arXiv:2303.00295v1 [cs.RO] 1 Mar 2023

大型地图上的高效机器人定位区域预测

Matteo Scucchia[1] 和 Davide Maltoni[2]

摘要—识别已探索过的地点（即地点识别）是同步定位与建图（SLAM）中的一项基本任务，可用于实现机器人重定位和回环检测。在拓扑同步定位与建图中，识别通过将与当前节点关联的特征签名（或特征向量）与已知地图中各节点的特征签名进行比较来完成。然而，随着节点数量增加，将当前节点的特征签名与所有现有特征签名进行匹配会变得效率低下，阻碍实时导航。本文提出了一种新方法，用于预先选取一部分地图节点进行地点识别。在探索过程中，地图节点会被聚类，每个簇都与一个区域相关联。区域标签成为深度神经网络的预测目标；在导航过程中，只将与预测概率较高的区域相关联的节点纳入匹配。虽然所提出的技术可集成到不同的同步定位与建图方法中，但本文介绍了将其有效集成到 RTAB-Map（一种流行的实时拓扑同步定位与建图框架）中的方案，并借此设计和开展了多项实验来证明其有效性。实验所用的所有代码和材料都将在以下网址公开：
https://github.com/MI-BioLab/region-learner。

I. 引言

回环检测，即通过分析传感器数据来判断智能体是否返回了先前到访过的地点，是同步定位与建图（SLAM）问题中的关键环节，因为它能够显著提高地图的精度 [1]。由于传感器和执行器存在固有噪声及未建模的动态特性，移动机器人在探索环境时会不断累积定位误差，这种误差称为漂移。返回先前到访过的地点能够纠正这一误差，从而提升地图的整体一致性。从哲学角度来看，地点识别为机器人提供了关于世界的拓扑知识：世界并非一条无尽的走廊，而是一个可以通过不同路径抵达同一地点的空间。因此，对于能够长期自主导航的移动机器人系统而言，通过有效的地点识别技术实现回环检测至关重要。遗憾的是，这个问题本身十分复杂，面临着重大挑战 [2]；具体而言：

- 环境条件的变化，例如昼夜或不同季节之间的光照差异，以及人类活动造成的变化或遮挡，都会增加地点识别的难度。
- 为了识别此前到访过的地点，机器人必须保存先前观测结果的记忆，并将其与当前观测结果进行比较。对于大型地图，这一过程所需的内存空间和处理时间可能超出可用资源。例如， [3]的作者指出，在导航过程中进行实时回环检测时，内存中最多只能维护约 500 个节点。

为克服第二个挑战，可以采用智能内存管理系统，以限制回环检测所需进行的比较次数。例如，RTAB-Map [4] 是一种广为人知的方法，它实现了基于图的同步定位与地图构建，并采用基于外观的回环检测器。为确保实时性能，RTAB-Map 使用三种类型的内存：

1）短期记忆（STM）：包含图中最新节点的缓冲区；2）工作记忆（WM）：用于图优化和回环检测的工作区；3）长期记忆（LTM）：存储地图全部知识的本地数据库。

因此，只有 WM 中的节点才用于地点识别和回环检测。WM 与 LTM 之间会持续进行转移，以便：i）从 LTM 中检索与 WM 中最近的、置信度最高的回环假设在时空上相邻的节点；ii）将最不可能参与回环的节点转移回 LTM，从而使 WM 的大小保持在预设容量以内。这种内存管理方式可确保回环检测耗时恒定，不受地图大小的影响。然而，如果 WM 中没有正确的节点（因为既不满足空间连续性，也不满足时间连续性），检测就不可避免地会失败。这是大范围回环中的典型情况：机器人返回到先前访问过的地点（见图1）。

所提出方法的目标是确保始终考虑回环所需的节点。为此，在探索过程中对地图图结构进行聚类，将地图节点关联到各个簇（或区域）；随后，每个区域都会成为导航过程中在线执行的预测过程的目标。具体而言，我们训练了一个深度神经网络，用于预测当前节点属于已知区域的概率，使系统能够检索所有相应的节点。节点聚类的概念对我们的方法至关重要，因为与单个节点相关联的特征签名（即我们这里的图像）过于具体，且对于机器人重访同一地点时可能出现的变化而言不够稳定；而与一个区域（例如建筑物中的房间或城市中的广场）相关联的图像集合则能以稳健得多的方式共同描述该地点。

[1,2]意大利博洛尼亚大学计算机科学与工程系。通讯作者：matteo.scucchia2@unibo.it

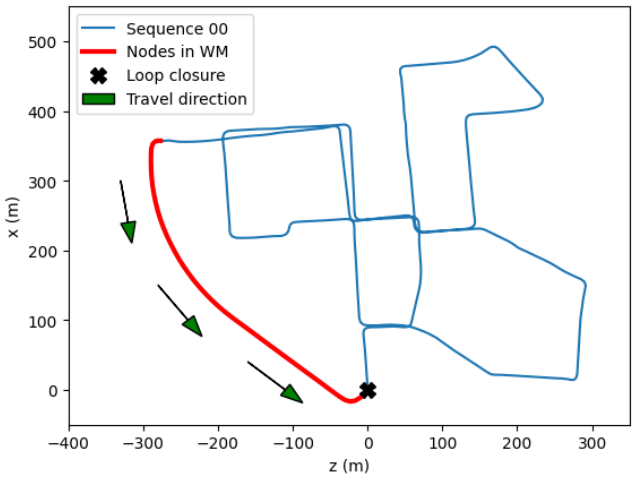

图 1. 在这个取自 KITTI 里程计数据集序列 00 的示例中，机器人正沿绿色箭头所示路径行进，工作记忆（WM）则依据时空连续性准则，存储了红色轨迹标记的节点。在此，当机器人经过此前探索过的位置（以符号 x 表示）时，无法检测到回环。

图2中展示了一个示例。

值得注意的是，所提出的技术可以与不同的同步定位与建图方法配合使用，不受位姿估计和地图优化所用算法的限制。本文将其集成到 RTAB-Map 中，以展示该技术在遵循实时性要求的同时，提升大型环境中的回环检测和重定位能力。除内存管理模块外，我们未对 RTAB-Map 作任何改动。回环仍通过 RTAB-Map 原生的词袋方法进行检测[5]，整个过程仍采用传统的基于图的同步定位与地图构建（例如通过 PnP RANSAC 进行位姿估计[6]）；地图聚类和基于深度学习的区域预测仅用于改进工作记忆（WM）与长期记忆（LTM）之间的节点交换。

在讨论相关文献（第 2 节）之后，本文其余部分将详细介绍我们的方法。第 3 节阐述了用于将图节点划分为区域的动态聚类算法；第 4 节和第 5 节分别详细介绍区域预测以及在 RTAB-Map 中的实现。第 6 节展示实验结果，最后，第 7 节给出一些总结性评论。

II. 相关工作

有效的内存管理和稳健的地点识别是成功实现长期回环检测的基本原则。文献中已提出了一些方法，用于在探索大型环境时智能地管理内存。[7],中概述的一种方法建议将地图的探索划分为较小的子地图，并在创建新的子地图时，在通过一扇门后自动触发。这种模块化结构能够对每个独立房间或室外区域的地图进行独立维护，仅考虑整个地图中的选定部分，从而便于优化和回环检测。然而，在非结构化环境中，在子地图之间切换可能较为复杂。

RTAB-Map 采用了三种不同的内存结构，如第 I 节所述。这些内存最初均为空。在机器人探索过程中，每当创建一个新节点时，该节点便会被插入 STM，并添加到整体地图图结构中。当 STM 达到最大容量时，最久未使用的节点会被转移到 WM 中，同时保留与当前观测相比最新且最相似的节点。随着地图不断扩展，用于回环检测的比较次数可能会妨碍实时处理。因此，WM 与 LTM 之间会持续进行节点移动（见图 3）。这一过程称为 转移，即将 WM 中相对于新节点最久未使用或最不相似的节点转移到 LTM。相反，检索 过程则是从 LTM 中检索与当前最高回环假设在时间或空间上最接近的节点，并将其置于 WM 中。正如前文所述，并且我们的实验结果也已证明，RTAB-Map 内存管理策略背后的空间和时间连续性原则，在出现大范围回环时可能会失效。

随着深度学习的蓬勃发展，深度神经网络已被用于改进地点识别 [8], [9]，持续学习技术也被用于帮助机器人学习地点外观可能随时间发生的变化 [10]。新颖的仿生方法将深度神经网络、持续学习技术和生成模型相结合，以改进地点识别 [11]。然而，大多数此类方法仍会将当前节点与整个地图进行匹配，因此无法扩展到大型地图。因此，所提出的方法并非替代方案，而是可以与这些方法协同工作，以提高其在大型地图上的效率。

III. 地图聚类

地图聚类旨在将地图节点划分为连通簇（或区域），在本研究中采用 [12] 提出的基于散布的算法来实现。该算法通过降低簇内节点的空间 散度，在探索过程中动态创建簇。散布度量反映了簇中节点相对于等效半径的分散程度。等效半径描述了簇的特征，而不受其实际形状影响，并将其与理想的高密度拓扑进行比较。新节点被分配到某个区域的方式取决于簇的期望基数、形状因子以及等效圆的半径上限。根据所探索的环境和机器人移动的速度，可以调节这些参数以获得所需的聚类效果（避免区域过小或过大）。

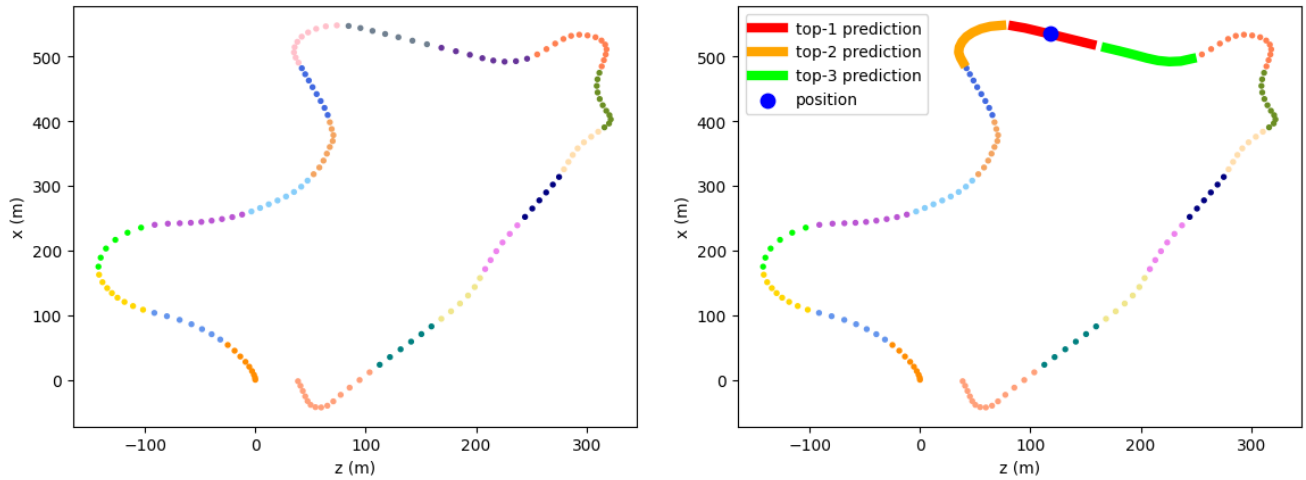

图 2. 左图展示了算法如何对 RTAB-Map 在 KITTI 里程计数据集的序列 09 上运行时生成的图进行聚簇。图中的每个点对应图中的一个节点，不同的簇以不同颜色标示。右图突出显示了训练好的模型在随后对同一序列进行导航时预测出的区域。

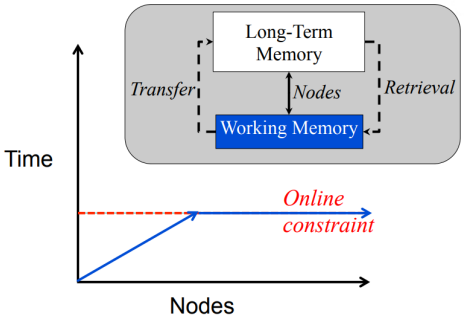

图 3. RTAB-Map 回环检测的计算开销。随着地图图结构中的节点数量增加，耗时呈线性增长，直至工作记忆被占满。此后，由于工作记忆中始终保留相同数量的节点，计算开销便保持不变。

公式 1 展示了簇 C_i 的散度计算方式。对于基数为 $n_i > 1$ 的簇，s'' 是簇内所有节点 v 到质心 $\mathbf{pos}(C_i)$ 的欧几里得距离平方之和，除以等效半径 $\mathbf{req}(C_i)$ (2)。阈值 s' 可以进行调整，以控制簇的大小。请参阅 [12]，了解更多详细信息和示例。

$$s(C_i) = s' + s''(C_i) \tag{1}$$

$$s''(C_i) = \frac{1}{\mathbf{req}(C_i)} \sum_{v \in C_i} \Delta(\mathbf{pos}(v), \mathbf{pos}(C_i))^2 \text{ if } n_i > 1 \tag{2}$$

由于这种方法是一种动态聚类算法，如果移除某个节点不会违反连通性约束（即不会将其所属的簇分割开），并且移除该节点导致当前簇的散度降低幅度小于将其纳入新簇所导致的散度增加幅度，则可以将该节点重新分配到不同的簇中。这种动态重新分配使得机器人在同一区域内移动时能够形成紧凑的（球形）簇；如果没有这种重新分配，簇的形状将大多呈线性（见图 4）。

IV. 区域预测

一般情况下，用于区域预测的神经网络必须以在线方式进行持续学习训练（即训练与推理之间没有明确区分）；但在这项旨在展示核心思想的初步工作中，我们采用了一些简化，并确定了三个阶段：

1) 探索阶段，机器人探索其环境，并将 RTAB-Map 创建的地图聚类为多个区域；在此阶段结束时，可获得由节点图像及其区域标签组成的训练数据集；2) 训练阶段，使用神经网络离线训练分类器；3) 推理阶段，使用神经网络预测机器人连续导航过程中的区域概率，包括再次访问已知地点时的情况。

探索步骤结束后，使用图像和区域以监督方式训练神经网络。采用在 ImageNet 上预训练且权重冻结的轻量级 MobileNetV2 [13] 作为卷积主干网络，从图像中提取特征；同时，在主干网络之上训练一个多层感知机（MLP）分类器，以预测区域概率。本文使用的模型非常简单，即使在嵌入式计算板上也能实现实时推理。不过，根据所需的准确率与效率的权衡，可以轻松地将其替换为专为地点识别设计的更复杂模型，例如 NetVLAD [14] 和 RegionVLAD [15]。

多层感知机通过监督进行训练：将正确区域的概率设为 1，所有其他区域的概率设为 0。由于各簇的基数可能存在显著差异，因此采用焦点损失；焦点损失更善于

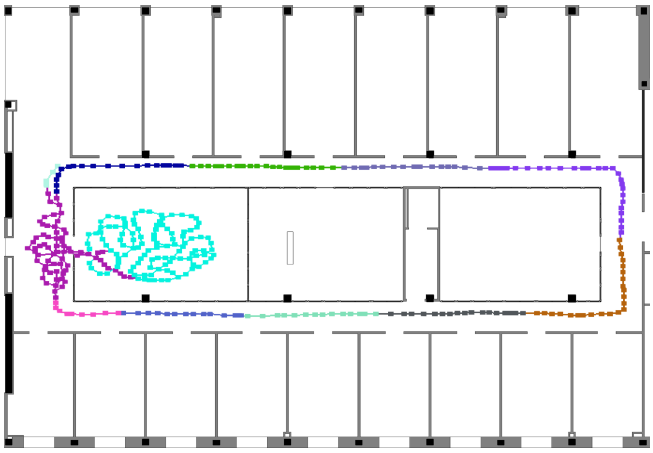

图4. 图中展示了大学校园某一楼层的一部分，并叠加了机器人导航过程中得到的聚类结果。不同的簇/区域以不同颜色标示。大多数簇（位于走廊中）呈线性形状；然而，当机器人深入探索左侧房间及其前方的走廊，并在其中闭合多个小回环、触发节点重新分配时，聚类算法还会生成两个更接近球形的簇。

处理类别不平衡。此外，我们将分类器最后一层中的经典 Softmax（使类别概率之和为 1）替换为逻辑函数，使网络能够以较高置信度预测更多区域；纹理稀少的地点（如走廊）便是这种情况，此时预测应正确返回更多区域（见图 5）。在推理时，为降低检索到错误区域的可能性（由于区域间相似度较高），采用了指数移动平均（EMA）。区域 p_t^i 在时间 t的概率取决于当前观测的概率 o_t^i以及前一步的概率 p_{t-1}^i，并由参数 α加权。通过这种方法，机器人可能会遇到相似的环境，但置信度融合倾向于降低错误选择的概率。

$$p_t^i = \alpha o_t^i + (1-\alpha) p_{t-1}^i \tag{3}$$

A. 在 *RTAB-Map* 中的集成

RTAB-Map 转移-检索过程经过修改，以便在导航期间检索属于最可能区域的节点。与原始解决方案一样，工作记忆不能超过 N 个节点的最大容量。



图5. 两条外观非常相似的不同走廊（来自我们的 Campus 数据集）。在这种情况下，我们的模型应以较高置信度预测这两个区域。

更新过程（算法 1 中的工作记忆更新）会在每次创建新节点时 v 调用。

算法1 修改后的 RTAB-Map 转移检索

过程工作记忆更新(v)
  $h \leftarrow$ v 在工作记忆中的最高置信度回环假设
  $U_1 \leftarrow k_1$ h的邻接节点（在时间和空间上）
在长期记忆中
  检索 U_1
  $U_2 \leftarrow k_2$ v 在工作记忆中的邻接节点
  $O_t \leftarrow$ 神经网络的区域预测
  $P_{t-1} \leftarrow$ 前一次迭代的区域概率
  $P_t \leftarrow \alpha O_t + (1-\alpha) P_{t-1}$ // 方程3
  $U_3 \leftarrow k_3$ 来自长期记忆、属于最可能区域的节点，根据 P_t
  检索 U_3
  当 大小$(WM) >$ N **do**
    $n \leftarrow$ 属于该区域的工作记忆节点根据 P_t，概率最低
    如果 n 不在 $U_1 \cup U_2$ **则** // U1 和 U2 中的节点已免疫
      转移 n
结束条件判断
  结束循环
结束过程

每一步中，都会从长期记忆中检索一组 k_1 节点，它们是工作记忆中最终成为最高回环假设的节点的时空邻居。我们的方法还会额外检索属于最可能区域的其他 k_3 节点。此时，属于较不可能区域的节点会被转移回长期记忆，但不包括当前周期检索到的 k_1 邻居，以及工作记忆中 v 已有节点的 k_2 邻居（这些节点已免疫），直到工作记忆的大小等于 N。

V. 实验

我们设计了两类实验来评估所提出方法的有效性。第一类旨在估计神经网络在机器人重新访问已知地点时预测正确区域的能力。第二类通过比较原版 RTAB-Map 与修改版，考察回环检测的准确性。为确保实验可复现并便于未来进行比较，我们将公开开展实验所需的所有数据（包括人工和自动标注）及代码。

在实验中，我们使用了三个数据集。前两个数据集在同步定位与建图领域广为人知且应用广泛：

- **OpenLoris**：OpenLoris-Scene 数据集 [16],专为终身 SLAM 创建，包含多个室内序列，这些序列的环境条件各不相同，且移动人群的出现带来了更多变化和遮挡。
- **KITTI**：KITTI 里程计数据集 [17], 是一个室外数据集，包含 22 个序列（其中 11 个序列带有真实值，用于调整 / 训练算法，另外 11 个序列不带真实值

用于测试这些算法），这些数据是在城市和乡村环境中使用立体相机和 3D Velodyne 激光雷达采集的；第三个数据集（记为 **Campus**）使用由 Xaxxon 自动巡检机器人采集的序列构建，[18]该机器人配备了二维旋转式激光雷达和 Intel D435 深度相机（见图 6），并在我们大学校园的三条走廊中行驶。本文的实验仅使用 RGB 数据进行区域预测。

A. 预测准确率

对于第一类实验，我们使用了 Campus 和两个 OpenLoris 数据包，其中机器人在不同序列中行经相同地点：

- Market 数据包包含在大型市场内采集的三个序列，各序列的光照条件相对一致；
- Corridor 数据包包含沿一条带有大型窗户的走廊采集的五个序列，各序列的光照条件差异显著（包括关闭人工照明的情况）。

由于缺少重访相同地点的序列，此处未使用 KITTI。对于 OpenLoris 和 Campus，我们使用第一个序列训练神经网络，其余序列用于测试。训练序列与测试序列之间的区域配对通过人工识别：对图像进行视觉匹配，并分配一致的区域标签。

这些实验采用 Top-1 和 Top-3 错误率指标，因为它们能体现网络预测正确区域的能力，以及捕捉不同区域之间相似性的能力。

表 I 展示了结果。在 OpenLoris Market 和 Campus Corridors 序列中，Top-3 准确率表现良好，表明正确区域几乎总是位于可能性最高的三个预测结果之中，因此其节点很有可能从工作记忆（WM）中检索出来。有时，错误区域可能会被预测为 Top-1；不过，在某些情况下，这种行为甚至是可取的，有助于应对区域之间的相似性。

由于光照条件变化剧烈（示例见图7），OpenLoris 的 Corridor序列上的预测准确率并不理想。为应对这种变化，有必要持续进行区域预测学习，正如第VI节所述。



图 6. 用于采集 Campus 数据集的 Xaxxon 自动爬行机器人。

表 I Top-1 和 Top-3 区域预测准确率

序列	Top-1 准确率	Top-3 准确率
OpenLoris/Market 1-2	0.81	0.92
OpenLoris/Market 1-3	0.79	0.93
OpenLoris/Corridor 1-2	0.27	0.45
OpenLoris/Corridor 1-3	0.06	0.14
OpenLoris/Corridor 1-4	0.17	0.44
OpenLoris/Corridor 1-5	0.65	0.90
Campus/Corridor-Biolab 1-2	0.53	0.79
Campus/Corridor-DEI 1-2	0.47	0.77
Campus/Corridor-Arc 1-2	0.33	0.76

每个序列名称末尾的编号 x-y 表示预测器在序列 x 上进行训练，并在序列 y 上进行测试。

B. 回环检测

在回环检测实验中，除了 OpenLoris Market 数据包和 Campus序列外，我们还使用了包含回环的 KITTI序列 00-10。参见算法1，RTAB-Map 的工作记忆（WM）大小被限制为 $N = 50$ 个节点（约为所考虑序列平均大小的 15%），以模拟大规模环境探索场景：此时只有部分地图节点能够存储在 WM 中。参数 k_1 和 k_2 分别设为 RTAB-Map 的默认值 2 和 0.25（即 25%；$\times N = 12$ 个 WM 中的邻接节点无法转移到长期记忆（LTM），从而避免转移过于近期的节点）。根据这些约束，$k_3 = N - k_1 - k_2$。

由于 KITTI 和 OpenLoris 的机器人真实位姿已知，我们实现了一种简单算法，用于匹配不同序列中的位姿，从而自动识别对应关系（进而确定回环候选项）。具体而言，如果两个位姿在二维平面上的位置 (x,y) 之间的距离，以及它们在二维平面上的角度差，均小于给定的两个阈值，则认为这两个位姿匹配。

如表 II所示，我们的方法能够识别所有序列中的全部回环（除一个序列外），回环检测率达到 95%，即使工作记忆非常有限也是如此。相比之下，RTAB-Map 默认的内存管理机制仅能在 15% 的情况下检测到回环，因为在大型地图中导航时，空间与时间接近准则可能并不理想。

OpenLoris 序列通常在单个序列中没有回环闭合，但在不同序列中，机器人会返回相同地点并可以进行重定位（见表 III）。为处理这些情况，RTAB-Map 允许在新序列



图 7. 左图为 OpenLoris 的第一个 Corridor序列中的图像，光照条件良好；右图为第四个序列中同一条走廊的图像，此时人工照明已关闭。

表 II 回环闭合检测结果

序列	回环数量闭合	检测到的回环	
		RTAB-Map 基线	Our
KITTI/00	4	1	**4**
KITTI/02	2	0	**2**
KITTI/05	3	0	**3**
KITTI/06	1	0	**1**
KITTI/07	1	1	1
KITTI/09	1	0	**1**
Campus/Corridor-Biolab 1-2	2	0	**2**
Campus/Corridor-DEI 1-2	2	0	**2**
Campus/Corridor-Arc 1-2	3	1	**2**
OpenLoris/Market 1-3	1	0	**1**
总计 20	3(15%)	**19 (95%)**	

对于 Campus 和 OpenLoris，每个序列名称末尾的 x-y 编号表示预测器在序列 x 上训练，并在序列 y 上测试。

表III 重定位结果

序列	重定位次数	重定位已执行	
		RTAB-Map 基线	Our
OpenLoris/Market 1-2	3	1	**3**
OpenLoris/Market 1-3	3	1	**3**
总计 6	2(33%)	**6 (100%)**	

每个序列名称末尾的 x-y 编号表示预测器在序列 x 上训练，并在序列 y 上测试。

开始时重新加载工作记忆中的全部内容，或者仅重新加载上一次探索结束时的工作记忆。为将工作记忆限制在 50 个节点以内，我们选择了后者。

最后值得注意的是，即使我们的节点预选完全准确（即始终确保正确的节点位于工作记忆中），所用同步定位与建图算法自身的回环检测算法仍可能因相应特征签名的相似度不足而漏检某些回环。对结果进行事后分析后发现，我们的方法在表II 中唯一漏检的回环就属于这种情况。

VI. 结论与未来工作

在这项工作中，我们提出了一种区域预测技术：利用地图聚类将节点划分为不同区域，并训练深度模型来预测机器人当前正在行进的区域。这种方法能够高效实现地点识别，用于实时回环检测。实验验证了这一思路的有效性，但仍有一些问题尚待解决。事实上，所提出的技术在某些实际场景中已经具有实用价值，例如预测器在离线状态下基于累积的全部地图知识重新训练；但其自然的发展方向，是实现终身 SLAM 所要求的在线持续学习。为此，模型需要以增量方式学习新区域，以及已知区域的新实例（例如昼夜变化），同时不遗忘旧知识（在持续学习术语中，这种情形称为 NIC [19]）。我们以往在持续学习方面的经验使我们相信这一目标是可行的：尤其是，潜在回放技术 [20]似乎非常适用于这一场景，因为它们能够仅存储过去数据的少量潜在表示来更新模型。

参考文献

[1] C. Cadena、L. Carlone、H. Carrillo、Y. Latif、D. Scaramuzza、J. Neira、I. Reid 和 J. Leonard，（2016），“《同时定位与建图：现状、未来与鲁棒感知时代》”，IEEE机器人学汇刊。32。10.1109/TRO.2016.2624754。[2] S. B. Nashed，“《回环检测简要综述：重新思考智能系统评估的理由》”，NeurIPS 2020研讨会：机器学习回顾、综述与元分析（ML-RSA），2020。[3] M. Labb´e，“RTAB-Map：用于大规模、长期在线运行的开源激光雷达与视觉同步定位与建图库”，《现场机器人学期刊》，第36卷，第2期，第416–446页，2019。[4] M. Labb´e、F. Michaud，“面向大规模、长期运行的实时基于外观的回环检测”，IEEE机器人学汇刊，第29卷，第3期，第734–745页，2013。[5] F. Fraundorferh、C. Wu、J.M. Frahm 和 M. Pollefeys，“使用距离增强加权法在三维模型中进行基于视觉词的地点识别”，第4届国际3D数据处理、可视化与传输研讨会，2008年，第1–8页。[6] D. Scaramuzza 和 F. Fraundorfer，“视觉里程计 [教程],”，载于 IEEE机器人与自动化杂志，第18卷，第4期，第80–92页，2011年12月，doi：10.1109/MRA.2011.943233。[7] S. F. G. Ehlers、M. Stuede、K. Nuelle 和 T. Ortmaier，“面向大规模室内外区域同步定位与建图的地图管理方法”，2020年IEEE国际机器人与自动化会议（ICRA），第9652–9658页。[8] S. Arshad、G.W. Kim，“深度学习在视觉与激光雷达同步定位与建图回环检测中的作用：综述”，《传感器》2021年，第21卷，第4期。[9] C. Masone、B. Caputo，“深度视觉地点识别综述”，IEEE 2021年，第9卷。[10] D. Gao、C. Wang 和 S. Scherer，“AirLoop：终身回环检测”，2022年国际机器人与自动化会议（ICRA）。[11] P. Yin、A. Abuduweili、S. Zhao、C. Liu 和 S. Scherer，“BioSLAM：用于通用地点识别的仿生终身记忆系统”，2022年。[12] D. Maio、D. Maltoni 和 S. Rizzi，“自主智能体中的地图动态聚类”，IEEE模式分析与机器智能汇刊，第18卷，第11期，第1080–1091页，1996年。[13] M. Sandler、A. Howard、M. Zhu、A. Zhmoginov 和 L.C. Chen，“MobileNetV2：倒置残差与线性瓶颈”，2018年。[14] R. Arandjelovi´c、P. Gron´at、A. Torii、T. Pajdla 和 J. Sivic，“NetVLAD：用于弱监督地点识别的卷积神经网络架构”（CoRR），2015年。[15] A. Khaliq、S. Ehsan、Z. Chen、M. Milford 和 K. McDonald-Maier，“一种整体式视觉地点识别方法：采用轻量级卷积神经网络，应对显著的视点与外观变化”，IEEE机器人学汇刊，第36卷，第2期，第561–569页，2020年4月，doi：10.1109/TRO.2019.2956352。[16] X. Shi、D. Li、P. Zhao、Q. Tian、Y. Tian、Q. Long、C. Zhu、J. Song、F. Qiao、L. Song、Y. Guo、Z. Wang、Y. Zhang、B. Qin、W. Yang、F. Wang、R. H. M. Chan 和 Q. She，“我们准备好迎接服务机器人了吗？用于终身同步定位与建图的 OpenLORIS 场景数据集 ”，第 3139–3145 页，2020 年。[17] A. Geiger、P. Lenz 和 R. Urtasun，“我们准备好迎接自动驾驶了吗？KITTI视觉基准套件”，计算机视觉与模式识别会议（CVPR），2012年。[18]Xaxxon，Xaxxon AutoCRAWLER自主机器人，http://www.xaxxon.com/xaxxon/autocrawler。[19]T. Lesort、V. Lomonaco、A. Stoian、D. Maltoni、D. Fil-liat、N. D´ıaz-Rodr´ıguez，“机器人持续学习：定义、框架、学习策略、机遇与挑战”，2020年《信息融合》，第58卷，第52–68页，doi：https://doi.org/10.1016/j.inffus.2019.12.004。[20]L. Pellegrini、G. Graffieti、V. Lomonaco 和 D. Maltoni，“用于实时持续学习的潜在回放”，2020年IEEE/RSJ智能机器人与系统国际会议（IROS），美国内华达州拉斯维加斯，2020年，第10203–10209页，doi：10.1109/IROS45743.2020.9341460。