



(12)发明专利

(10)授权公告号 CN 107403163 B

(45)授权公告日 2019.11.08

(21)申请号 201710642717.X

G06N 3/04(2006.01)

(22)申请日 2017.07.31

G06N 3/08(2006.01)

(65)同一申请的已公布的文献号

申请公布号 CN 107403163 A

(56)对比文件

CN 106780631 A,2017.05.31,全文.

US 2015/0304634 A1,2015.10.22,全文.

(43)申请公布日 2017.11.28

吴俊君. 移动机器人视觉候选闭环召回方法设计.《计算机工程与设计》.2016,第37卷(第6期),第1659-1662页.

(73)专利权人 武汉大学

地址 430072 湖北省武汉市武昌区珞珈山
武汉大学

审查员 魏旭阳

(72)发明人 邹勤

(74)专利代理机构 武汉科皓知识产权代理事务
所(特殊普通合伙) 42222

代理人 齐晨涵 姜学德

(51)Int.Cl.

G06K 9/00(2006.01)

G06K 9/62(2006.01)


权利要求书2页 说明书6页 附图1页

(54)发明名称

一种基于深度学习的激光SLAM闭环自动检测方法

(57)摘要

本发明公开了一种基于深度学习的激光SLAM闭环检测方法,它将SLAM闭环检测的问题转化为SALM数据样本的检索问题,并创新性地构建了一种深度Hash网络对激光点云样本进行Hash编码,进而在Hash编码的基础上进行样本相似度计算,实现相似样本的快速检索和SLAM闭环检测。所构建深度Hash网络利用深度学习的优势可以获得比传统编码技术更可靠的二进制编码,从而大幅提高检索的准确度;设计了一种新的点云特征提取算法,它在对点云进行空间划分和投影的基础上构建特征图,实现了对激光点云样本数据的可靠描述和与深度Hash网络的有效对接。所构建的深度Hash网络采用离线训练,训练好的模型能满足实时的编码需求。



1. 一种基于深度学习的激光SLAM闭环检测方法,其特征在于:包括以下步骤:

s1、构建点云数据样本对数据集,并按样本对中两样本的相似度将样本对标记为正样本对和负样本对;

s2、提取样本对中的样本特征;

s3、构建深度Hash网络模型:所述深度Hash网络模型包括一个输入层、若干个卷积层、池化层,一个Hash层和一个输出层;

s4、将步骤s2中提取了样本特征的样本对作为深度Hash网络的输入,对所构建的网络进行训练;

s5、取出步骤s4中深度Hash网络模型从输入层到Hash层的网络模型和参数,作为Hash编码器;

s6、进行实际的SLAM作业:利用Hash编码器对采集的点云数据进行编码,且Hash编码器的输入层为上一个点云数据的输出层;

s7、进行闭环判断:设已进行编码的点云数据编码为 $HASH_1, HASH_2, \dots, HASH_{j-1}$,当前样本编码为 $HASH_j$,计算 $HASH_j$ 与 $HASH_1, HASH_2, \dots, HASH_{j-1}$ 之间的距离,如果距离都大于设定的阈值,判断为非闭环,继续进行步骤s6的操作,如果某一距离小于设定的阈值,则用点云配准算法进行配准操作,误差小于设定的阈值,则判断为闭环,否则判断为非闭环。

2. 根据权利要求1所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:所述步骤s1中正样本对为两个点云数据样本位置之间的欧式距离小于5米并且点云配准误差小于一定阈值的样本对,负样本对为两个点云数据样本位置之间的欧式距离大于10米的样本对。

3. 根据权利要求2所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:所述步骤s1中样本对构建有200000个,其中正样本对100000个,负样本对100000个。

4. 根据权利要求1所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:步骤s2的具体过程如下:计算投影中心O和投影主轴UOV,其中U端朝下,V端朝上,从下往上在投影轴上构建垂直于投影主轴UOV的 $n+1$ 个切分平面,依次为 L_1, L_2, \dots, L_{n+1} ,利用这 $n+1$ 个切分平面将点云进行空间划分,位于其中的 L_i 和 $L_{i+1}, 1 \leq i \leq n$ 之间的所有点沿着平行于投影主轴的方向向切分平面 L_i 投影;对于 L_1, L_2, \dots, L_n 中的每个平面,统计落在它上面的投影点,将同一坐标处投影点的个数记作该坐标的特征值,依次得到特征图 M_1, M_2, \dots, M_n ;将这 n 个特征图作为对应的点云样本的特征。

5. 根据权利要求4所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:所述投影中心O为点云样本的几何中心,利用重力方向的平均值作为投影主轴方向,从而构建投影主轴UOV,其中U是指向地心的一端,V是指向天空的一端。

6. 根据权利要求5所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:切分平面的个数为10,切分平面 L_1 垂直于投影主轴并且经过高程值最小的点云样本点, L_{10} 垂直于投影主轴并且经过高程值最大的点云样本点, L_1 和 L_{10} 之间等距划分得到 L_1 至 L_9 ,将划分后的样本点投影到 L_1 至 L_9 便依次得到特征图 M_1, M_2, \dots, M_9 ,所述特征图的形状为正方形,在投影轴方向上投影重合,所述正方形恰好能包含所有投影点,在此基础上将所有特征图分别进行重采样得到 400×400 像素大小的特征图。

7. 根据权利要求6所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:所述深

度Hash网络模型由16层组成,其中,第1层是输入层,由步骤s2得到的n个特征图构成,第2,4,6,8,9,11,12层是卷积层,第3,5,7,10是四个池化层,第13,14,16是三个全连接层,第15层是一个Hash层,与第14层节点数目相等;第16层为输出层,由两个节点组成。

8.根据权利要求7所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:所述第13层设置2048个节点,第14层设置36个节点,第14层和第15层的节点连接方式为一对一的连接,其激活函数采用Sigmoid函数,第15层中的第i个节点的输出值定义为 H_i ,

$$H_i = \begin{cases} 0, & \text{if Sigmoid}(v_i) < 0.5 \\ 1, & \text{otherwise} \end{cases}$$

其中 v_i 为第14层第i个节点的值,Sigmoid函数的定义为:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^x}.$$

9.根据权利要求8所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:训练过程停止的条件为两种,一种是损失函数的值小于设定的阈值T,另一种是训练达到一定次数N,其中,整个网络的损失函数采用交叉熵进行计算,其定义为其中,p和q分别代表真实标签和预测标签,p(x)和q(x)分别对应x的统计概率值和预测概率值

$$H(p, q) = \sum_x p(x) \log q(x)$$

10.根据权利要求9所述的基于深度学习的激光SLAM闭环检测方法,其特征在于:Hash编码之间的距离值采用哈密尔顿距离计算,它定义为

$$\text{HamiDist}(\text{HASH}_i, \text{HASH}_j) = \text{XOR}(\text{HASH}_i, \text{HASH}_j)$$

其中,XOR表示异或操作。

一种基于深度学习的激光SLAM闭环自动检测方法

技术领域

[0001] 本发明涉及移动测图与自主导航领域,具体涉及一种基于深度学习的激光SLAM闭环自动检测方法。

技术背景

[0002] SLAM(simultaneous localization and mapping),即时定位与地图构建。SLAM最早在1988年被提出,由于其重要的理论与应用价值,被很多学者认为是实现真正全自主移动机器人的关键。SLAM问题可以描述为:机器人在未知环境中从一个未知位置开始移动,在移动过程中根据位置估计和地图进行自身定位,同时在自身定位的基础上建造增量式地图,实现机器人的自主定位和导航。目前用在SLAM上的传感器主要分两大类,一类是激光雷达,另一类是摄像头,相应的SLAM技术被分别称为激光SLAM和视觉SLAM。在机器人或测量平台移动的过程中,由于地图构建和自主定位不可避免地产生误差,而且它会随着时间而累加,即产生累积误差。通常需要采用闭环检测对这种累积误差进行处理。闭环检测,又称回环检测(Loop closure detection),是指机器人或移动测量平台识别出曾经到达的场景。如果检测成功,则可以通过平差技术显著地减小累积误差,提高地图构建和自主定位的精度。因此,闭环检测的准确性是决定SLAM精度的一个重要问题。传统的激光SLAM闭环检测主要采用ICP算法(iterative closest point迭代最近点)或词袋技术(Bag-of-Words,BOW)对场景点云数据进行匹配识别,其中前者比较点云的空间位置分布,后者比较点云的空间特征,并结合特征提取、特征编码、特征分类和匹配算法,进行场景相似度的计算以实现闭环检测。然而,ICP算法的运算效率较低,词袋技术的特征提取、编码、分类等通常是建立在人工构建的特征空间之上,其适应性存在局限,所构建的闭环检测方法准确度较低、可靠性较差,不能满足高精度的激光SLAM定位和构图需求。

发明内容

[0003] 本发明针对现有技术的不足,提供一种准确度高、可靠性好的基于深度学习的激光SLAM闭环检测方法。

[0004] 为了实现上述目的,本发明所设计的一种基于深度学习的激光SLAM闭环检测方法,其特殊之处在于:包括以下步骤:

[0005] s1构建点云数据样本对数据集,并按样本对中两样本的相似度将样本对标记为正样本对和负样本对;

[0006] s2提取样本对中的样本特征;

[0007] s3构建深度Hash网络模型:所述深度Hash网络模型包括一个输入层、若干个卷积层、池化层,一个Hash层和一个输出层;

[0008] s4将步骤s2中提取了样本特征的样本对作为深度Hash网络的输入,对所构建的网络进行训练;

[0009] s5取出步骤s4中深度Hash网络模型从输入层到Hash层的网络模型和参数,作为

Hash编码器；

[0010] s6进行实际的SLAM作业：利用s5中的Hash编码器对采集的点云数据进行编码；

[0011] s7进行闭环判断：设已进行编码的点云数据编码为HASH₁, HASH₂, …, HASH_{j-1}, 当前样本编码为HASH_j, 计算HASH_j与HASH₁, HASH₂, …, HASH_{j-1}之间的距离, 如果距离都大于设定的阈值, 判断为非闭环, 继续进行步骤s6的操作, 如果某一距离小于设计阈值, 则用点云配准算法进行精细的配准操作, 误差小于设定阈值, 则判断为闭环, 否则判断为非闭环。

[0012] 进一步地, 所述步骤s1中正样本对为两个点云数据样本位置之间的欧式距离小于5米、并且点云配准误差小于一定阈值的样本对, 负样本对为两个点云数据样本位置之间的欧式距离大于10米的样本对。

[0013] 优选地, 所述点云配准采用ICP算法, 误差阈值取 $0.2 \times [Q(S1) + Q(S2)]$, 其中Q(S1)表示点云样本S1的最小外接长方体的体积。

[0014] 更进一步地, 所述步骤s1中样本对构建有200000个, 其中正样本对100000个, 负样本对100000个。

[0015] 再进一步地, 步骤s2的具体过程如下：计算投影中心O和投影主轴UOV, 其中U端朝下, V端朝上, 从下往上在投影轴上构建垂直于投影主轴UOV的n+1个切分平面, 依次为L₁, L₂, …, L_{n+1}, 利用这n+1个切分平面将点云进行空间划分, 位于其中的L_i和L_{i+1} (1 ≤ i ≤ n) 之间的所有点沿着平行于投影主轴的方向向切分平面L_i投影；对于L₁, L₂, …, L_n中的每个平面, 统计落在它上面的投影点, 将同一坐标处投影点的个数记作该坐标点的特征值, 依次得到特征图M₁, M₂, …, M_n, 将这n个特征图作为点云样本的特征。

[0016] 再进一步地, 所述投影中心O为点云样本的几何中心, 利用重力方向的平均值作为投影主轴方向, 从而构建投影主轴UOV, 其中U是指向地心的一端, V是指向天空的一端。

[0017] 再进一步地, 切分平面的个数为10, 切分平面L₁垂直于投影主轴并且经过高程值最小的点云样本点, L₁₀垂直于投影主轴并且经过高程值最大的点云样本点, L₁和L₁₀之间等距划分得到L₁至L₉, 将划分后的样本点投影到L₁至L₉便依次得到特征图M₁, M₂, …, M₉, 所述特征图的形状为正方形, 在投影主轴方向上投影重合, 所述正方形恰好能包含所有投影点, 在此基础上将所有特征图进行重采样得到400 × 400像素大小的特征图。

[0018] 再进一步地, 所述深度Hash网络模型由16层组成, 其中, 第1层是输入层, 由步骤2得到的n个特征图构成, 第2, 4, 6, 8, 9, 11, 12层是卷积层, 第3, 5, 7, 10是四个池化层, 第13, 14, 16是三个全连接层, 第15层是一个Hash层, 与第14层节点数目相等；第16层为输出层, 由两个节点组成。

[0019] 再进一步地, 第13层设置1024个节点, 第14层设置36个节点, 第14层和第15层的节点连接方式为一对一的连接, 其激活函数采用Sigmoid函数, 第15层中的第i个节点的输出值定义为H_i,

$$[0020] \quad H_i = \begin{cases} 0, & \text{if Sigmoid}(v_i) < 0.5 \\ 1, & \text{otherwise} \end{cases}$$

[0021] 其中v_i为第14层第i个节点的值, Sigmoid函数的定义为：

$$[0022] \quad \text{Sigmoid}(x) = \frac{1}{1 + e^x}$$

[0023] 再进一步地,训练过程停止的条件为两种,一种是损失函数的值小于设定的阈值,另一种是训练达到一定次数;其中,整个网络的损失函数采用交叉熵进行计算,其定义为

$$[0024] \quad H(p, q) = \sum_x p(x) \log q(x)$$

[0025] 其中,p和q分别代表真实标签和预测标签,p(x)和q(x)分别对应x的统计概率值和预测概率值,

[0026] 再进一步地,Hash编码之间的距离值采用哈密尔顿距离(HamDist)计算,它定义为

$$[0027] \quad \text{HamDist}(\text{HASH}_i, \text{HASH}_j) = \text{XOR}(\text{HASH}_i, \text{HASH}_j)$$

[0028] 其中,XOR表示异或操作。

[0029] 本发明的优点在于:

[0030] 1) 本发明将SLAM闭环检测的问题转化为SALM数据样本的检索问题,并设计了一种由粗到精的闭环检测策略,大幅提高闭环检测的效率。首先在粗检测中利用深度Hash网络对点云样本进行二进制编码和检索,发现疑似闭环样本对,然后在精检测中利用点云配准算法对疑似闭环样本对进行判别;在粗检测中,利用Hash编码能对样本的相似度进行快速比对,从而能将大量的不相似样本在粗检测中过滤掉,使得所发明的方法相较于传统闭环检测方法具有大幅提高的运算效率。值得注意的是,所构建的深度Hash网络采用离线学习的模式进行训练,训练好的模型能满足实时的点云样本Hash编码需求。

[0031] 2) 本发明创新性地构建了一种深度Hash网络对SLAM中的激光点云样本进行Hash编码,进而在Hash编码的基础上进行样本相似度的计算,实现相似样本的快速检索和SLAM闭环检测。所构建的深度Hash网络实现了深度卷积神经网络技术和Hash编码技术的融合,它利用深度学习的优势可以获得比传统编码技术更可靠的二进制编码,从而能大幅度提高检索的准确度;

[0032] 3) 设计了一种新的点云特征提取算法,它在对点云进行空间划分和投影的基础上构建特征图,实现了对激光点云样本数据的可靠描述和与深度Hash网络的有效对接。

附图说明

[0033] 图1为一种点云样本空间划分及投影主轴示意图。

[0034] 图2为一种深度Hash网络模型图。

具体实施方式

[0035] 下面结合附图和具体实施例对本发明作进一步的详细描述:

[0036] 一种基于深度学习的激光SLAM闭环检测方法,包括以下步骤:

[0037] 步骤1:构建点云数据样本对数据集:采集激光点云数据,将激光点云数据按采集的时间顺序和一定的间隔划分成单个样本,从点云数据样本中提取一定数量的样本对,并按样本对中两样本的相似度将样本对划分为正样本对和负样本对;构建一定数量的正样本

和负样本对,其中,所述正样本对和负样本对构成点云数据样本集,每个样本对由两个样本组成,根据每对样本之间的相似度,确定样本对的标签。

[0038] 优选地,通过机器人或移动测量平台携带的激光扫描仪采集激光点云数据;

[0039] 优选地,利用时间长度1秒作为点云的分段间隔将点云数据划分为点云数据样本;

[0040] 优选地,构建包含200000个样本对的点云数据样本集,其中100000个样本对的标签为正,另100000个样本对的标签为负,它们分别称为正样本对和负样本对。

[0041] 优选地,利用POS系统(Positioning and Orientation System,定位定姿系统)获取机器人或移动测量平台的位置坐标,并作为辅助信息来判定样本对之间的相似度。设两个点云数据样本S1和S2的中心位置分别为P1和P2,计算P1和P2之间的欧氏距离 $D(P1, P2)$,

[0042] 其中下标 x, y, z 分别代表点在 x, y, z 轴上的坐标值。如果 $D(P1,$

[0043] $D(P1, P2) = [(P1_x - P2_x)^2 + (P1_y - P2_y)^2 + (P1_z - P2_z)^2]^{-\frac{1}{2}}$

[0044] $P2)$ 大于10米,则判定S1和S2相似度低,是一个负样本对;如果 $D(P1, P2)$ 小于5米,则计算S1和S2的相似度来确认它们是否为负样本对。

[0045] 优选地,采用ICP算法对点云样本S1和S2的相似度进行计算,通过ICP对S1和S2进行配准处理,如果其配准误差小于 $0.2 \times [Q(S1) + Q(S2)]$,则判定S1和S2相似度高,是一个正样本对,其中 $Q(S1)$ 表示点云S1的最小外接长方体的体积;值得说明的是,POS系统只是用于辅助收集训练样本,在实际SLAM闭环检测时,不需要POS系统。

[0046] 步骤2:提取样本对中样本特征:对步骤1中样本对的每一个样本进行特征提取。计算投影中心O和投影主轴UOV,其中U端朝下,V端朝上,从下往上在投影轴上构建垂直于投影主轴UOV的 $n+1$ 个切分平面,依次为 L_1, L_2, \dots, L_{n+1} ,利用这 $n+1$ 个切分平面将点云进行空间划分,位于 L_i 和 L_{i+1} ($1 \leq i \leq n$)之间的所有点沿着平行于投影主轴的方向向切分平面 L_i 投影;对于 L_1, L_2, \dots, L_n 中的每个平面,统计落在它上面的投影点,将同一坐标处投影点的个数记作该坐标点的特征值,依次得到特征图 M_1, M_2, \dots, M_n ;将这 n 个特征图作为对应的单个点云样本的特征。

[0047] 优选地,将此点云样本的几何中心作为投影中心O,利用重力方向的平均值作为投影主轴方向,从而构建投影主轴UOV,其中U是指向地心的一端,V是指向天空的一端。

[0048] 优选地,切分平面的个数为10,切分平面 L_1 垂直于投影主轴并且经过高程值最小的点云样本点, L_{10} 垂直于投影主轴并且经过高程值最大的点云样本点, L_1 和 L_{10} 之间等距划分得到 L_1 至 L_9 ,将划分后的样本点投影到 L_1 至 L_9 便依次得到特征图 M_1, M_2, \dots, M_9 ,特征图的形状取正方形,各正方形需包含其对应特征图上的所有投影点,并且在投影主轴方向上投影重合,在此基础上将所有特征图进行重采样得到 400×400 像素大小的特征图,优选地,特征图采样采用双线性插值算法。

[0049] 步骤3:构建深度Hash网络模型,其网络模型结构由一个输入层、若干个卷积层、池化层,一个Hash层和一个输出层构成。其中输入层由步骤2得到的 n 个特征图构成,Hash层包含若干个节点,用于生成Hash数列,即一个二进制序列,输出层包含两个节点。

[0050] 优选地,网络由16层组成,其中,第1层是输入层,由步骤2得到的 n 个特征图构成,第2,4,6,8,9,11,12层是卷积层,卷积层采用一定数量和一定大小的卷积核进行卷积操作得到,卷积操作定义为

$$[0051] \quad g(s, t) = \sum_{i=-r}^r \sum_{j=-r}^r f(i, j) I(s - i + 1, t - j + 1)$$

[0052] 其中f为卷积核,r是卷积核的尺寸大小,f(i, j)表示卷积核在坐标(i, j)处的值,I为卷积输入,一般称作特征图,g(s, t)表示在对I进行卷积操作在点(s, t)处得到的输出值,优选地,卷积层采用256个卷积核,卷积核的尺寸大小为3;第3,5,7,10是四个池化层,所谓的池化,是指对每个特征图进行下采样,在一定的邻域范围内选取一个值作为采样值,优选地,池化采用2×2邻域的最大池化法;第13,14,16是三个全连接层;第15层是一个Hash层,与第14层节点数目相等;第16层为输出层,由两个节点组成。优选地,卷积层和全连接层的激活函数采用ReLU(Rectified Linear Units)函数。

[0053] 优选地,第13层设置1024个节点,第14层设置36个节点,第14层和第15层的节点连接方式为一对一的连接,其激活函数采用Sigmoid函数,第15层中的第i个节点的输出值定义为H_i,

$$[0054] \quad H_i = \begin{cases} 0, & \text{if Sigmoid}(v_i) < 0.5 \\ 1, & \text{otherwise} \end{cases}$$

[0055] 其中v_i为第14层第i个节点的值,Sigmoid函数的定义为

$$[0056] \quad \text{Sigmoid}(x) = \frac{1}{1 + e^x}$$

[0057] 步骤4:将步骤2中提取了样本特征的本样本对作为深度Hash网络的输入,对所构建的网络进行训练,训练过程停止的条件为两种,一种是损失函数的值小于设定的阈值T,另一种是训练达到一定次数N,保存训练好的模型及参数;

[0058] 优选地,整个网络的损失函数采用交叉熵进行计算,其定义为

$$[0059] \quad H(p, q) = \sum_x p(x) \log q(x)$$

[0060] 其中,p和q分别代表真实标签和预测标签,p(x)和q(x)分别对应x的统计概率值和预测概率值;优选地,T取值0.01,N取值100000。

[0061] 步骤5:取出步骤4中深度Hash网络模型从输入层到Hash层的网络模型和参数,作为Hash编码器。

[0062] 步骤6:进行实际的SLAM作业,利用Hash编码器对采集的点云数据进行编码。

[0063] 步骤7:继续进行实际的SLAM作业,设已进行编码的点云数据编码为HASH₁, HASH₂, ..., HASH_{j-1},当前样本编码为HASH_j,计算HASH_j与HASH₁, HASH₂, ..., HASH_{j-1}之间的距离,如果距离都大于设定的阈值,判断为非闭环,继续进行步骤6的操作,如果某一距离小于设计阈值,则用点云配准算法进行配准操作,误差小于设定阈值,则判断为闭环,否则判断为非闭环;如果移动测量平台安装有GPS系统,可以利用GPS获取的位置信息过滤掉明显不是闭环的HASH编码,从而缩小闭环搜索的范围。

[0064] 优选地,Hash编码之间的距离值采用哈密尔顿距离(HamiDist)计算,它定义为

$$[0065] \quad \text{HamiDist}(\text{HASH}_i, \text{HASH}_j) = \text{XOR}(\text{HASH}_i, \text{HASH}_j)$$

[0066] 其中,XOR表示异或操作。

[0067] 优选地,步骤7中的设计阈值取Hash编码长度值的六分之一。

[0068] 优选地,步骤7中点云配准算法及阈值设置与前述步骤1相同。

[0069] 本发明的优点在于:

[0070] 1) 本发明将SLAM闭环检测的问题转化为SALM数据样本的检索问题,并设计了一种由粗到精的闭环检测策略,大幅提高闭环检测的效率。首先在粗检测中利用深度Hash网络对点云样本进行二进制编码和检索,发现疑似闭环样本对,然后在精检测中利用点云配准技术对疑似闭环样本对进行判别;在粗检测中,利用Hash编码能对样本的相似度进行快速比对,从而能将大量的不相似样本在粗检测中过滤掉,使得所发明的方法相较于传统闭环检测方法具有大幅提高的运算效率。值得注意的是,深度Hash网络采用离线学习的模式进行训练,训练好的模型能满足实时的点云Hash编码需求。

[0071] 2) 本发明创新性地构建了一种深度Hash网络对SLAM中的激光点云样本进行Hash编码,进而在Hash编码的基础上进行样本相似度的计算,实现相似样本的快速检索和SLAM闭环检测。所构建的深度Hash网络实现了深度卷积神经网络技术和Hash编码技术的融合,它利用深度学习的优势可以获得比传统编码技术更可靠的二进制编码,从而能大幅度提高检索的准确度;

[0072] 3) 设计了一种新的点云特征提取算法,它在对点云进行空间划分和投影的基础上构建特征图,实现了对激光点云样本数据的可靠描述和与深度Hash网络的无缝对接。

[0073] 以上所述仅为本发明的较佳实施例,并不用以限制本发明,凡在本发明的精神和原则之内所作的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。




图1




图2