



融合长短时记忆机制的机械臂多场景快速运动规划

张云洲, 孙永生, 夏崇坤, 丁其川, 王晓哲

引用本文:

张云洲, 孙永生, 夏崇坤, 等. 融合长短时记忆机制的机械臂多场景快速运动规划[J]. 控制与决策, 2020, 35(12): 2968–2976.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.1387>

您可能感兴趣的其他文章

Articles you may be interested in

凸优化与A*算法结合的路径避障算法

Convex optimization and A-star algorithm combined path planning and obstacle avoidance algorithm

控制与决策. 2020, 35(12): 2907–2914 <https://doi.org/10.13195/j.kzyjc.2019.0351>

FMM与改进GBNN模型相结合的多AUV实时围捕算法

Multi-AUV real-time hunting control based on FMM and improved GBNN model

控制与决策. 2020, 35(12): 2845–2854 <https://doi.org/10.13195/j.kzyjc.2019.0393>

基于改进萤火虫算法的区域交通信号配时优化

Timing optimization of regional traffic signals based on improved firefly algorithm

控制与决策. 2020, 35(12): 2829–2834 <https://doi.org/10.13195/j.kzyjc.2019.1835>

一种高匹配性的多层代价地图生成算法

A high matching layered costmap generation algorithm

控制与决策. 2020, 35(12): 2883–2888 <https://doi.org/10.13195/j.kzyjc.2018.0721>

微型无人机集群低时延组网规划方法

A low delay networking planning method for micro UAV swarm

控制与决策. 2020, 35(11): 2696–2706 <https://doi.org/10.13195/j.kzyjc.2018.1549>

融合长短时记忆机制的机械臂多场景快速运动规划

张云洲^{1,2†}, 孙永生¹, 夏崇坤¹, 丁其川², 王晓哲¹

(1. 东北大学 信息科学与工程学院, 沈阳 110004; 2. 东北大学 机器人科学与工程学院, 沈阳 110169)

摘 要: 针对快速扩展随机树 (rapid-exploration random trees, RRT) 算法难以有效解决多场景环境下的机械臂快速运动规划问题, 提出一种融合长短时记忆机制的快速运动规划算法. 首先, 采用高斯混合模型 (Gaussian mixture models, GMM) 在规划的初始阶段通过随机采样构建环境的场景模型, 并利用该模型进行碰撞检测, 以提高运动规划效率; 然后, 根据人类的记忆机制原理, 对多场景的不同 GMM 按照即时记忆、短期记忆和长期记忆进行存储, 并通过场景匹配算法实现不同场景 GMM 的快速自适应提取, 提高对变化环境的适应能力; 最后, 通过在 Matlab 以及 ROS 仿真环境下 6 自由度柔性机械臂的运动规划仿真实验对所提出的算法进行验证. 实验结果表明, 所提出算法可以快速提取场景的记忆信息, 有效提高多场景环境下的运动规划效率, 具有较强的适应性.

关键词: 多自由度机械臂; 运动规划; GMM; 碰撞检测; 场景匹配; 记忆机制

中图分类号: TP241

文献标志码: A

DOI: 10.13195/j.kzyjc.2018.1387

引用格式: 张云洲, 孙永生, 夏崇坤, 等. 融合长短时记忆机制的机械臂多场景快速运动规划 [J]. 控制与决策, 2020, 35 (12): 2968-2976.

Multi-scene rapid motion planning combining with long and short time memory mechanisms for manipulators

ZHANG Yun-zhou^{1,2†}, SUN Yong-sheng¹, XIA Chong-kun¹, DING Qi-chuan², WANG Xiao-zhe¹

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 2. Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110169, China)

Abstract: Aiming at the problem of that the rapid-exploration random trees (RRT) algorithm is difficult to solve the rapid motion planning of a manipulator in the multi-scene environment, a fast motion planning algorithm combining long and short time memory mechanism is proposed. Firstly, the paper uses the Gaussian mixture model (GMM) to build a scene model of the environment through random sampling in the initial stage of planning, and uses this model for collision detection to improve the efficiency of motion planning. Then, according to the principle of human memory mechanism, different GMMs for multiple scenes are stored according to real-time memory, short-term memory and long-term memory, and the scene matching algorithm is used to achieve fast adaptive extraction of different scene GMM to improve the adaptability to changing environments. Finally, the proposed algorithm is validated by the grab simulation experiment of the 6-DOF flexible manipulator in Matlab and ROS simulation environment. Experimental results show that the algorithm can quickly extract the memory information of the scene, effectively improve the efficiency of motion planning in multi-scene environment, and has strong adaptability.

Keywords: multi-freedom manipulators; motion planning; GMM; collision detection; scene matching; memory mechanism

0 引 言

多自由度串联机械臂的运动规划是机器人操控领域的重要研究方向之一. 机械臂的运动规划是指机械臂在有障碍的环境中, 能够通过一种寻径算法找到一条从起始点到目标点的无碰撞路径^[1]. 当前

的运动规划算法有基于图搜索的方法 (如 A*、D* 和 Dijkstra 等启发式算法)、基于人工势场的运动规划算法等, 通常需要对环境进行严格的数学建模. 随着机械臂自由度的增加, 容易导致计算量呈指数增长, 甚至导致算法失效, 无法规划出合理的路径.

收稿日期: 2018-10-12; 修回日期: 2019-02-14.

基金项目: 国家重点研发计划项目 (2017YFC0805005, 2017YFB1301103); 教育部高校基本科研业务费专项基金项目 (N172608005); 国家自然科学基金项目 (61733003).

责任编委: 方勇纯.

[†]通讯作者. E-mail: zhangyunzhou@ise.neu.edu.cn.

为了解决高维空间中的运动规划问题,Lavalle^[2]提出了RRT算法,在机械臂的关节空间通过扩展随机树的方式生成路径.作为一种基于随机采样的搜索方法,RRT算法能够快速地完成在高维空间中的搜索,同时在采样过程中不依赖于精确的环境模型.与其他规划算法相比,RRT算法更适合于解决高维空间中路径搜索问题,因此在机械臂运动规划领域得到了广泛应用^[3-6].RRT算法的本质是使用随机的数据结构寻找一条可行路径,但通常找到的不是最优路径.为此,Adiyatov等^[7]提出了一种改进的RRT算法,将障碍物信息纳入采样步骤,用于寻找最优路径.该算法将环境中的障碍分为有价值障碍和无价值障碍,起点与目标点之间的障碍被认为是有价值的,然后使用部分可观测马尔科夫模型引导RRT算法在有价值障碍物边界采样,有效降低了规划器在具有规则形状的障碍物环境中的运动规划时间.

RRT算法可以解决高维空间机器人的运动规划问题,但是当机器人需要穿越狭窄通道才能到达目标点时,往往需要更稠密的采样才能找到一条路径.为了提高搜索效率,钟建冬等^[8]提出了一种三树RRT算法,通过星形实验法标识出操作空间中的狭窄通道,并从起点、目标点和狭窄通道中的随机点分别扩展出3棵RRT树,再利用RRT-connect算法进行启发式扩展,通过全局采样与局部采样相结合的方式改变不同区域的采样密度,从而加快了RRT算法的规划速度.杨一波等^[9]提出了基于人工势场引导的快速随机扩展树改进算法,用于解决RRT算法扩展缺乏指向性、收敛效率低等问题,在采样起始阶段,根据规划场景建立人工势场,使用势场强度启发采样过程,进而引导节点向目标点扩展,同时针对人工势场的局部极小值问题,采样改进的转换测试方法对采样节点进行筛选,自适应调节树的前进坡度,使得树尽量向低势场强度区域扩展的同时避免陷入局部震荡.Karaman等^[10]提出渐近最优的RRT*算法,改变了父节点的选择方式,在添加新的扩展节点后,通过计算代价函数选择扩展节点邻域内最小代价的节点作为该节点的父节点,另一方面,每次迭代过程都会重新选择扩展节点邻域内所有节点的父节点,保证最后求得的路径是渐近最优路径.

碰撞检测和最近邻搜索过程是RRT算法主要的性能瓶颈^[11].在机器人运动规划过程中,RRT算法需要进行多次随机采样,每一次采样都要进行碰撞检测,为此消耗的时间占据算法运行总时间的90%以上.随着工作场景复杂度增加、采样点增多,RRT算

法的效率将持续降低.为了减少在采样过程中碰撞检测所需的时间,Yoon等^[12]提出了一种延迟碰撞检测算法,在采样过程中不进行碰撞检测,直到生成完整路径时再进行碰撞检测,从而能够花费更短的时间生成一条无碰撞的路径.然而,一旦在规划过程中检测到机器人与环境发生碰撞,该方法则需要重新规划路径,在复杂场景中算法效率反而会降低.Arslan等^[13]提出了一种基于障碍物信息的优化算法,将临近障碍物信息纳入节点并使用这些信息避免将一些节点添加到扩展树中,不仅减少了很多无效的采样点,而且减少了相关的碰撞检测和最近邻搜索等耗时操作.

近年来,基于机器学习的方法也被应用于RRT算法以提高算法的效率.Pan等^[14]提出了基于概率的碰撞检测算法,引入支持向量机(SVM)算法应对环境中的不确定性.Georges等^[15]提出的RR-GP算法也是一种基于学习的运动规划模型,在RRT算法中引入高斯过程,通过预测障碍物轨迹动态地规划路径,能够在动态约束环境中找到一条安全无碰撞的路径.Huh等^[16]提出了一种基于高斯混合模型(GMM,Gauss mixture models)的高维构型空间碰撞检测算法,应用到RRT*算法中,使用增量期望最大化算法(EM)学习基于环境的高斯混合模型,用于代替传统方法进行碰撞检测,有效地减少了碰撞检测的次数,提高了RRT*算法的效率.然而,由于高斯混合模型是针对具体的环境训练获得^[17]的,当环境发生变化时需要对新环境重新开始训练,即使遇到重复场景也需要重新训练,时间成本较高.

本文针对基于GMM模型的RRT*算法仅适用于单一固定场景的局限性,引入记忆机制,提出了一种融合长短时记忆机制的快速运动规划算法以解决多场景下的快速运动规划问题.通过模拟人类的记忆机制,在建立高斯混合模型的过程中将当前场景及对应的GMM模型通过感觉记忆、短期记忆和长期记忆3个阶段存储到记忆空间,使机器人能够记住出现过的环境,当机器人遇到类似环境时能够根据记忆适应当前场景,快速完成运动规划.最后,通过Matlab和ROS环境下的仿真实验验证了算法在多场景环境下的有效性.

1 长短时记忆机制

人类的认知包括感知、学习、记忆和决策4个部分.通过感知系统接收外界环境刺激信号,将该信号传输至神经中枢,由中央处理系统对该信号作出相应的反应.人类能在一定的时间内记住所遇到的环境,

这些环境信息则是作出相应决策的依据. 根据现代认知学理论, 记忆机制可以分为感觉记忆、短期记忆和长期记忆3个阶段, 也称为长短时记忆机制^[18].

感觉记忆又称为瞬时记忆, 在人类认知过程中的作用相当于滤波器, 将通过感知系统获得的外部环境信息进行过滤和选择, 存储有用的信息. 短时记忆由感知系统获得的瞬时记忆进一步处理获得的新信息、存储在短时记忆中的短期信息和从长时记忆中提取的记忆3部分组成, 人类大脑主要根据短时记忆作出决策^[19]. 其优势在于只存储少量的信息, 可以根据当前的一种或多种环境作出快速决策. 长时记忆是一个庞大而复杂的信息数据库, 存储着主体过去学习的经验和知识, 其优点是存储海量信息, 使记忆主体可以适应各种各样复杂的环境.

融合长短时记忆机制可以根据已有信息作出快速决策, 避免重新学习的过程. 本文将记忆机制应用于基于高斯混合模型的碰撞检测过程, 解决在多场景中机械臂的运动规划问题.

2 融合长短时记忆机制的MGMM-RRT*算法

2.1 基于GMM的RRT*算法

GMM-RRT*算法是一种结合了高斯混合模型的RRT*算法, 它以模型检测的方式代替传统的FCL碰撞检测算法. 算法基本流程如下: 首先, 通过传统RRT*算法获取机械臂 n 维关节空间的碰撞区域和非碰撞区域样本, 通过增量期望最大值聚类(EM)算法学习如下所示的高斯混合模型的参数:

$$p(x) = \sum_{k=1}^K \pi_k N(u(x) | \mu_k, S_k) = \sum_k \pi_k \frac{1}{(2\pi)^{\frac{n}{2}} |S_k|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(u(x) - \mu_k)^T S_k^{-1} (u(x) - \mu_k)\right). \quad (1)$$

其中 (μ_k, S_k, π_k) 为GMM模型中第 k 个组元的均值、协方差矩阵和权重. 其次, 在RRT算法执行过程中, 当产生新的采样点时, 通过下式计算采样点与高斯混合模型各个组元之间的Mahalanobis距离以判断采样点是否与周围环境中的障碍物发生碰撞:

$$D_M(u(x)) = \sqrt{(u(x) - \mu_i)^T S_i^{-1} (u(x) - \mu_i)}. \quad (2)$$

最后, 由于基于概率的方法具有不确定性, 对规划后的路径进行完整碰撞检测, 并根据检测结果更新高斯混合模型. 相应的伪代码如下所示.

算法1 GMM-RRT*算法.

require: $X_{\text{col}}, X_{\text{free}}$ exemplars

$G_{\text{col}}, G_{\text{free}} = \text{BUILD_GMM}(X_{\text{col}}; X_{\text{free}})$

T.init(q_{init})

while Distance($q_{\text{goal}}, q_{\text{new}}$) < d_{min} do

$q_{\text{rand}} = \text{StateSampling}(G_{\text{col-free}})$

$q_{\text{near}} = \text{NodeSelection}(T, q_{\text{rand}})$

$q_{\text{new}} = \text{NodeExpansion}(T, q_{\text{rand}}, q_{\text{near}})$

$d_{\text{col}}, d_{\text{free}} = \text{MahalanobisDist}(q_{\text{new}}, G_{\text{col}},$

$G_{\text{free}})$

if $(d_{\text{col}} - d_{\text{free}}) < \delta_{\text{col}}$ then

q_{new} is collision

else if $(d_{\text{col}} - d_{\text{free}}) > \delta_{\text{col}}$ then

q_{new} is collision-free

else

KinematicCollisionCheck(q_{new})

end if

if q_{new} is collision-free then

T.addTree(q_{new})

end if

end while

$X_{\text{pathset}} = \text{GetPathFromTree}(T)$

CollisionFreeCheck(X_{pathset})

$G_{\text{col}}, G_{\text{free}} = \text{UPDATE_GMM}(G_{\text{col}}, G_{\text{free}}, X_{\text{new}})$

算法1中: X_{col} 、 X_{free} 为规划过程中采集的样本, G_{col} 、 G_{free} 为使用样本训练得到的高斯混合模型, T 为随机扩展树, q_{rand} 、 q_{near} 、 q_{new} 分别为随机采样点、最近邻点和新扩展点, d_{col} 、 d_{free} 分别为新扩展点到碰撞区域和非碰撞区域的距离, X_{pathset} 为生成的路径.

2.2 改进GMM-RRT*算法

GMM-RRT*算法的优势是针对固定的场景, 可以使用GMM模型替代FCL方法进行碰撞检测, 然而训练得到的高斯混合模型仅能适应当前环境, 一旦环境发生了变化则需要重新训练, 这样会降低算法的效率. 若机器人能够记忆遇到的环境及对应的GMM模型, 则当其遇到类似环境时只需要从记忆中提取与环境相匹配的模型, 不需要重新训练便能适应新的环境, 算法效率将得到提升. 为了能够存储和调用基于场景的高斯混合模型, 本文引入长短时记忆机制, 通过模拟人类的记忆机制对模型进行记忆、匹配和提取, 在存储模型的同时使用词袋模型算法构建词典, 用于场景图像检索与匹配. 将存储场景及对应模型的空间分为3部分, 即: 感觉记忆空间、短时记忆空间和长时记忆空间^[18].

感觉记忆空间(USTMS)存储机器人对于当前环

境的感知信息,包括在仿真环境中障碍物的大小位置或者通过视觉传感器获取的图像和点云信息等。

将存储在USTMS中的感知信息经过训练得到的高斯混合模型存储在短时记忆空间(STMS)中,用STMS模拟人类的短时记忆.对于高斯混合模型,STMS中存储环境信息及对应GMM的 K 个组元的集合.如果用 E_j 表示第 j 个环境信息, N_{ji} 表示记忆空间中用于描述环境 E_j 对应的GMM第 i 个组元, M 表示STMS空间存储的最大容量,则STMS可以表示为

STMS =

$$\{T_j = (E_j, N_{ji}, i = 1, 2, \dots, K) | j = 1, 2, \dots, M\}. \quad (3)$$

短时记忆空间中的模型是RRT*算法作出决策与规划的主要依据.短时记忆空间中的模型不仅包括由感觉记忆空间中的场景学习得到的新的高斯混合模型,还包括短时记忆空间中已有且被更新的模型和从长时记忆空间中调用的模型.短时记忆空间中模型设置参数 β 作为模型可记忆性的衡量,在记忆过程中通过 β 的大小确定该模型是否需要被记忆.参数 β 与模型的质量有关,在一般情况下,RRT*算法迭代次数越多,训练得到的模型越精确,碰撞检测出错的几率越低,模型被存储的可能性也越大.具体地,对于 $\forall T_j \in \text{STMS}, j = 1, 2, \dots, M$,设置初始 $\beta_j = 0, \beta_j = 0$ 的更新公式为

$$\beta_j = s_t / t_t \times 100. \quad (4)$$

s_t 和 t_t 分别为算法在当前场景中规划成功的次数和规划的总次数.若 β_j 大于阈值 β_t ,则模型 T_j 即为可记忆模型.根据经验,阈值 $\beta_t = 85\%$ 时可以取得较好的实验效果.长时记忆空间(LTMS)存储机器人在过去时间中遇到的所有的可记忆模型及对应的环境信息,并通过一些策略维护和更新记忆.LTMS空间集合表示为

LTMS =

$$\{T_j = (E_j, N_{ji}, i = 1, 2, \dots) | j = 1, 2, \dots, Q\}, \quad (5)$$

其中 Q 为LTMS空间的最大容量.

图1为场景模型的存储和提取过程.感觉记忆空间中存储环境信息,使用算法1训练得到的高斯混合模型存储于短时记忆空间,当使用模型规划路径用时短且成功率较高时,将模型存储于长时记忆空间.在遇到相似环境时提取记忆中的匹配模型,通过短暂的学习阶段快速地适应环境,提高算法在不同环境中的适应能力.




图1 三段式记忆存储机制


引入长短时记忆机制后,融合记忆机制高斯混合模型的RRT*(memory GMM-RRT*, MGMM-RRT*)算法主要步骤如下.

step 1: 在机器人初始化过程中,通过RGB-D相机获取当前环境信息,建立基于机器人坐标系的环境描述 E ,包含彩色图、深度图和点云.如果使用 rgb 表示彩色图, $depth$ 表示深度图, pcl 表示点云数据,则 E 定义为


$$E = \{rgb, depth, pcl\}. \quad (6)$$

step 2: 在场景匹配步骤中,将环境信息 E 依次与短时记忆空间和长时记忆空间中的场景进行匹配并计算相似度.首先使用词袋法在记忆空间中搜索匹配场景;然后对当前场景与匹配场景进行ICP配准,计算两个场景之间的位姿变换;最后将位姿变换与预先设定好的阈值 T 进行比较,若变换大于阈值,则认为不匹配,否则认为是匹配场景.


step 3: 提取长时记忆空间到短时记忆空间的过程如图2(a)所示,先从长时记忆空间中提取匹配模型



(a) 模型存储和提取示意图



(b) 模型提取和遗忘示意图



(c) 模型竞争存储示意图

图2 模型存储、提取和遗忘的示意图

T_i 到短时记忆空间,然后将短时记忆空间中最后一个环境模型 T_K 存储到长时记忆空间中. 图中灰色圆点表示可记忆,五角星表示记忆权重,五角星不同的灰度表示权重的大小,颜色越淡代表记忆权重越小.

step 4: 如果短时和长时记忆空间中都不存在与环境相匹配的模型,则表明机器人在过去的时间里没有遇到类似的场景,需要通过 GMM-Based 算法对新环境进行学习训练,得到新环境的模型 T_i ,同时使用新环境训练并更新 BOW 词典.

step 5: 当模型 T_K 是不可记忆模型时,提取匹配模型 T_i 的同时直接遗忘 T_K ,如图 2(b)所示.

step 6: 模型 T_K 存储到长时记忆空间中的流程如图 2(c)所示. 从短时记忆空间中提取出模型 T_K ,如果长时记忆空间未滿,则将 T_K 直接存储至模型队列. 如果空间已滿,则使用竞争机制,通过比较模型 T_K 与长时记忆空间中模型的记忆权重决定是否存储 T_K . 设 T_j 表示长时记忆空间中权重最小的模型, $\alpha_{j\min}$ 表示 T_j 的权重, α_K 表示模型 T_K 的权重. 如果 $\alpha_K > \alpha_{j\min}$,则保留模型 T_K ,遗忘模型 T_j ,否则直接遗忘模型 T_K .

3 实验结果及讨论分析

为了验证算法的有效性,本文分别在 Matlab 和 ROS 环境下针对机械臂运动规划开展研究. 为了比较算法在不同障碍物场景中的性能,分别按照障碍物形状、障碍物数量的多少在 Matlab 环境中设置 40 组不同的实验场景,进行平面机械臂的运动规划实验. 图 3 为 4 种典型的场景. 在每组实验场景中,黑色圆或方块代表障碍物,灰色小圆代表目标物体. 将本文 MGMM-RRT* 算法应用到所有 Matlab 实验场景中进行运动规划,并分别与 RRT* 算法和 GMM-RRT* 算法的规划结果进行比较. 最后,在 ROS 环境中进行 Kinova 六自由度机械臂仿真实验,进一步评估算法的性能.

3.1 MGMM 参数

对于长短时记忆机制,可记忆权重 β_t 是非常重要的参数. 本文通过实验分析的方法确定最佳的权重,在实验过程中分别设置不同的权重,并对比在不同权重下的场景模型的可存储数量和算法平均运行时间. 可存储数量是指在当前记忆权重阈值 β_t 的情况下,短时记忆空间中可以被存储到长时记忆空间中的数量. 平均运行时间指算法在每种场景下规划时间的平均值. Matlab 环境下的实验结果如表 1 和图 4 所示.




图 3 Matlab 实验场景设置

表 1 可记忆权重阈值 β_t

$\beta_t / \%$	1
100	1
95	2
90	10
85	30
80	40
75	40
70	40




图4 可记忆权重阈值 β_t

通过对比可以发现,随着阈值 β_t 的减少,场景模型的可存储数量变多,算法运行时间所需收敛次数也

变多. 当 β_t 小于85%时,收敛次数发生较大变化,因此选择85%作为权重阈值 β_t .

3.2 Matlab仿真实验

本文将MGMM-RRT*算法分别与RRT*和GMM-RRT*算法进行对比. 图5为4种场景下使用MGMM-RRT*运动规划算法得到的结果. 可以看出,在每个场景中算法都能规划出正确的路径,使机械臂绕过障碍到达目标点. 在同样的场景下分别使用RRT*和GMM-RRT*进行运动规划,并对规划结果进行统计.




图5 运动规划实验结果

由于RRT类算法具有随机性,本文在每种场景下进行1000次重复实验,并给出平均结果. 表2统计了本文算法与其他两种算法在40种实验场景下的平均数据对比,图6为其中4种场景的实验数据. 由图6(a)和图6(c)可见,本文算法比其他两个算法运行时间短、所需的迭代次数少. 图7为MGMM-RRT*与GMM-RRT*的实验对比结果. 由表2和图6、图7可见,MGMM-RRT*的优势在于当遇到类似场景时不需要训练模型,可以通过提取记忆中的模型快速地适应环境,减少了算法的运行时间,提高了算法的成功


率,增强了算法的适应能力.

表2 40组实验场景数据对比


	RRT*	GMM-RRT*	MGMM-RRT*
平均运行时间/s	98.5	63.7	44.5
算法迭代次数	6355	4571	2834
规划成功率/%	67	75	81

3.3 ROS仿真实验


本文在ROS环境下,以Kinova机械臂为研究对象进行三维仿真实验. 针对现有算法在狭窄通道中



(a) 平均算法运行时间



(b) 平均算法迭代次数




(c) 平均路径长度


图6 实验结果对比

路路径规划成功率较低的情况,设计100组不同的实验场景,部分场景如图8(a)~图8(h)所示,图8(i)~图8(p)则分别展示了本文算法在每种场景下的运动规划结果。


由于在三维环境下运动规划的复杂程度更高,基于随机采样的运动规划算法有一定的失败几率,算法规划成功率更有参考意义.本文对比了RRT*、GMM-RRT*和MGMM-RRT*在4种实验场景下的平均规划时间和规划成功率.在匹配过程中,先通过RGB图像进行词典匹配,再利用点云对匹配场景进行ICP配准计算3D位姿变换.其中,耗时较长的ICP配准过程仅需执行一次.实验数据表明,100组场景所需匹配时间小于100ms.表3为3种算法在各个场景下的规划成功率. RRT*、GMM-RTT*和MGMM-RRT*这3种算法的平均运行时间分别是23.3s、16.7s和9.8s,相应的规划成功率依次为74.7%、75.3%和87%.可以看出,由于本文算法使用GMM模型并加入了记忆机制,相比RRT*和GMM-RRT*算法,规划成功率提高了16%,规划时间减少了41%.




(a) 场景1



(b) 场景2



(c) 场景3



(d) 场景4

图7 算法运行时间对比

表3 40组实验场景数据对比 单位: %

	RRT*	GMM-RRT*	MGMM-RRT*
场景1	71	75	86
场景2	74	75	87
场景3	72	80	93
场景4	60	66	75
场景5	67	76	89
场景6	71	75	86
场景7	65	73	91
场景8	50	64	72




图8 ROS环境仿真实验

4 结 论

本文在高斯混合模型中引入记忆机制,提出一种基于记忆高斯混合模型的RRT*算法(MGMM-RRT*). 算法在运动规划过程中基于环境训练高斯混合模型,使用模型引导机械臂在关节空间采样并代替传统的FCL方法进行碰撞检测,与RRT*算法相比,有效提高了算法的规划成功率,减少了算法的运行时间. 机器人能够通过记忆机制记住所遇到的场景及其对应的模型,并在遇到相似场景时通过提取对应的场景模型快速地适应环境,不需要重新训练学习,提高了规划算法的适应能力.

参考文献(References)

- [1] 任秉银, 魏坤, 吴卓琦. 机械臂视觉伺服运动规划研究进展[J]. 哈尔滨工业大学学报, 2018, 50(1): 1-10.
(Ren B Y, Wei K, Wu Z Q. Research progress of robot servo vision planning[J]. Journal of Harbin Institute of Technology, 2018, 50(1): 1-10.)
- [2] Lavalley S. Rapidly-exploring random trees: A new tool for path planning[R]. Ames: Iowa State University, 1998: 293-308.
- [3] An B, Kim J, Park F C. An adaptive stepsize RRT planning algorithm for open-chain robots[J]. IEEE Robotics and Automation Letters, 2018, 3(1): 312-319.
- [4] 杜明博, 梅涛, 陈佳佳, 等. 复杂环境下基于RRT的智能车辆运动规划算法[J]. 机器人, 2015, 37(4): 443-450.
(Du M B, Mei T, Chen J J, et al. RRT-based motion planning algorithm for intelligent vehicle in complex environments[J]. Robot, 2015, 37(4): 443-450.)
- [5] 唐华斌, 王磊, 孙增圻. 基于随机采样的运动规划综述[J]. 控制与决策, 2005, 20(7): 721-726.
(Tang H B, Wang L, Sun Z Q. Review of motion planning based on random sampling[J]. Control and Decision, 2005, 20(7): 721-726.)
- [6] Keselman L, Verriest E, Vela P A. Forage RRT-An efficient approach to task-space goal planning for high dimensional systems[C]. IEEE International Conference on Robotics and Automation. Piscataways: IEEE, 2014: 1572-1577.
- [7] Adiyatov O, Sultanov K, Zhumabek O, et al. Sparse tree heuristics for RRT* family motion planners[C]. IEEE International Conference on Advanced Intelligent Mechatronics (AIM). Piscataways: IEEE, 2017: 1447-1452.
- [8] 钟建冬, 苏剑波. 基于概率路标的机器人狭窄通道运动规划[J]. 控制与决策, 2010, 25(12): 1831-1836.
(Zhong J D, Su J B. Path planning of robot narrow channel based on probability landmarks[J]. Control and Decision,

- 2010, 25(12): 1831-1836.)
- [9] 杨一波, 王朝立. 基于改进的人工势场法的机器人避障控制及其Matlab实现[J]. 上海理工大学学报, 2013, 35(5): 496-500.
(Yang Y B, Wang C L. Robot obstacle avoidance control based on improved artificial potential field method and its implementation in Matlab[J]. Journal of University of Shanghai for Science and Technology, 2013, 35(5): 496-500.)
- [10] Karaman S, Frazzoli E. Incremental sampling-based algorithms for optimal motion planning[C]. Robotics Science and Systems. Robotics: Science and Systems Foundation, 2010: 104-111.
- [11] Kleinbort M, Salzman O, Halperin D. Efficient high-quality motion planning by fast all-pairs r-nearest-neighbors[C]. IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2015: 2985-2990.
- [12] Yoon S, Lee D, Jung J, et al. Spline-based RRT, using piecewise continuous collision-checking algorithm for car-like vehicles[J]. Journal of Intelligent and Robotic Systems, 2018, 90(3): 537-549.
- [13] Arslan O, Pacelli V, Koditschek D E. Sensory steering for sampling-based motion planning[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway: IEEE, 2017: 3708-3715.
- [14] Pan J, Manocha D. GPU-based parallel collision detection for real-time motion planning[M]. Berlin: Springer, 2010: 211-228.
- [15] Georges S A, Brandon D L, Joshua M Joseph, et al. Probabilistically safe motion planning to avoid dynamic obstacles with uncertain motion patterns[J]. Autonomous Robots, 2013, 35(1): 51-76.
- [16] Huh J, Lee D D. Learning high-dimensional mixture models for fast collision detection in rapidly-exploring random trees[C]. IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2016: 63-69.
- [17] Li Y, Shao J. A revised Gaussian distribution sampling scheme based on RRT* algorithms in robot motion planning[C]. International Conference on Control, Automation and Robotics. Piscataway: IEEE, 2017: 22-26.
- [18] 齐玉娟, 王延江, 李永平. 基于记忆的混合高斯背景建模[J]. 自动化学报, 2010, 36(11): 320-326.
(Qi Y J, Wang Y J, Li Y P. Mixed Gaussian background modeling based on memory[J]. Acta Automatica Sinica, 2010, 36(11): 320-326.)
- [19] Pechtel P, Pizzagalli D A. Disrupted reinforcement learning and maladaptive behavior in women with a history of childhood sexual abuse: A high-density event-related potential study[J]. Jama Psychiatry, 2013, 70(5): 499-507.

作者简介

张云洲(1974—), 男, 教授, 博士生导师, 从事智能机器人、计算机视觉领域等研究, E-mail: zhangyunzhou@ise.neu.edu.cn;

孙永生(1994—), 男, 硕士生, 从事机器人运动规划的研究, E-mail: 1143347288@qq.com;

夏崇坤(1991—), 男, 博士生, 从事智能机器人的研究, E-mail: 946393367@qq.com;

丁其川(1984—), 男, 副教授, 博士, 从事面向智能机器人的立体视觉感知理解等研究, E-mail: dingqichuan@mail.neu.edu.cn;

王晓哲(1971—), 女, 副教授, 博士, 从事复杂系统的智能控制等研究, E-mail: wangxiaozhe@ise.neu.edu.cn.

(责任编辑: 郑晓蕾)