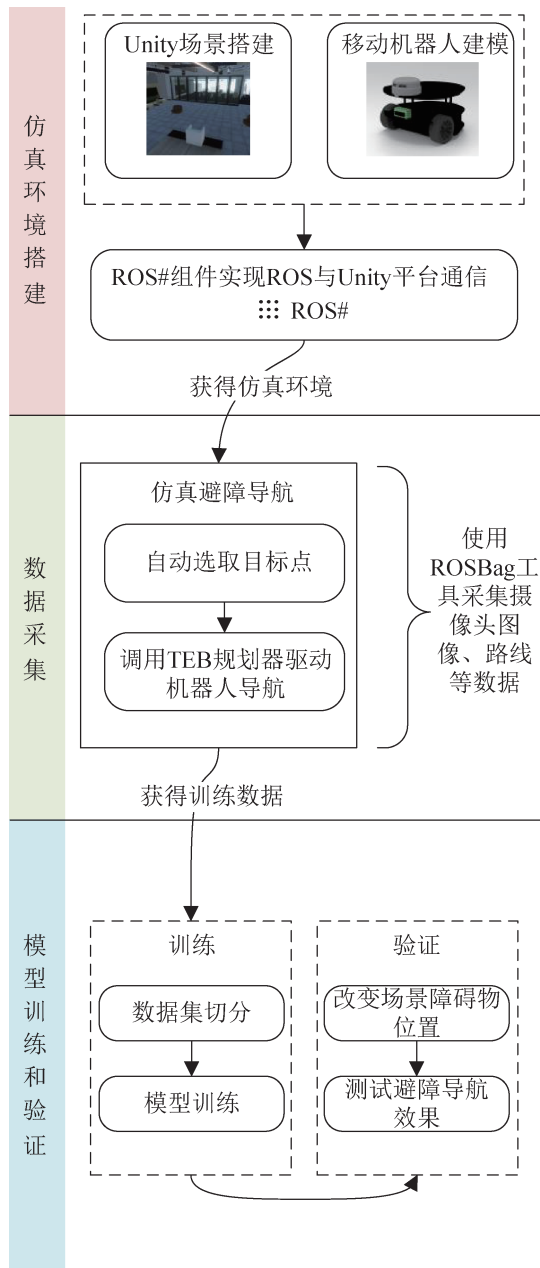


图3 模型实现和仿真技术路线图

Fig. 3 Technology roadmap for model implementation and simulation

2.1 仿真环境搭建

为了确保仿真环境中训练和验证得到的结论

与真实场景较为契合，本文提出的仿真训练方案基于Unity的HDRP渲染管线实现了对真实室内场景的模拟。在场景搭建方面，本文使用了Unity Asset Store中的官方HDRP示例工程Unity Japan Office。该场景包含102个模型以及1134个纹理资源，对典型的室内场景实现了较为精细的刻画。除此之外，该场景包含早、中、晚三种场景样本，可以在多种光线条件下进行模型训练，增强模型的泛化性能。

本文使用Blender等软件对真实的差速驱动机器人小车进行建模，使用URDF(unified robot description format)文件描述小车的摄像头、激光传感器节点相对底盘中心的位置，并将其导入ROS框架和Unity引擎中。与此同时，ROS#插件中的激光和摄像头传感器脚本与URDF中对应节点绑定，以实现仿真过程中的实时采样和与ROS框架的数据交互。为了获得更加理想的仿真效果，ROS的fake_localization软件包被用于将Unity环境中小车的坐标直接传输至ROS导航框架中，确保任意时刻导航框架获取的小车位姿都是精确的。

除了各个传感器的数据同步，仿真环境同样需要侦听发送至底盘的速度指令，并以此作为改变机器人当前坐标的数据来源，从而驱动虚拟机器人运动。为了实现上述需求，本方案采用了在ROS框架内编写软件包的方式用于里程计同步。该软件包从Unity引擎中获取机器人相对于地图原点的坐标，进而使用ROS的消息传递机制将该坐标信息传入导航框架中。在另一个方向上，Unity引擎中ROS#对应脚本侦听/cmd_vel传输的速度指令，根据指令中的线速度和角速度实时改变仿真环境中机器人的当前坐标，实现机器人的精确指令执行。

局部路径规划器的一个重要功能是规划出一条能够绕开地图中不存在的障碍物的路线。因此，本文在原有的办公室场景中随机摆放了桌椅等之前不存在于场景中的物品，实现了对上述动态障碍物的模拟。搭建的场景如图4所示。




图4 用于建图的空场景及增加障碍物之后的训练环境
Fig. 4 Empty scene for map building and training scene with obstacles added

2.2 仿真环境数据采集

借助上文描述的仿真环境, 本文使用自动选点方案在全局地图区域生成目标点, 进而使用传统TEB局部路径规划器驱动机器人在该区域内进行避障导航, 以此进行数据集的收集工作。该选点方案以ROS框架中的软件包实现。该软件包持续侦听导航框架的状态, 若此时机器人处于空闲状态, 则其将在事先指定的点集中选取起点和终点, 将机器人的坐标设置为起始点的位置, 并将最终选出的目标点通过MoveBaseClient发送至ROS导航框架。

在机器人导航的过程中, 该数据收集方案使用ROSBag工具实现坐标转换(TF)、虚拟摄像头图像数据、机器人位姿、全局路径和局部路径的记录。ROSBag是一组记录和回放ROS Topic信息的工具集合, 能够高效地记录ROS框架中的各个软件包在每个时间节点内发布的消息。该方案借助ROSPy库开发了bag文件的序列化脚本, 使这些图像和坐标数据能够在将来的模型训练流程中被直接使用。在该脚本中, 首先丢弃机器人未处于导航状态时收集的所有摄像头图像, 对于过滤后的每一张图像, 脚本获取与此图像时间戳相近时的全局路径信息和机器人位姿信息, 并由此计算得到其跟随全局路径的转向角。同时, 此刻由局部路径规划器规划的路径也将被同步记录。最终, 这些数据与对应的图像一起被打包作为数据集的样本, 用于后续的训练和验证工作。

2.3 模型训练和验证

在数据采集部分, 本文采集了大量机器人位于随机初始坐标向随机目标点导航的路线以及图像数据。其中每一次导航过程均可能包含上百张摄像头返回的图片。在实际的模型训练中, 循环神经网络具有数据依赖, 长序列将影响模型训练时的并行程度, 进而限制模型训练的效率。过长的图片序列也通常难以加载到GPU内存中。因此, 本文采用切分训练集的方式, 将每次导航过程采集的长序列切分为多个短序列, 以提升模型训练性能。对于采集的整个序列文件, 以每次导航结束作为分界点, 对整个数据集进行一次切分, 得到若干个独立导航过程的数据集合。在此基础上, 规定单个序列的最大长度, 对每个独立导航过程进行二次切分, 得到训练集。

训练过程中, 本文使用Adam优化算法, 采用HuberLoss作为损失函数以降低训练数据中噪声的影响。将batch size设置为32、初始学习率为0.0001, 在序列最大长度为10的情况下, 可以得到训练结果如图5所示。




图5 训练及测试集损失值变化曲线
Fig. 5 Loss value of the training set and test set

在对模型的避障效果进行测试之前, 本文调整原有场景中各类障碍物的位置, 从而更准确地衡量该模型在不同场景下的避障能力。调整后的场景如图6所示。在机器人执行指令过程中, 本文采集各个时刻机器人用于避障的RGB摄像头图像, 同时记录由纯追踪算法根据全局路径计算的

全局转向角(该数据为模型输入的一部分), 以及模型输出且最终发送至机器人底盘执行的转向角。图 7 展示了机器人在两次导航中的表现。

在图 7 中, 图像右下方蓝色指针指示跟随全局路径应该使用的转向角, 红色指针指示机器人通过模型推理实际使用的转向角。第一个序列记录了机器人从房间左下方导航到右上方指定的目标点时的过程。在机器人距离该障碍物尚有一段距离时, 局部路径规划器选择跟随全局路径的指引, 输出向右前方行驶的指令。随着机器人与障碍物的距离逐渐缩小, 规划器引导机器人向全局路径的右侧偏航以避免障碍物。当机器人越过椅子障碍物时, 前方出现阻挡其继续直线前行的桌

台。因此, 规划器引导机器人继续向右偏航绕行。在机器人的前方没有更多障碍时, 局部路径规划器重新跟随全局指引, 发出向左转向的指令以使机器人回到全局路径上。第二个序列同样展示了模型通过摄像头传回的图像信息, 在跟随全局路径的过程中避开路径中障碍物的场景。



图 6 调整障碍物摆放位置后的测试场景

Fig. 6 Test scene after adjusting placement of obstacles




图 7 仿真环境中避障及跟随全局路径能力测试

Fig. 7 Test of ability for obstacle avoidance and global path following in simulation

图 8 呈现了在几次避障导航过程中的全局转向角以及实际执行转向角数据。该数据表明, 模型在总体跟随全局路径的同时, 能够融合视觉信息判断前方障碍物对导航的影响, 通过适度的偏航操作使机器人始终与障碍物保持一定距离, 最终顺利完成导航任务。




图 8 避障导航过程中全局转向角与实际执行转向角

Fig. 8 Global steering angle and actual steering angle during obstacle avoidance and navigation

3 实验和算法验证

3.1 仿真环境验证

为了比较本文提出的基于深度学习的局部路径规划器与传统规划器的性能差异, 本文进一步设计了一种基于路径的性能评估方案。在局部路径规划任务中, 规划器应当在保证安全(即自始至终与障碍物保持一定安全距离)的情况下生成能够跟随全局路径, 且长度相对较短的局部路径。除此之外, 规划任务对路径的顺滑程度同样提出了一定的要求。更顺滑的路径能够减少机器人速度和角度的急剧变化, 从而提升其稳定性和行驶效率。综合以上考虑, 本文提出的局部路径规划器性能评估方案考察了 3 个重要的性能指标, 即路径长度、路径曲率变化率以及路径点与最近障碍

物之间的距离, 旨在客观评估不同规划器在相同输入条件下生成路径的效果。

该验证和评估流程同样在虚拟环境中进行, 以排除真实机器人打滑、激光定位不稳定等因素的干扰。本文在与训练时障碍物摆放情况不同的新场景下部署该方案。其中, TEB规划器的参数设置与收集训练数据时一致。机器人分别使用以TEB为代表的传统局部路径规划器和本文提出的规划器进行避障导航。设计的5条测试路线如图9所示。




图9 虚拟环境中设计的五条测试路线
Fig. 9 Five routes designed for test in simulation

每一次测试均是一次完整的避障导航过程。测试开始时, 将机器人的位置初始化为路线起始点, 并设定起始姿态。完成准备工作后, 将目标位姿传入导航框架, 以开始自主导航。在机器人向目标点行进的过程中, 评估程序作为ROS框架中的一个节点, 持续监控并记录行进路径以及激光传感器传回的周边障碍物情况。对于测试路线1、2、3、4, 两种局部路径规划器使机器人执行的最终导航路径如图10所示。

传统路径规划器以及本文提出的基于深度学习的规划器在测试中均实现了较优秀的避障导航效果。针对本文设计的几条测试路线, 路线1、2、3从起始点到终点的直线上均存在需要避开的障碍物。这些障碍物于全局地图构建之后被放置, 因此全局路径规划器无法获得这些障碍物的信息, 导致其规划出一条穿过障碍物的路径。两种局部路径规划器在导航过程中均能够感知障碍物的存在, 并采取相应的绕行策略向左或向右偏航避开障碍物。在此之后, 其驱动机器人回到预定的全局路径上, 最终到达目标位置。




图10 两种规划器在测试路线中执行的导航路径
Fig. 10 Navigation paths performed by two planners in test route

表1展示了评估程序记录的性能指标数据。其中, TEB一栏数据是指使用TEB局部路径规划器导航得到的结果, DL一栏数据指使用本文提出的基于深度学习的局部路径规划器导航得到的结果。在测试路线1、2、3中, 由于绕行障碍物策略(向左或向右绕行)的影响, DL规划器较TEB规划器产生的路径略长。而在另外两个测试路线中, DL规划器产生了相对更短的路径。对于路线1、3, DL规划器在绕行障碍物时调整转向角的幅度更大, 导致了更高的平均曲率变化率, 但该指标在其余三个路线中均未与TEB规划器产生过大差异。除此之外, DL规划器在路线3的整个导航过程中相较于TEB规划器与障碍物保持了更远的距离。因为绕行策略的不同, 在路线1、2上, 两个规划器离最近障碍物的距离指标同样有微小差异, 但均保持在安全范围内。对于路线4、5, 机器人在导航过程中不需要接近任何障碍物即可到达目标点, 故这两条路线的测试数据不包含最近障碍物指标。

表 1 两种规划器在测试中的指标数据
Table 1 Metric data for two planners in tests

指标	测试路线 1		测试路线 2		测试路线 3		测试路线 4		测试路线 5	
	TEB	DL	TEB	DL	TEB	DL	TEB	DL	TEB	DL
长度/m	7.35	7.91	5.77	6.23	6.71	7.25	4.52	4.29	2.86	2.54
平均曲率变化率	0.29	0.41	0.37	0.40	0.18	0.37	0.26	0.26	0.33	0.39
最近障碍物/m	0.44	0.36	0.42	0.30	0.42	0.90	n/a	n/a	n/a	n/a

注: n/a 为无数据。

仿真环境测试结果表明, 本文提出的基于深度学习的局部路径规划器能够安全、准确地完成避障导航任务, 拥有较优秀的路径规划能力, 能够自主感知环境障碍物, 驱动机器人绕行规避并回到全局路径上, 最终抵达目标点。

3.2 真实场景测试

为了评估本文提出的局部路径规划方案在实际场景中的避障能力, 将该方案部署到了如图 11 所示的真实移动机器人小车上进行测试。该机器人小车采用 Jetson TX2 NX 平台, 搭载的 NVIDIA Pascal 架构 GPU 具有 1.3TFLOPS 运算能力, 能够处理较复杂的神经网络推理任务。除此之外, 该平台集成了双核 NVIDIA Denver 2 以及四核 ARM Cortex-A57 处理器, 拥有 4GB LPDDR4 内存。同时, 机器人小车搭载了 1 080 P 广角摄像头以及镭神 LS01B 激光雷达, 满足本文提出的方案中对于图像感知和全局激光定位的要求。




图 11 模型部署采用的机器人小车

Fig. 11 Robot used for deploying proposed model

在执行测试之前, 先使用 Gmapping 软件包对

实验场地进行建图。得到全局地图之后, 在场景中摆放障碍物, 使用 TEB 导航方案控制机器人在场地中执行避障导航动作。在这个过程中, 记录机器人各个时刻跟随全局路径所需转向角、实际执行的转向角以及摄像头传回的图像。这些信息之后被用于本文提出的避障导航网络的训练。得到网络模型后, 更改场景中障碍物的摆放位置和方式, 指定导航路线, 测试机器人的导航性能。图 12 展示了测试场景的图片以及于对应场景中进行避障导航的测试结果。

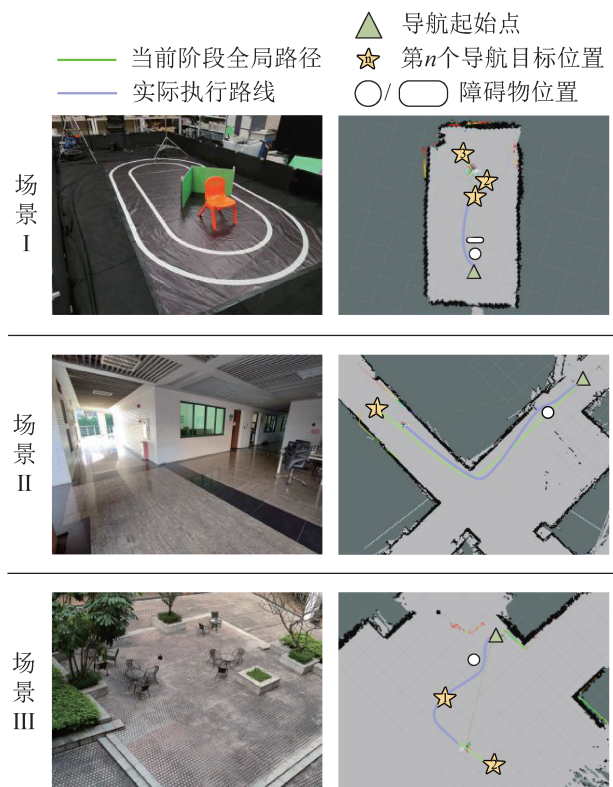


图 12 机器人在真实场景中的避障导航过程

Fig. 12 Obstacle avoidance and navigation process of robot in real scene

该导航方案于三个真实场景中进行了测试, 分别为室内测试场地场景、建筑物走廊场景, 以及室外场景。在每次测试中, 将机器人放置于导航起始点, 依次指定导航目标, 命令机器人执行自主避障导航。在场景 I 中, 机器人完成了 3 个连续的导航任务。在向第 1 个目标点行进时, 其能够准确避开障碍物, 并在超越障碍物后返回全局路径。随后, 机器人跟随全局路径完成了向第 2 和第 3 个目标点的导航任务。对于场景 II, 机器人首先绕过障碍物, 之后跟随全局路径向右转弯到达目标点。在位于户外的场景 III 中, 机器人同样顺利完成指定的 2 个导航任务。该实验说明, 本文提出的局部路径规划方案在真实场景中能够准确、安全地驱动机器人从其所在位置移动至目标点, 具有良好的避障和导航效果。

4 结论

本文提出的基于深度学习的机器人局部路径规划方案在虚拟环境和真实场景中均展现了较好的避障导航效果。该方案以摄像头的 RGB 图像数据作为主要输入, 实现了视觉信息和感知信息的融合, 提升了对于障碍物的检测能力。同时, 该方案使用 Unity 3D 引擎对典型的室内环境和动态障碍物进行模拟, 简化了模型训练和验证的流程。除此之外, 本文实现了数据收集、模型训练、效果验证及比较等一系列 ROS 框架下的相关工具, 使该方案可以简单地迁移至不同的模型、仿真环境、导航平台中, 适应不同使用场景的需要。

与传统规划器相比, 该方案同样存在一些不足之处。在与训练集差异较大的光照条件下, 该方案对障碍物的识别率将有一定程度的下降。此外, 其对于规避移动障碍物的灵活性也比较一般。因此, 未来计划在全局地图、点云信息与图像信息的融合方向上进行更深入的研究, 进一步优化机器人的避障导航效果。

参考文献:

[1] Armin Hornung, Phillips M, Gil Jones E, et al.

Navigation in Three-dimensional Cluttered Environments for Mobile Manipulation[C]//2012 IEEE International Conference on Robotics and Automation. Piscataway, NJ, USA: IEEE, 2012: 423-429.

[2] 晋晓飞, 王浩, 宗卫佳, 等. 自主移动机器人避障技术研究现状[J]. 传感器与微系统, 2018, 37(5): 5-9.

Jin Xiaofei, Wang Hao, Zong Weijia, et al. Research Status of Obstacle Avoidance Technologies for Autonomous Mobile Robots[J]. Transducer and Microsystem Technologies, 2018, 37(5): 5-9.

[3] Lee H Y, Ho H W, Zhou Y. Deep Learning-based Monocular Obstacle Avoidance for Unmanned Aerial Vehicle Navigation in Tree Plantations[J]. Journal of Intelligent & Robotic Systems, 2021, 101(1): 5.

[4] Sina Sharif Mansouri, Petros Karvelis, Christoforos Kanellakis, et al. Vision-based MAV Navigation in Underground Mine Using Convolutional Neural Network [C]//IECON 2019-45th Annual Conference of the IEEE Industrial Electronics Society. Piscataway, NJ, USA: IEEE, 2019: 750-755.

[5] Travis Manderson, Juan Camilo Gamboa Higuera, Cheng Ran, et al. Vision-based Autonomous Underwater Swimming in Dense Coral for Combined Collision Avoidance and Target Selection[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ, USA: IEEE, 2018: 1885-1891.

[6] Antonio Loquercio, Ana I Maqueda, Carlos R del-Blanco, et al. DroNet: Learning to Fly by Driving[J]. IEEE Robotics and Automation Letters, 2018, 3(2): 1088-1095.

[7] Tai Lei, Li Shaohua, Liu Ming. A Deep-network Solution Towards Model-less Obstacle Avoidance[C]//2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ, USA: IEEE, 2016: 2759-2764.

[8] Liu Canglong, Zheng Bin, Wang Chunyang, et al. CNN-based Vision Model for Obstacle Avoidance of Mobile Robot[C]//2017 3rd International Conference on Mechanical, Electronic and Information Technology Engineering. France: EDP Sciences, 2017: 7.

[9] 金彦亮, 朱容廷. 机器人端到端视觉避障方法研究[J]. 工业控制计算机, 2019, 32(9): 77-79.

Jin Yanliang, Zhu Rongting. Research on Robot End-to-end Visual Obstacle Avoidance Method[J]. Industrial Control Computer, 2019, 32(9): 77-79.

[10] Michels J, Saxena A, Ng A Y. High Speed Obstacle Avoidance Using Monocular Vision and Reinforcement Learning[C]//Proceedings of the 22nd International conference on Machine learning. New York, NY, USA:

<http://www.china-simulation.com>

• 1209 •

- Association for Computing Machinery, 2005: 593-600.
- [11] Xie L, Wang S, Markham A, et al. Towards Monocular Vision Based Obstacle Avoidance Through Deep Reinforcement Learning[C]//Robotics: Science and Systems (RSS 2017) Workshop. Boston, MA, USA: MIT, 2017: 1-6.
- [12] Ronja Guldenring, Michael Görner, Norman Hendrich, et al. Learning Local Planners for Human-aware Navigation in Indoor Environments[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ, USA: IEEE, 2020: 6053-6060.
- [13] R Craig Coulter. Implementation of the Pure Pursuit Path Tracking Algorithm: CMU-RI-TR-92-01[R]. Pittsburgh, PA, USA: Carnegie Mellon University, 1992: 1-15.
- [14] Zhang Chao, Yang Zichao, He Xiaodong, et al. Multimodal Intelligence: Representation Learning, Information Fusion, and Applications[J]. IEEE Journal of Selected Topics in Signal Processing, 2020, 14(3): 478-493.
- [15] Sepp Hochreiter, Jürgen Schmidhuber. Long Short-term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [16] Koenig N, Howard A. Design and Use Paradigms for Gazebo, an Open-source Multi-robot Simulator[C]//2004 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ, USA: IEEE, 2004: 2149-2154.
- [17] Liu Yuzhou, Georg Novotny, Nikita Smirnov, et al. Mobile Delivery Robots: Mixed Reality-based Simulation Relying on ROS and Unity 3D[C]//2020 IEEE Intelligent Vehicles Symposium (IV). Piscataway, NJ, USA: IEEE, 2020: 15-20.
- [18] Pushkal Katara, Mukul Khanna, Harshit Nagar, et al. Open Source Simulator for Unmanned Underwater Vehicles Using ROS and Unity3D[C]//2019 IEEE Underwater Technology (UT). Piscataway, NJ, USA: IEEE, 2019: 1-7.
- [19] Konrad A. Simulation of Mobile Robots with Unity and Ros: A Case-study and a Comparison with Gazebo[D]. Trollhättan, Sweden: University West, 2019.