科学通报 2023 年 第 68 卷 第 35 期: 4872 ~ 4884
2023年度松山湖科学会议: 脑科学与类脑技术专题 论 文
《中国科学》杂志社 SCIENCE CHINA PRESS

面向具身智能的网格细胞群表征空间认知方法

柴清澳, 黄赣, 费一鸣, 马歌华, 章国锋, 唐华锦*

浙江大学计算机科学与技术学院, 杭州 310027

* 联系人, E-mail: htang@zju.edu.cn

2023-08-15 收稿, 2023-10-24 修回, 2023-10-26 接受, 2023-10-30 网络版发表
国家重点研发计划(2020AAA0105900)和国家自然科学基金(62236007)资助

摘要 与基于结构化场景建模的传统导航算法不同, 哺乳动物通过内嗅皮层和海马体中多种神经细胞的分工协作构建认知地图, 实现了适用于非结构化场景且具有强鲁棒性、泛化性的导航. 随着认知神经科学、人工智能等领域的发展, 类脑导航在近年来受到了广泛的关注, 成为实现"具身智能"中机器人环境认知与导航功能的可行方案. 本文结合大脑空间认知机理以及同时定位与地图构建算法, 提出了一种基于网格细胞群表征模型的移动机器人认知地图构建系统. 在该系统中, 网格细胞模型与位置细胞模型协同配合完成了位置表征、路径积分的功能. 基于公开真实数据集的实验, 验证了该系统在认知地图构建任务中的有效性与网格细胞群表征模型的度量特性. 此外, 这种脑启发式的认知地图构建系统为进一步揭示人脑的空间认知机理提供了有效的实验环境.

关键词 认知地图构建, 类脑导航, 具身智能, 网格细胞, 移动机器人, 同时定位与地图构建

具身智能(embodied intelligence)相对于传统认知科学中脱离实体的人工智能更加强调智能体自身物理结构对认知和行为的影响, 是一种受自然界中生物智能启发而产生的人工智能实现方式[1~4]. 近年来, 人工智能与机器学习领域的快速发展给具身智能领域带来了新的可能, 使其得到了与日俱增的关注. 空间认知与导航作为动物在自然环境下赖以生存的基础决定了动物的觅食、避险等多种行为, 也是实现具身智能过程中不可或缺的关键环节[5,6]. 然而, 如何在智能体中实现与动物类似的高效空间认知与导航仍然是悬而未决的问题.

基于结构化几何建模的传统导航算法在过去数十年间获得了长足发展, 并被广泛应用于各领域. 然而, 这类方法在复杂非结构化场景下难以取得令人满意的效果, 且其导航能力在不同场景下的泛化效果十分受限. 与传统导航算法相比, 动物以脑为基础的导航具有鲁棒性、泛化性强, 能耗低, 适用于非结构化场景等优点. 受动物空间认知机制的启发, 类脑导航(brain-inspired navigation)技术旨在通过模拟动物认知空间并完成导航的过程, 实现在非结构化复杂场景下的导航任务, 在近年来受到了越发广泛的关注[7~10]. 认知地图(cognitive map)是一种大脑内的表征, 提供个体以空间环境相对位置及属性的信息, 构建认知地图是类脑导航的基础, 决定了智能体对环境的认知、与环境的交互[11~13]. 随着认知神经科学的发展, 动物认知地图构建的生物学基础逐渐得以揭示, 使利用空间认知神经细胞模型构建认知地图的任务成为了可能[14].

尽管大脑的空间认知机制仍存在大量有待探索的问题, 现有的研究表明, 人与部分动物的空间认知和导航能力与大脑中海马体及内嗅皮层处包括位置细胞(place cell)、速度细胞(speed cell)、网格细胞(grid cell)、边界细胞(boundary cell)、头方向细胞(head di-

引用格式: 柴清澳, 黄赣, 费一鸣, 等. 面向具身智能的网格细胞群表征空间认知方法. 科学通报, 2023, 68: 4872–4884
Chai Q A, Huang G, Fei Y M, et al. A spatial cognition approach based on grid cell group representation for embodied intelligence (in Chinese). Chin Sci Bull, 2023, 68: 4872–4884, doi: 10.1360/TB-2023-0850

© 2023《中国科学》杂志社

rection cell)等在内的多种细胞的协作密切相关[15~19]. 图1展示了认知地图构建过程中的网格细胞、位置细胞和头方向细胞的放电模式. 位置细胞与头方向细胞分别负责动物空间位置与头部朝向的表征, 速度细胞的放电率与运动速度呈正相关, 边界细胞的活动对空间边界呈现敏感性. 位于内嗅皮层的网格细胞具有矢量导航、路径积分、空间度量等功能, 在二维空间中动物活动区域呈现出规律的六边形网格状放电模式[17], 其特征是放电位置与最邻近放电位置之间形成等边三角形, 进而形成六边形网格(如图1网格细胞G_0所示). 网格细胞这种规则的空间放电模式为认知地图提供了距离信息, 被视为大脑进行空间表征和导航的关键组成部分[20]. 网格细胞因其多样的功能与独特的放电模式被认为是大脑中的"GPS系统", 其发现者更是获得了2014年诺贝尔生理学或医学奖. 有关网格细胞表征模式建模的研究相继涌现, 包括目前主流的连续吸引子神经网络模型(continuous attractor neural network, CANN)与振荡干涉模型(oscillatory interference, OI)等[21~24], 同时, 基于网格细胞编码的导航算法陆续被提出[25~27].

网格细胞的发现为理解大脑如何表征和处理空间信息提供了关键线索, 有效推进了类脑导航领域的发展. 本研究提出了一种基于网格细胞编码的认知地图构建算法, 从类脑的视角完成了移动机器人实物平台上的认知地图构建任务, 为具身智能中空间认知与导航功能的实现提供了新思路, 有助于进一步揭示人脑空间认知的机理.

1 网格细胞计算模型

1.1 相关工作

自2005年网格细胞被发现[17]以来, 研究者们提出了大量的计算模型来解释网格细胞是如何形成周期性网格状放电模式以及实现路径积分功能的. 经典的模型主要分为两类: 神经元级别的建模——振荡干涉模型和网络级别的模型——连续吸引子神经网络模型. 此外随着近年来深度学习的发展, 一些神经网络模型[24,28]在被用于与位置相关的导航学习任务时也呈现出了网格状放电模式.

OI模型旨在对网格细胞进行神经元级别的建模, 它最开始被用于解释海马体位置细胞放电模式. O'Keefe和Recce[18]发现了位置细胞中存在的相位进动(phase precession)现象, 并使用振荡干涉模型来解释海马位置细胞的位置编码, 但模型存在一个明显的缺陷, 就是会产生周期性的放电模式, 而位置细胞只会在特定位置野放电. 之后随着网格细胞的发现, 振荡干涉模型被扩展到二维, 自然地用于网格细胞的建模中[29]. 振荡干涉模型利用膜电位振荡器频率的变化, 将有关运动速度和方向的信息转化为周期性网格模式, 如图2所示, 不同树突对应不同方向运动的振荡输入, 与细胞体

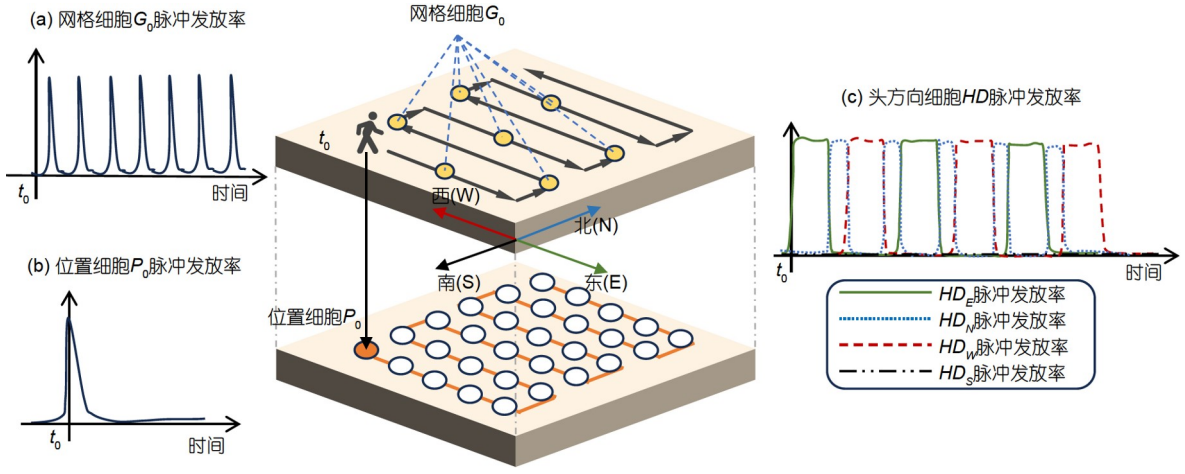


图 1 认知地图构建过程. 考虑人沿箭头所指示的轨迹运动的情景, 不同类别神经细胞的放电模式如图所示. (a) 同一网格细胞在二维平面上呈现出六边形的放电模式. (b) 空间中不同位置处有不同的位置细胞被激活. (c) 人面朝不同方向运动时有不同的头方向细胞被激活

Figure 1 Cognitive map construction. Consider a scenario where a person moves along the trajectory indicated by the arrows, and the firing patterns of different nerve cells are shown in the figure. (a) The same grid cell presents a hexagonal firing pattern on a two-dimensional plane. (b) Different place cells are activated at different locations. (c) Corresponding head-direction cells are activated when the person is facing in different directions

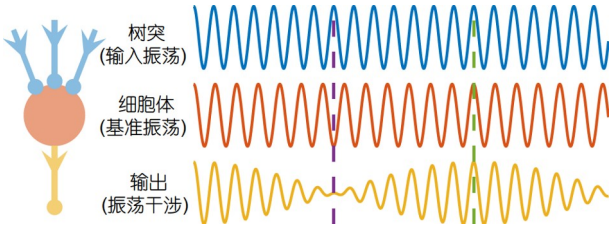


图 2 振荡干涉模型
Figure 2 Oscillatory interference model

的基准振荡相互干涉后形成周期性的输出. OI模型的一个问题是输入振荡器之间的夹角必须是60°, 但这样的设定并没有神经科学的发现或理论支撑.

CANN模型是另一类对网格细胞网络级别的建模, 可以从局部的网络活动中产生网格状放电模式. 吸引子网络可以通过吸引子状态来存储位置, 每一个吸引子都可被一组特定的外部刺激激活[30], 如果输入刺激在方向或空间表征中连续分布, 则会出现连续吸引子[31]. 如图3所示, 连续吸引子之间的连接方式类似墨西哥帽, 网络中距离相近的神经元存在较强的兴奋性连接, 距离较远的神经元存在抑制性连接, 这样的连接方式会形成与外部刺激相关的放电簇. CANN模型最早被用于建模头方向细胞和位置细胞, 在网格细胞发现后很快被修改来产生网格状周期性放电模式[32]. 通过连接边界的神经元形成二维环面连接, 避免了吸引子网络中的边缘效应, 使得网络中神经元放电模式更接近网格细胞的周期性网格状[33], 并且这种周期边界的吸引子可以完成精确的路径积分功能[23]. CANN模型中假设了神经元的排列与物理空间存在位置上的对应, 但这种排列和连接模式缺少神经科学的依据. 上述两种模型也都无法解释网格细胞为什么会形成网格状放电模式.

除了人工设计的模型能产生网格状放电模式, 近年来随着深度学习的发展, 在一些用于空间位置表征的神经网络的隐藏层中也出现了网格状放电模式. Dordek等人[34]构建了一个单层神经网络, 在利用Oja规则学习位置细胞放电模式时, 网格细胞呈现出了正方形网格状放电模式, 在添加非负约束后则变为六边形网格状放电模式. Cueva等人[28]构建了一个循环神经网络(recurrent neural network, RNN)用于路径积分任务的学习, 发现了在正方形环境中训练可以得到正方形网格状放电模式, 而在三角形环境中则得到六边形网格状放电模式. 在同样的任务上, Deepmind使用长短期记忆神经网络模型(long short-term memory, LSTM), 也观察到了类似网格状的放电模式[24]. 以上模型虽然都产生了类似网格状放电模式, 但缺少可解释性, 无法说明网格细胞的度量特性.

Gao等人[35,36]提出了一个网格细胞群表征模型, 使用一个高维向量表征网格细胞群, 使用矩阵来表征二维运动, 并通过局部和全局几何约束训练网络, 成功在模型隐藏层中观察到六边形网格状放电模式. 更进一步地, Dang等人[37]构建了基于三角函数的网格细胞群表征模型, 并从理论和实验上证明了其度量特性. 相较于OI、CANN这些人工设计的模型, 网格细胞群表征模型在没有假设傅里叶平面波的情况下通过优化算法自然地产生了六边形网格状放电模式, 且相较于RNN、LSTM这些神经网络模型有着更清晰的代数和几何意义, 并已经过理论和实验证明具有度量特性, 因此本文使用该模型来作为认知地图构建中网格细胞的表征模型.

1.2 网格细胞群表征模型

记智能体在二维空间的位置为$\boldsymbol{x}=(x_1, x_2)\in\mathbb{R}^2$, 我们

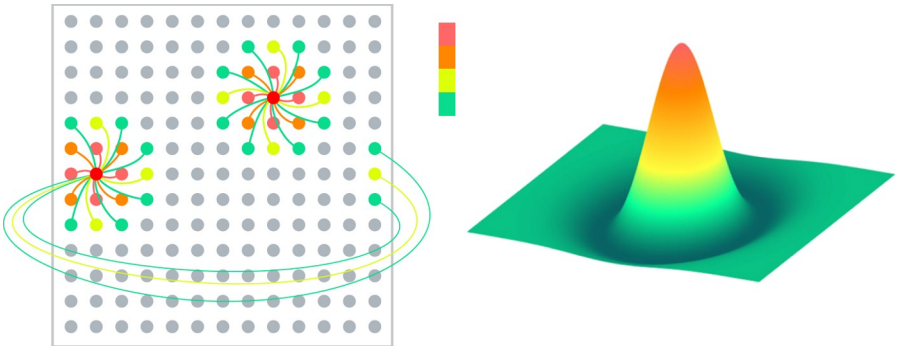


图 3 连续吸引子神经网络模型
Figure 3 Continuous attractor neural network model

可以用N个网格细胞的脉冲发放速率来表示该位置, 得到该位置的网格细胞表征向量$\boldsymbol{g}(\boldsymbol{x})=(g_1(\boldsymbol{x}), g_2(\boldsymbol{x}), \cdots, g_N(\boldsymbol{x}))^T\in\mathbb{R}^N$, 其中$g_i(\boldsymbol{x})$表示第$i$个网格细胞的脉冲发放速率, 则我们可以将网格细胞的建模表述为求解映射$\boldsymbol{g}$: $\mathbb{R}^2\to\mathbb{R}^N$的过程.

当智能体在二维空间移动$\Delta\boldsymbol{x}=(\Delta x_1, \Delta x_2)$到达位置$\boldsymbol{x}+\Delta\boldsymbol{x}$时, 其对应网格细胞表征向量从$\boldsymbol{g}(\boldsymbol{x})$变换至$\boldsymbol{g}(\boldsymbol{x}+\Delta\boldsymbol{x})$, 用一个函数$T$来表示该过程: $\boldsymbol{g}(\boldsymbol{x}+\Delta\boldsymbol{x})=T(\boldsymbol{g}(\boldsymbol{x}), \Delta\boldsymbol{x})$, 那么$T$应满足以下条件:

$$\begin{cases} T(\boldsymbol{g}(\boldsymbol{x}), 0)=\boldsymbol{g}(\boldsymbol{x}) \\ T(\boldsymbol{g}(\boldsymbol{x}), \Delta\boldsymbol{x}_1+\Delta\boldsymbol{x}_2)=T(T(\boldsymbol{g}(\boldsymbol{x}), \Delta\boldsymbol{x}_1), \Delta\boldsymbol{x}_2) \end{cases}. \tag{1}$$

我们用一个矩阵$\boldsymbol{M}(\Delta\boldsymbol{x})$来表示位移$\Delta\boldsymbol{x}$, 变换函数表示为$T(\boldsymbol{g}(\boldsymbol{x}), \Delta\boldsymbol{x})=\boldsymbol{M}(\Delta\boldsymbol{x})\boldsymbol{g}(\boldsymbol{x})$, 这样我们就建立起了二维物理空间的加法运算到$N$维网格细胞表征空间的乘法运算的映射.

进一步地, 我们考虑极坐标系下的运动$(\Delta r, \theta)$, 对于$\Delta\boldsymbol{x}=(\Delta r\cos\theta, \Delta r\cos\theta)$, 矩阵$\boldsymbol{M}(\Delta\boldsymbol{x})$可以由不同运动角度的矩阵组成, 记为$\boldsymbol{M}_\theta(\Delta\boldsymbol{r})$, 那么前述的变换过程可以表示为$T(\boldsymbol{g}(\boldsymbol{x}), \Delta\boldsymbol{x})=T(\boldsymbol{g}(\boldsymbol{x}), \Delta r, \theta)=\boldsymbol{M}_\theta(\Delta\boldsymbol{r})\boldsymbol{g}(\boldsymbol{x})$.

对于θ方向上一个微小的运动δr, 我们对$T(\boldsymbol{g}(\boldsymbol{x}), \delta r, \theta)$在$\Delta r=0$处做一阶泰勒展开可得:

$$\begin{aligned} T(\boldsymbol{g}(\boldsymbol{x}), \delta r, \theta)&=T(\boldsymbol{g}(\boldsymbol{x}), 0, \theta)+T'(\boldsymbol{g}(\boldsymbol{x}), 0, \theta)\delta r+o(\delta r) \\ &=(\boldsymbol{I}+\boldsymbol{M}'_\theta(0)\delta r)\boldsymbol{g}(\boldsymbol{x})+o(\delta r), \end{aligned} \tag{2}$$

其中, $\boldsymbol{I}$是单位矩阵, $\boldsymbol{M}'_\theta(0)$是$\boldsymbol{M}_\theta(\Delta r)$在$\Delta r=0$时的导数, 我们记其为$\boldsymbol{B}(\theta)$. 对于运动$(\Delta r, \theta)$, 将其拆分为$L$个微小的运动$(\delta r, \theta)$, 其中$\delta r=\Delta r/L$. 当$L\to\infty$时, 可以得到:

$$\begin{aligned} T(\boldsymbol{g}(\boldsymbol{x}), \Delta r, \theta)&=\left(\boldsymbol{I}+\boldsymbol{B}(\theta)\left(\frac{\Delta r}{L}\right)+o\left(\frac{1}{L}\right)\right)^L\boldsymbol{g}(\boldsymbol{x}) \\ &\to e^{\boldsymbol{B}(\theta)\Delta r}\boldsymbol{g}(\boldsymbol{x}). \end{aligned} \tag{3}$$

在实际应用中, 为了便于计算, 我们对其进行二阶泰勒展开可得:

$$\begin{aligned} &T(\boldsymbol{g}(\boldsymbol{x}), \Delta r, \theta) \\ &=\left(\boldsymbol{I}+\boldsymbol{B}(\theta)\Delta r+\frac{1}{2}(\boldsymbol{B}(\theta)\Delta r)^2+o(\Delta r^2)\right)\boldsymbol{g}(\boldsymbol{x}). \end{aligned} \tag{4}$$

生物中的网格细胞根据表征尺度不同分为了不同的块, 相应我们构造出$\boldsymbol{g}(\boldsymbol{x})=(g_k(\boldsymbol{x}), k=1, 2, \cdots, K)$, $\boldsymbol{B}(\theta)=diag(\boldsymbol{B}_k(\theta), k=1, 2, \cdots, K)$. 至此就完成了对网格细胞的建模以及路径积分的实现, 网络中可学习的参数为$\boldsymbol{g}(\boldsymbol{x})$和$\boldsymbol{B}(\theta)$.

Dang等人[37]提出的三角函数基模型是上述模型的一个特解, 并且证明了网格细胞具有度量特性. 取$\boldsymbol{g}(\boldsymbol{x})=\boldsymbol{C}(e^{i\langle\boldsymbol{w}_j, \boldsymbol{x}\rangle}, j=1, 2, 3)^T$, 其中$\boldsymbol{C}$矩阵是任意酉矩阵, $(\boldsymbol{w}_j, j=1, 2, 3)$是3个2×2的旋转矩阵, 两两之间角度差为120°. 令$\boldsymbol{M}(\Delta\boldsymbol{x})=\boldsymbol{C}\boldsymbol{D}(\Delta\boldsymbol{x})\boldsymbol{C}^*$, 其中$\boldsymbol{D}(\Delta\boldsymbol{x})=diag(e^{i\langle\boldsymbol{w}_j, \Delta\boldsymbol{x}\rangle}, j=1, 2, 3)$, 就可以得到满足式的三角函数基模型. 进一步推导出网格细胞集群可以生成正定核, 由此可以证明基于三角函数基的网格细胞模型具备度量特性.

2 认知地图构建

上述网格细胞计算模型, 在计算机仿真中验证了真实网格细胞在空间表征过程中的神经活动, 为神经科学家进一步探索与揭示大脑空间认知的机制提供了有力的计算工具. 此外, 这些模型也可以被运用于实现高效的路径积分、位置表征, 从而在机器人认知地图构建及导航中发挥重要作用. 在机器人领域, 同时定位与地图构建(simultaneous localization and mapping, SLAM)算法通常被用于解决在未知环境中自定位和感知环境的问题. 相比于大脑中基于海马体-内嗅皮层的认知地图构建, SLAM算法可以实现更为精确的定位和建图, 但其在真实世界应用时却面临非结构化场景、动态场景、大尺度场景以及难以长期运行等挑战[38]. 研究大脑空间认知机制与机器人的结合有望解决这些挑战, 进而实现具有人类智能的机器人.

动物在未知环境中移动时, 会同时接收并整合多感官信息(如视觉、前庭等). 随后, 内嗅皮层的网格细胞对自运动进行路径积分, 并经过内嗅皮层—海马体神经环路的解码, 得到自身位置信息. 同时, 动物还从视觉信息提取到视觉特征, 并将这些信息与自身位置相关联, 存储在海马体位置细胞中, 形成对空间环境中的相对位置和相关属性的记忆[39], 即认知地图[40].

Milford等人[7]于2004年提出的RatSLAM是借鉴动物大脑进行认知地图构建的开创性工作, 该方法基于3个模块来模拟大鼠的空间认知机制: 局部视觉细胞(local view cell)用于感知视觉信息、位姿细胞(pose cell)用于位姿表征、经历地图(experience map)用于环境表征, 并完成了认知地图构建, 但其用于位姿表征的位姿细胞模块没有相关神经科学发现或理论支撑, 缺乏生物可解释性.

随着网格细胞的发现及其相关计算模型的提出, 大脑中有关空间认知的机制逐渐清晰, 开始有学者使

用网格细胞模型来进行定位和路径积分. Yuan等人[41]于2015年提出了一个基于内嗅皮层-海马体神经环路的认知地图构建方法, 该方法使用CANN对网格细胞进行建模, 并基于赫布规则(Hebbian learning rules)更新网格细胞与位置细胞的连接权重, 更具有生物可解释性. 但其在不同环境运行时都需要一段时间用于学习连接权重, 而且采用轮式编码器作为里程计输入, 容易受地面摩擦力或车轮空转影响产生定位误差.

2.1 系统架构

本文基于网格细胞群表征模型提出的认知地图构建系统架构如图4所示.

认知地图构建系统分为4个主要模块: 里程计、位置表征、视觉表征、认知地图构建与优化. 其中, 里程计模块接收来自惯性测量单元(inertial measurement unit, IMU)的加速度、角速度和来自相机的RGB图像, 并对IMU数据进行预积分和对图像进行特征跟踪, 输出两帧图像之间的自运动信息. 位置表征模块接收来自里程计的输出, 将运动方向和距离信息输入到网格细胞模型中进行路径积分得到当前位置的网格细胞群表征, 之后通过位置细胞模型解码出当前位置. 视觉表征模块接收来自相机的RGB图像, 并提取出表征当前环境特征的视觉模板. 认知地图构建与优化模块同时接收视觉模板和位置信息并建立关联记忆, 构建认知

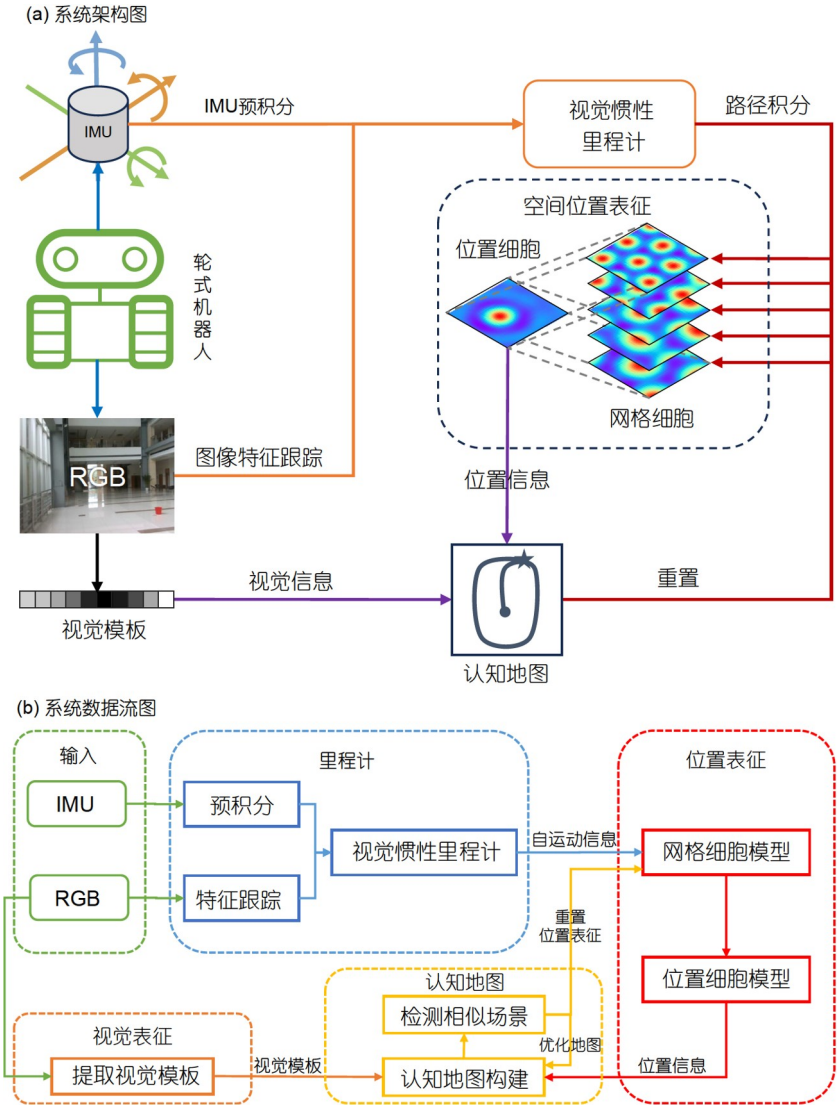


图 4 认知地图构建系统架构与数据流图. (a) 系统架构图. (b) 系统数据流图

Figure 4 Cognitive map construction system architecture and data flow diagram. (a) System architecture diagram. (b) Data flow diagram

地图. 此外, 该模块在检测到相似视觉模板时会对网格细胞模型和位置细胞模型进行重置, 并对整个认知地图进行优化.

2.2 里程计: 自运动信息

里程计是根据传感器采集数据来估计自身运动的算法. 基于特征的视觉里程计精度较高, 但受环境影响较大, 在缺少纹理信息的场景或高速运动时无法正常工作. 惯性里程计则不会受环境影响, 且有着非常高的采样频率, 但长时间工作会有非常大的累计误差. 本文选用的视觉惯性里程计(visual inertial odometry, VIO)是融合了相机图像数据和IMU数据的位姿估计算法, 使得两者可以很好的互补. 其中关键技术是IMU预积分和图像特征跟踪: 预积分解决了对图像帧之间的IMU数据进行积分时因初始状态改变而带来的重复积分问题[42,43], 实现了高频IMU数据的积分计算; 特征跟踪实现了对图像的特征点提取与匹配, 进而恢复出相机运动. 本文分别选用了VINS-Mono[44,45]和XRSLAM[46]两种视觉惯性里程计.

XRSLAM提出了一种全新的VIO系统, 旨在解决VIO跟踪中受外部运动物体干扰以及自身静止或纯旋转影响的问题. 为了有效地辨识移动的关键点, XRSLAM引入了IMU运动先验信息, 并通过其提出的自适应的IMU-PARSAC算法来优化动态物体的剔除过程. 为避免纯旋转引起的运动退化, 系统首先检测图像帧的运动类型, 并在纯旋转时延迟地图点三角化, 防止错误的深度估计. 与此同时, 系统还设计了带子帧窗口的滑窗优化, 以处理纯旋转数据并避免主滑动窗口规模扩大. 此外, 纯旋转子帧窗口还可通过位置约束来改善IMU零偏的估计.

2.3 网格细胞-位置细胞: 空间编解码

在空间位置信息编解码过程中, 1.2节的网格细胞群表征模型建立起了欧式空间到网格细胞群表征空间的映射, 并能完成路径积分功能, 而自身位置的估计则需要通过网格细胞与位置细胞的连接得到. 每一个网格细胞都与所有位置细胞相连接, 其连接权重可以通过仿真数据训练得到. 在二维空间中, 每一个网格细胞与$D\times D$个位置细胞相连接, 其连接权重矩阵可以看作该网格细胞的空间放电模式矩阵, 网格细胞的脉冲发放速率则决定了其放电模式的强度. 通过对网格细胞群体到位置细胞的连接累加可以得到位置细胞的脉冲发放速率, 脉冲发放速率最大的位置细胞即为估计位置.

系统运行时在网格细胞群表征空间进行路径积分的过程如下: 设初始位置为$\boldsymbol{x}_0=(0,\ 0)$, 可以得到相应网格细胞群表征向量为$\boldsymbol{g}^0$, 之后接收来自里程计的自运动信息$(\Delta r_1, \theta_1), (\Delta r_2, \theta_2), \cdots, (\Delta r_t, \theta_t)$, 可以由式(4)计算得到网格细胞群表征向量$\boldsymbol{g}^t$为:

$$\boldsymbol{g}^t=\left(\prod_{i=1}^{t}\left(\boldsymbol{I}+\boldsymbol{B}(\theta_i)\Delta r_i+\frac{1}{2}(\boldsymbol{B}(\theta_i)\Delta r_i)^2\right)\right)\boldsymbol{g}^0. \tag{5}$$

为了得到$\boldsymbol{g}^t$所对应的位置, 需要利用位置细胞来进行解码. 设位置细胞共有$D\times D$个, 每个位置细胞表征空间中一个位置, 并与所有N个网格细胞相连接, 连接权重矩阵为$\boldsymbol{W}(D\times D\times N)$, 则可以得到位置细胞脉冲发放速率矩阵$\boldsymbol{P}^t$为:

$$\boldsymbol{P}^t=\sum_{i=1}^{N}\boldsymbol{W}_i g_i^t, \tag{6}$$

其中, $\boldsymbol{W}_i(D\times D)$表示第$i$个网格细胞与位置细胞的连接权重矩阵, 也是该网格细胞的空间放电模式矩阵, g_i^t表示第i个网格细胞的脉冲发放速率. 那么估计位置$\hat{\boldsymbol{x}}^t$可以由下式计算得到:

$$\hat{\boldsymbol{x}}^t=\underset{x\in\mathbb{R}^2}{\operatorname{argmax}}\boldsymbol{P}^t. \tag{7}$$

2.4 视觉表征: 相似场景识别

进行路径积分的过程中会产生误差, 该误差随时间累积, 使得智能体的定位精度会随着时间逐渐下降. 因此我们引入了视觉信息来进行相似场景的检测. 在生物中也有类似的例子, 如大鼠在移动到相似场景时, 其网格细胞和位置细胞发放会进行重置以适应熟悉环境[32,47]. 本文中我们使用视觉模板来表征场景并识别场景的相似度.

记输入的RGB图像为$N\times M$的矩阵$\boldsymbol{I}^{\mathrm{RGB}}$, 首先将其转换为灰度图像$\boldsymbol{I}^{\mathrm{gray}}$, 之后通过计算相应的视觉模板$\boldsymbol{VT}$:

$$\boldsymbol{VT}=\frac{1}{N}\sum_{i=1}^{N}\boldsymbol{I}_i^{\mathrm{gray}}, \tag{8}$$

其中, $\boldsymbol{I}_i^{\mathrm{gray}}$表示图像$\boldsymbol{I}^{\mathrm{gray}}$的第$i$行, 这里把二维图像压缩成了一个向量, 之后对其做归一化:

$$\boldsymbol{VT}_i=\frac{\boldsymbol{VT}_i}{\sum_{i=1}^{M}\boldsymbol{VT}_i}. \tag{9}$$

给定两个视觉模板$\boldsymbol{VT}^a$、$\boldsymbol{VT}^b$, 通过下式来计算它

们之间的距离$D(\boldsymbol{VT}^a, \boldsymbol{VT}^b)$:

$$D(\boldsymbol{VT}^a, \boldsymbol{VT}^b) = \min_{\Delta x\in[-st,st]} \frac{1}{M-|\Delta x|} \times \sum_{i=1}^{M-|\Delta x|} \left|\boldsymbol{VT}^a_{i+\max(\Delta x,0)} - \boldsymbol{VT}^b_{i+\max(-\Delta x,0)}\right|, \quad (10)$$

其中, Δx表示匹配两个视觉模板时的偏移量, 允许2个视觉模板存在少量左右偏移的情况下也可被认为是相似场景; st表示偏移量的范围, 根据图像列数来设置, 本文的实验中设置为20. 当两个视觉模板的距离小于一定阈值T_{VT}时, 我们认为两个视觉模板表征的场景是相似的.

系统运行时图像是逐个输入的, 由此可以增量式构建视觉模板库. 只有新输入图像的视觉模板与前一帧图像的视觉模板的距离大于T_{VT}才作为新视觉模板加入视觉模板库, 否则就复用之前的视觉模板. 这保证了智能体在连续缓慢移动时, 视觉模板库不会大量增加重复视觉模板.

2.5 认知地图: 建图及优化

认知地图是对环境拓扑结构的表征, 由位置细胞和头方向细胞表征的位姿信息与视觉模板表征的视觉场景信息在海马体中形成关联记忆, 组成认知地图中的一个节点N^i:

$$N^i=\{\boldsymbol{VT}^i, \boldsymbol{P}^i\}, \quad (11)$$

其中, $\boldsymbol{VT}^i$是节点N^i关联的视觉模板, $\boldsymbol{P}^i$是N^i关联的位姿.

当智能体发生移动时, 会创建新的地图节点N^j, 并在认知地图中搜索距离最近的节点N^i并建立连接:

$$L^{ij}=\{\Delta\boldsymbol{P}^{ij}\}, \quad (12)$$

其中, 表$\Delta\boldsymbol{P}^{ij}$示两个节点之间的位姿差. 通过地图节点和节点连接, 我们构建了对环境中路标点的相对位置和相对关系的拓扑表达, 即完成了认知地图的构建.

当智能体当前节点N^{now}的视觉模板与视觉模板库比对得到的最小距离小于阈值T_{VT}, 且两个视觉模板的序号差大于一定阈值, 即存在两个节点在时间上相差较大但视觉信息相似时, 我们认为智能体移动到之前探索过的环境. 记视觉模板最小距离对应的地图节点为N^{sim}, 建立节点N^{now}, N^{sim}之间的连接并修改$\boldsymbol{P}^{\text{now}}=\boldsymbol{P}^{\text{sim}}$, 此时认知地图中出现了节点全局位置与节点间相对位置不一致的情况, 即$\Delta\boldsymbol{P}^{\text{sim_now}}\neq\boldsymbol{P}^{\text{now}}-\boldsymbol{P}^{\text{sim}}$, 需要对整个认知地图进行优化, 对每个节点及其连接节点的修正如下式所示:

$$\begin{cases}\boldsymbol{P}^i=\boldsymbol{P}^i+\alpha(\boldsymbol{P}^j-\Delta\boldsymbol{P}^{ij})\\ \boldsymbol{P}^j=\boldsymbol{P}^j-\alpha(\boldsymbol{P}^j-\boldsymbol{P}^{ij})\end{cases}, \quad (13)$$

其中, α表示修正系数, 过小会导致优化速度慢, 过大则会影响认知地图精度, 本文中设置为0.7. 优化过程以迭代的方式进行, 认知地图中存在的闭环误差会从$\Delta\boldsymbol{P}^{\text{sim_now}}$逐渐扩散到每个节点上, 迭代至一定次数后, 最终形成优化后的全局与局部相对一致的认知地图.

3 实验分析

3.1 实验设置

我们在实验前通过仿真位移数据对网格细胞群表征模型的网络参数进行训练. 为了验证网格细胞群表征模型的位置编码能力、路径积分能力以及其在实际场景中构建认知地图的性能, 实验中选取了M2DGR数据集[48], 这是一个由搭载了包括RGB相机和IMU在内的多种传感器的地面机器人采集的多个不同场景下的大规模数据集, 并且每段轨迹都提供了高精度的地面轨迹真值.

3.2 网格细胞-位置细胞空间编码分析

实验选取了M2DGR数据集中室内场景hall_01~hall_05五个序列的轨迹真值来验证网格细胞的位置编码和路径积分能力. 由于hall_02序列在前100 s时间内存在明显的定位误差, 因此实验中去除了前100 s的轨迹, 采用余下部分作为有效数据. 由于网格细胞表征的位置需要经过位置细胞解码后得到欧式坐标, 因此位置细胞数量会对其解码精度产生很大影响. 为了真实反映网格细胞的位置编码能力, 实验中将网格细胞数量固定为192, 分别设置了位置细胞的数量为1600(40×40)和6400(80×80). 实验结果如表1所示, 其中路径积分1对应1600个位置细胞, 路径积分2对应6400个位置细胞.

从表1中可以看出, 在网格细胞数量固定时, 增加位置细胞的数量可以等比降低路径积分平均误差, 说明网格细胞对位置表征的误差几乎可以忽略不计, 路径积分结果的误差来源主要是位置细胞在解码时由于其离散的对应空间点坐标而引入的. 为了更进一步地说明, 我们绘制了网格细胞每一步路径积分的结果以及与欧式坐标的误差对比, 如图5所示. 可以看出, 路径积分误差不会随着时间累积. 以

表 1 路径积分结果

Table 1 Results of path integration

轨迹序列	时长(s)	路径长度(m)	路径点个数	路径范围(m)	路径积分1平均误差(m)	路径积分2平均误差(m)
hall_01	363.85	214.03	2369	19.95	0.56	0.24
hall_02	211.33	94.01	1199	12.24	0.36	0.15
hall_03	186.74	144.65	1213	14.92	0.35	0.18
hall_04	190.45	91.51	1276	20.67	0.51	0.19
hall_05	408.37	285.51	2698	19.66	0.38	0.18

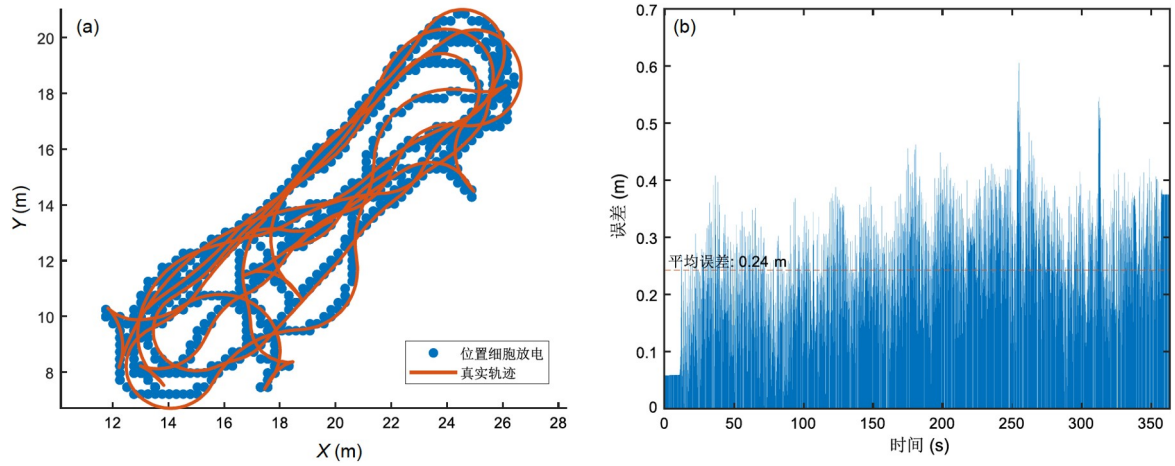


图 5 hall_01序列路径积分轨迹对比与误差. (a) 轨迹对比. 点表示位置细胞放电位置, 线表示真实轨迹. (b) 路径积分误差, 展示了随时间推移路径积分结果与真实位置之间的误差变化

Figure 5 Path integration trajectory and error in hall_01 sequence. (a) Trajectory comparison. Dots represent the firing locations of place cells, while the line represents the ground truth trajectory. (b) Path integration error, illustrating the error variation between path integration results and ground truth locations over time

上真实轨迹的路径积分实验表明网格细胞有着精确的位置表征和路径积分能力，可以用于认知地图构建任务.

尽管在我们使用的网格细胞群表征模型中，没有使用任何周期性或傅里叶平面波的假设，而仅仅从其功能上来对代数和几何做了相关约束，但是通过在路径积分任务上进行训练，我们仍然可以在隐藏层观察到清晰的六边形网格状放电模式(图6). 图6中绘制了hall_01序列的第100、200、300、400、500个位置时的真实轨迹、网格细胞路径积分轨迹、位置细胞放电模式和选取的16个块的网格细胞放电模式，从图中可以看出位置细胞只对特定位置响应值较高，而网格细胞则出现了周期性网格状的放电模式，表明我们使用的网格细胞群表征模型在弱约束的条件下可以通过训练学习到六边形网格状放电模式以及与位置细胞的连接权重.

网格细胞除了网格状放电模式这一特性外，还有空间度量特性[37]. 为了验证本文的网格细胞群表征模型也是空间的一个度量，我们随机生成了一条长度为30的轨迹，并计算轨迹点两两之间的核距离作为位置之间的度量值, 结果如图7所示. 可以看到, 在欧式空间距离较近的两个位置在网格细胞群表征空间距离也较近，反之亦然. 这一现象与距离函数的同一性相符，换言之，通过我们的建模方法构造的网格细胞具有良好的度量特性.

3.3 认知地图构建分析

虽然前述的网格细胞群表征模型可以实现对机器人自运动的精确路径积分，但视觉惯性里程计获取的自运动误差会随着机器人移动逐渐累积，使得位置发生漂移. 我们通过表征场景的视觉模板信息来识别相似场景并分散误差至各个地图节点上，由此可构建出

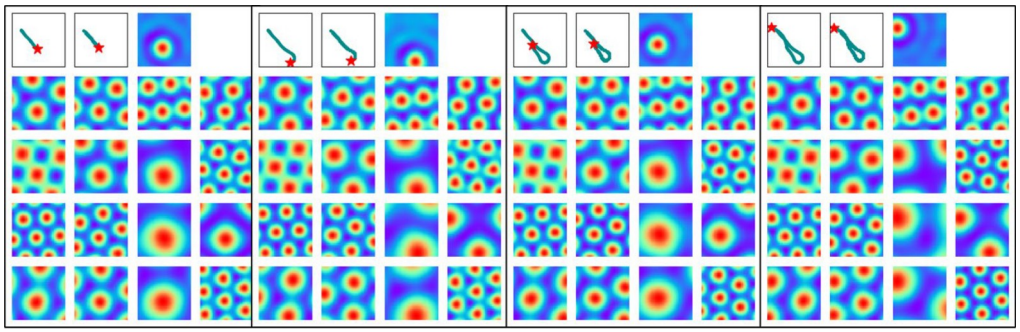


图 6 hall_01序列位置细胞及网格细胞放电模式
Figure 6 Place cell and grid cell firing patterns in hall_01 sequence

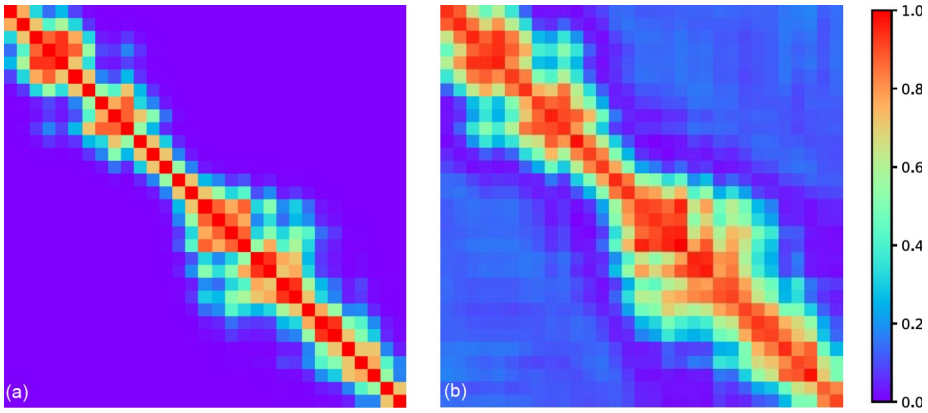


图 7 欧式空间与网格细胞群表征空间距离对比. (a)和(b)分别为欧式空间和网格细胞群表征空间中的轨迹点两两之间的核距离
Figure 7 Comparison of distance between Euclidean space and grid cell group representation space. (a) and (b) illustrate Kernel distances between pairwise trajectory points in Euclidean space and in grid cell group representation space, respectively

更高精度的认知地图. 实验使用XRSLAM作为VIO, 选取M2DGR数据集室内场景hall_05序列前110 s数据进行认知地图构建, 结果如图8所示, 其中虚线表示真实移动轨迹, (a)图实线表示原始VIO(XRSLAM)输出的轨迹, (b)图实线为系统构建的认知地图的轨迹. 从图中可以看出, 认知地图的轨迹更为接近真实轨迹, 说明引入视觉模板信息辅助认知地图优化有效地检测到了相似场景并提升了认知地图精度.

为了衡量轨迹精度, 我们使用evo工具(https://github.com/MichaelGrupp/evo)计算了ATE(absolute trajectory error)作为评价指标, 结果如表2所示. 从表中可以看出, XRSLAM相较于VINS-Mono的轨迹精度有较大提升(平均误差降低了37.68%), 而不论是采用VINS-Mono或XRSLAM作为视觉惯性里程计, 认知地图的轨迹精度都明显高于原始VIO的轨迹精度, 平均误差分别降低了48.91%和43.60%. 从以上实验结果可以看出, 通过结合基于网格细胞群表征模型的路径积分和基于视觉模板的相似场景识别, 可以实现一个具有生物可解释性且高精度的认知地图构建系统.

4 总结

网格细胞的位置表征和路径积分功能为机器人构建认知地图提供了有效机制. 本文基于网格细胞群表征模型实现了一个认知地图构建系统, 机器人在真实场景移动时可以通过网格细胞、位置细胞的放电来完成路径积分, 并联合视觉模板信息来构建认知地图. 针对现有认知地图构建系统中仅使用相机来进行位姿估计易受相机抖动或环境纹理影响精度的问题, 引入了IMU数据与视觉信息融合, 加强了位姿的约束. 在机器人平台上的实验验证了该系统在认知地图构建任务中的有效性, 其具备较高精度的路径积分和误差修正, 可以在真实场景中完成认知地图的构建. 实时性是认知地图构建系统在机器人平台上运行的关键问题, 认知地图优化过程涉及对所有位

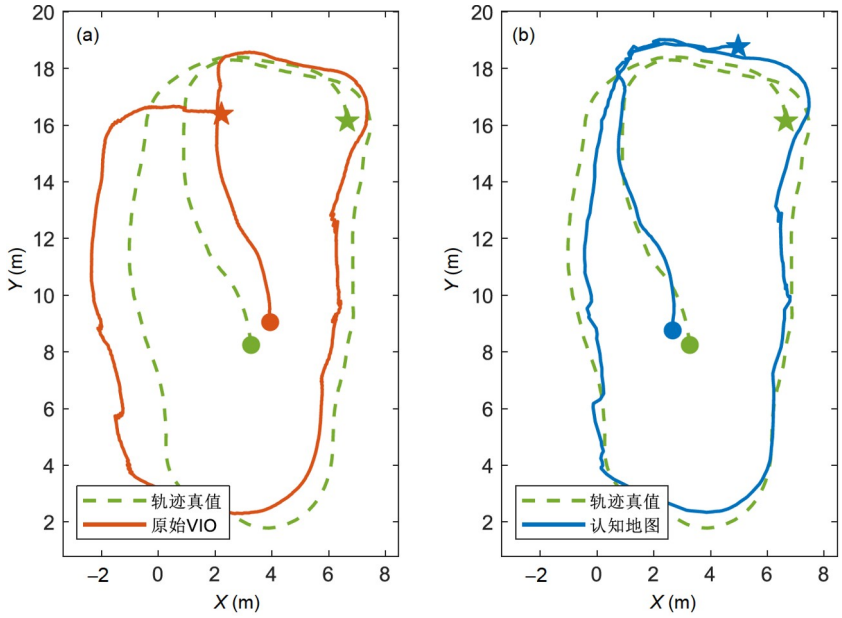


图 8 认知地图构建结果. (a) 原始VIO轨迹与轨迹真值对比. (b) 认知地图轨迹与轨迹真值对比. ●和★分别代表轨迹起点和终点

Figure 8 Cognitive map construction results. (a) Comparison between the original VIO trajectory and the ground truth trajectory. (b) Comparison between the cognitive map trajectory and the ground truth trajectory. ● and ★ represent the starting and ending points, respectively

表 2 轨迹误差对比[a)]

Table 2 Comparison of trajectory error

VIO方法	原始VIO		认知地图	
	VINS-Mono	XRSLAM	VINS-Mono	XRSLAM
最大误差(m)	4.95	3.74	6.37	**1.51**
平均误差(m)	2.76	1.72	1.41	**0.97**
中值误差(m)	2.65	1.63	1.18	**1.05**
最小误差(m)	0.38	**0.12**	0.15	0.14
RMSE(m)	2.94	1.87	1.84	**1.05**

a) 加粗部分表示最优结果

置点的修正, 是一项相对耗时的过程, 在长时间运行位置点数量较多时会影响实时性, 因此在保证认知地图精度的同时如何提高优化速度是未来的研究方向之一.

参考文献

1 Howard D, Eiben A E, Kennedy D F, et al. Evolving embodied intelligence from materials to machines. Nat Mach Intell, 2019, 1: 12–19

2 Gupta A, Savarese S, Ganguli S, et al. Embodied intelligence via learning and evolution. Nat Commun, 2021, 12: 5721

3 Pfeifer R, Scheier C. Understanding Intelligence. Cambridge: MIT Press, 2001

4 Starzyk J A. Motivation in Embodied Intelligence. London: INTECH Open Access Publisher, 2008

5 Pfeifer R, Bongard J. How The Body Shapes The Way We Think: A New View of Intelligence. Cambridge: MIT Press, 2006

6 Shapiro L. The Routledge Handbook of Embodied Cognition. London: Routledge, 2014

7 Milford M J, Wyeth G F, Prasser D. RatSLAM: A hippocampal model for simultaneous localization and mapping. In: Proceedings of the IEEE International Conference on Robotics and Automation, 2004. 403–408

8 Yu F, Shang J, Hu Y, et al. NeuroSLAM: A brain-inspired SLAM system for 3D environments. Biol Cybern, 2019, 113: 515–545

9 Qiao H, Chen J, Huang X. A survey of brain-inspired intelligent robots: Integration of vision, decision, motion control, and musculoskeletal systems. IEEE Trans Cybern, 2021, 52: 11267–11280
10 Hwu T, Krichmar J, Zou X. A complete neuromorphic solution to outdoor navigation and path planning. In: Proceedings of the 2017 IEEE International Symposium on Circuits and Systems (ISCAS), 2017. 1–4
11 Epstein R A, Patai E Z, Julian J B, et al. The cognitive map in humans: Spatial navigation and beyond. Nat Neurosci, 2017, 20: 1504–1513
12 Behrens T E J, Muller T H, Whittington J C R, et al. What is a cognitive map? Organizing knowledge for flexible behavior. Neuron, 2018, 100: 490–509
13 Peer M, Brunec I K, Newcombe N S, et al. Structuring knowledge with cognitive maps and cognitive graphs. Trends Cogn Sci, 2021, 25: 37–54
14 McNaughton B L, Battaglia F P, Jensen O, et al. Path integration and the neural basis of the 'cognitive map'. Nat Rev Neurosci, 2006, 7: 663–678
15 O′Keefe J, Dostrovsky J. The hippocampus as a spatial map: Preliminary evidence from unit activity in the freely-moving rat. Brain Res, 1971, 34: 171–175
16 Moser E I, Moser M B, McNaughton B L. Spatial representation in the hippocampal formation: A history. Nat Neurosci, 2017, 20: 1448–1464
17 Hafting T, Fyhn M, Molden S, et al. Microstructure of a spatial map in the entorhinal cortex. Nature, 2005, 436: 801–806
18 O'Keefe J, Recce M L. Phase relationship between hippocampal place units and the EEG theta rhythm. Hippocampus, 1993, 3: 317–330
19 Rank J B Jr. Head-direction cells in the deep layers of dorsal presubiculum of freely moving rats. In: Proceedings of the Soc Neuroscience Abstr, 1984. 10
20 Derdikman D, Moser E I. A manifold of spatial maps in the brain. Trends Cogn Sci, 2010, 14: 561–569
21 Burgess N, Barry C, O′Keefe J. An oscillatory interference model of grid cell firing. Hippocampus, 2007, 17: 801–812
22 Rowland D C, Roudi Y, Moser M B, et al. Ten years of grid cells. Annu Rev Neurosci, 2016, 39: 19–40
23 Burak Y, Fiete I R. Accurate path integration in continuous attractor network models of grid cells. PLoS Comput Biol, 2009, 5: e1000291
24 Banino A, Barry C, Uria B, et al. Vector-based navigation using grid-like representations in artificial agents. Nature, 2018, 557: 429–433
25 Bush D, Barry C, Manson D, et al. Using grid cells for navigation. Neuron, 2015, 87: 507–520
26 Erdem U M, Hasselmo M. A goal-directed spatial navigation model using forward trajectory planning based on grid cells. Eur J Neurosci, 2012, 35: 916–931
27 Edvardsen V, Bicanski A, Burgess N. Navigating with grid and place cells in cluttered environments. Hippocampus, 2020, 30: 220–232
28 Cueva C J, Wei X X. Emergence of grid-like representations by training recurrent neural networks to perform spatial localization. In: Proceedings of the International Conference on Learning Representations, 2018. arXiv: 1803.07770
29 O′keefe J, Burgess N. Dual phase and rate coding in hippocampal place cells: Theoretical significance and relationship to entorhinal grid cells. Hippocampus, 2005, 15: 853–866
30 Hopfield J J. Neural networks and physical systems with emergent collective computational abilities.. Proc Natl Acad Sci USA, 1982, 79: 2554–2558
31 Tsodyks M, Sejnowski T. Associative memory and hippocampal place cells. Intl J Neur Syst, 1995, 6: 81–86
32 Fuhs M C, Touretzky D S. A spin glass model of path integration in rat medial entorhinal cortex. J Neurosci, 2006, 26: 4266–4276
33 Samsonovich A, McNaughton B L. Path integration and cognitive mapping in a continuous attractor neural network model. J Neurosci, 1997, 17: 5900–5920
34 Dordek Y, Soudry D, Meir R, et al. Extracting grid cell characteristics from place cell inputs using non-negative principal component analysis. eLife, 2016, 5: e10094
35 Gao R, Xie J, Zhu S C, et al. Learning grid cells as vector representation of self-position coupled with matrix representation of self-motion. In: Proceedings of the International Conference on Learning Representations, 2018. arXiv: 1810.05597
36 Gao R, Xie J, Wei X X, et al. On path integration of grid cells: Group representation and isotropic scaling. Adv Neur Inform Proc Syst, 2021, 34: 28623–28635
37 Dang S, Wu Y, Yan R, et al. Why grid cells function as a metric for space. Neural Networks, 2021, 142: 128–137
38 Macario Barros A, Michel M, Moline Y, et al. A comprehensive survey of visual slam algorithms. Robotics, 2022, 11: 24
39 Chen G, King J A, Burgess N, et al. How vision and movement combine in the hippocampal place code. Proc Natl Acad Sci USA, 2013, 110: 378–383
40 Tolman E C. Cognitive maps in rats and men. Psychol Rev, 1948, 55: 189–208
41 Yuan M, Tian B, Shim V A, et al. An entorhinal-hippocampal model for simultaneous cognitive map building. In: Proceedings of the Proceedings of the AAAI Conference on Artificial Intelligence, 2015
42 Forster C, Carlone L, Dellaert F, et al. IMU preintegration on manifold for efficient visual-inertial maximum-a-posteriori estimation. In: Proceedings of the Robotics: Science and Systems, 2015. 586–592
43 Forster C, Carlone L, Dellaert F, et al. On-manifold preintegration for real-time visual–inertial odometry. IEEE Trans Robot, 2016, 33: 1–21

44 Qin T, Li P, Shen S. VINS-Mono: A robust and versatile monocular visual-inertial state estimator. IEEE Trans Robot, 2018, 34: 1004–1020
45 Qin T, Shen S. Online temporal calibration for monocular visual-inertial systems. In: Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018. 3662–3669
46 Li J, Pan X, Huang G, et al. RD-VIO: Robust visual-inertial odometry for mobile augmented reality in dynamic environments. 2023, arXiv: 2310.15072
47 Moser E I, Kropff E, Moser M B. Place cells, grid cells, and the brain's spatial representation system. Annu Rev Neurosci, 2008, 31: 69–89
48 Yin J, Li A, Li T, et al. M2DGR: A multi-sensor and multi-scenario SLAM dataset for ground robots. IEEE Robot Autom Lett, 2022, 7: 2266–2273

Summary for “面向具身智能的网格细胞群表征空间认知方法”

A spatial cognition approach based on grid cell group representation for embodied intelligence

Qing’ao Chai, Gan Huang, Yiming Fei, Gehua Ma, Guofeng Zhang & Huajin Tang*

College of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China
* Corresponding author, E-mail: htang@zju.edu.cn

Navigation, both in biological organisms and in artificial systems, is a complex process that requires an understanding of the environment and the ability to plan a route through it. While traditional navigation algorithms depend heavily on structured scene modeling, mammals demonstrate a more robust approach. They generate cognitive maps using a combination of different neuron types in the entorhinal cortex and hippocampus and thus achieve effective navigation through unfamiliar or unstructured terrains with ease and robustness. Therefore, the robustness of mammals in navigating through diverse environments suggests that a brain-inspired approach may offer superior performance in unstructured or dynamic terrains, particularly for mobile robots. Recent progress in cognitive neuroscience and artificial intelligence has shed light on the potential benefits of brain-inspired navigation. Given the benefits, there has been an increasing interest in applying insights from neuroscience to robotic systems. This fusion of fields is not only expected to enhance the capabilities of robots but also provide a deeper understanding of the mammal brain′s spatial cognition mechanisms. In the presented study, we propose a novel cognitive map construction system tailored for mobile robots based on a grid cell group representation model, combining spatial cognitive mechanisms of the brain with simultaneous localization and mapping (SLAM) algorithms. In this system, the grid cell and place cell model collaborate to accomplish place representation and path integration. While the place cells are crucial for representing the spatial layout of the environment, the grid cells function as a spatial metric and perform path integration. In the grid cell group representation model, the grid cell group is characterized by a high-dimensional vector and the movements in two-dimensional space are represented using a matrix. Compared to the continuous attractor neural network (CANN) model, the oscillation interference (OI) model, and models based on recurrent neural networks, this model naturally generates hexagonal grid-like firing patterns and offers a clearer geometric and algebraic interpretation. The combination of grid cells and place cells model allows the robot to understand its surroundings and its location more effectively. To validate our proposed system, it is verified using publicly available real-world datasets and the results were promising. The metric characteristics of the grid cell group model were clearly observable, confirming its suitability in representing space in a manner analogous to mammalian brains. More importantly, the experiments showcased the system’s capability in constructing a cognitive map. Beyond its application in robotic navigation, our brain-inspired design offers another advantage. It presents an opportunity to delve deeper into the spatial cognitive mechanisms of the mammalian brain. By creating models that emulate these mechanisms, we not only propose a novel cognitive map construction system but also pave the way for a more comprehensive understanding of mammalian cognitive processes. In conclusion, our study underscores the potential of a spatial cognition approach based on grid cell group representation. By combining insights from neuroscience with modern robotic algorithms, we are a step closer to achieving truly embodied intelligence of mobile robots.

cognitive map construction, brain-inspired navigation, embodied intelligence, grid cell, mobile robot, simultaneous localization and mapping

doi: 10.1360/TB-2023-0850