

DOI:10.11992/tis.201704038

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20170705.1653.002.html>

一种融合 DGSOM 神经网络的仿生算法研究

许瞳, 凌有铸, 陈孟元

(安徽工程大学 安徽省电气传动与控制重点实验室, 安徽 芜湖 241000)

摘要: 基于生理学和脑科学研究成果提出的 SOM 神经网络仿生优化方法能够通过学习自主绘制出拓扑地图, 但需通过大量的尝试确定其初始网络结构, 无法保证系统的实时性。提出一种方向信息和特征信息构建的动态增长自组织特征网 DGSOM, 通过引入方向参数减少网络的训练次数, 降低了系统复杂度, 通过引入特征参数避免了感知混淆, 并将该神经网络模型应用于澳大利亚 Milford 等提出的 RatSLAM 模型中。实验表明, 提出的 DGSOM-RatSLAM 模型通过减少视觉细胞的数量降低系统的复杂度; 通过视觉细胞的场景匹配实验和位姿细胞的活性状态实验证明该模型能够更快地实现闭环检测, 提出的 DGSOM-RatSLAM 模型的准确率、召回率及 F_1 值分别为 94.74%、86.88% 和 90.64%, 高斯噪声干扰下 Gauss-DGSOM-RatSLAM 模型的准确率、召回率及 F_1 值分别为 86.70%、80.25%、83.35%。

关键词: RatSLAM 模型; DGSOM 神经网络; 同步定位与地图构建; 闭环检测; 准确率; 召回率

中图分类号: TP242.6; TP183 **文献标志码:** A **文章编号:** 1673-4785(2017)03-0405-08

中文引用格式: 许瞳, 凌有铸, 陈孟元. 一种融合 DGSOM 神经网络的仿生算法研究[J]. 智能系统学报, 2017, 12(3): 405-412.

英文引用格式: XU Tong, LING Youzhu, CHEN Mengyuan. A bio-inspired algorithm integrated with DGSOM neural network[J]. CAAI transactions on intelligent systems, 2017, 12(3): 405-412.

A bio-inspired algorithm integrated with DGSOM neural network

XU Tong, LING Youzhu, CHEN Mengyuan

(Anhui Key Laboratory of Electric Drive and Control, Anhui Polytechnic University, Wuhu 241000, China)

Abstract: Based on physiology and brain science, self-organizing-map (SOM) neural networks can learn and autonomously draw topological maps, but the initial SOM network structure must be repeatedly tested, so the real-time characteristics of the system cannot be assured. In this paper, we built a dynamic growing self-organizing map (DGSOM) based on direction and feature parameters that reduces network training times by the introduction of the direction parameter and decreases system complexity and avoids perceptual aliasing by the introduction of the feature parameter. By introducing the feature parameter, we can avoid perception confusion. We applied the proposed model to the view cells of the simultaneous localization and mapping system (SLAM) known as RatSLAM, proposed by Milford et al. Our experimental results show that the proposed DGSOM-RatSLAM model can decrease the complexity of the system by reducing the quantity of view cells and realize closed-loop detection earlier by matching the scene with view cells and detecting on the activity of the pose cells. We found the precision rate, recall rate, and F_1 value of the DGSOM-RatSLAM model to reach 94.74%, 86.88%, and 90.64%, respectively, and those of the Gauss-DGSOM-RatSLAM model to reach 86.70%, 80.25%, and 83.35%, respectively.

Keywords: RatSLAM model; DGSOM neural network; simultaneous localization and mapping; closed-loop detection; precision rate; recall rate

在生物神经系统中, 存在着一种侧抑制现象, 一个神经细胞的兴奋会对周围其他神经细胞产生

抑制作用, 这种抑制作用会使神经细胞之间出现竞争, 从而造成神经细胞的兴奋或抑制。1982 年芬兰 Helsinki 大学的 T. Kohonen 教授^[1] 基于这种现象提出一种自组织特征图 (self-organizing feature map,

SOM),并引入赢者通吃(winner take all, WTA)理论,该仿生优化方法通过学习能够自主绘制出拓扑地图,但需通过大量的尝试确定其初始网络结构,无法保证系统的实时性能,研究者们基于该模型的缺陷进行了改进。1993年Martinetz等^[2]提出一种神经气(neural gas, NG)模型,提高了网络自组织学习过程的效率。2004年尹峻松等^[3]为克服SOM孤立学习与噪声敏感等缺陷,结合一氧化氮(NO)扩散机理,在SOM网中引入时间增强机制,提出了一种新型扩散的自组织模型(diffusing self-organizing maps, DSOM)。2009年王春东等^[4]将SOM理论运用于信息学,利用灰色关联系数(grey relational coefficient, GRC)调整权重,检测拒绝服务攻击(denial of service, DOS)。2011年于乃功等^[5]将可增长特征映射图(growing self-organizing map, GSOM)融入双目立体视觉,通过自组织拓扑结构避免了传统SOM网需大量实验才能确定的初始网络结构。本文以GSOM神经网络模型为基础引入了方向参数和特征参数构成的动态增长自组织特征图(dynamic growing self-organizing feature map, DGSOM),并应用于澳大利亚Milford等^[6-9]提出的RatSLAM模型中。

1 RatSLAM 模型

由于传感器和环境的不确定性,移动机器人利用概率解决同步定位与地图构建问题。其中,卡尔曼滤波、极大期望估计和粒子滤波3种概率算法是当前移动机器人SLAM的核心技术,其通过专用网格或拓扑地图的方式进行环境描述,这些研究成果在仿真和限定条件下能够取得良好效果,但难以兼顾实际环境,且存在计算量大、搜索时间长、易于陷入局部最优解等问题。

鼠类是生物医学研究最多的动物之一^[10-11],人们对于其导航、环境探索和真实神经机制的模拟理解得很好,因此鼠类成为科学家们创造生物系统人工模型的原型。

经过不断的研究探索, Milford 等提出一种基于鼠类导航细胞的扩展海马模型 RatSLAM, 该模型包括位姿细胞、视觉细胞以及经验图3部分,通过一维头方向细胞和二维位置细胞合并形成的三维位姿细胞表征当前位置,利用一维视觉细胞在环境中学习独特场景,通过位姿细胞和视觉细胞链路编码共同构建拓扑化的经验图,其经验 E 包含关于视觉细胞 V 、位姿细胞 P 和位置间拓扑关系 d , 定义 $E = \langle V, P, d \rangle$ 。

1.1 位姿细胞的活性状态变化

创建的兴奋度权重矩阵 ε_{abc} 和由于兴奋性使位姿感知细胞活动产生的变化 $\Delta P_{x'y'\theta'}$ 如式(1)和式(2)所示:

$$\varepsilon_{abc} = \frac{1}{k_{x'y'} \sqrt{2pk_q}} \varepsilon^{-\frac{(a^2+b^2)}{k_{x'y'}}} \varepsilon^{-\frac{c^2}{k_{\theta'}}} \quad (1)$$

$$\Delta P_{x'y'\theta'} = \sum_{a=0}^{N_{x'}} \sum_{b=0}^{N_{y'}} \sum_{c=0}^{N_{\theta'}} \varepsilon_{(a-x')(b-y')(c-\theta')} P_{abc} - \varphi \quad (2)$$

式中: $k_{x'y'}$ 和 $k_{\theta'}$ 分别为位姿感知细胞平面 (x', y') 和 θ' 维中对应着兴奋性一维分布的方差常数; a, b, c 分别为 x', y', θ' 的分布系数; $N_{x'}, N_{y'}, N_{\theta'}$ 分别为 (x', y', θ') 空间中的位姿感知细胞三维矩阵元素; 抑制常数 φ 控制全局抑制水平, 使兴奋度被限制在非负范围内。

1.2 视觉细胞的场景学习及位姿关联

一维视觉细胞通过视觉关联影响位姿细胞活性状态, 其连接强度 $a_{ix'y'\theta'}^{i+1}$ 如式(3)所示:

$$a_{ix'y'\theta'}^{i+1} = \{P_{x'y'\theta'}, V_i\} \quad (3)$$

视觉细胞关联下的位姿细胞网络活性如式(4)所示:

$$\Delta P_{x'y'\theta'} = \delta \sum_i a_{ix'y'\theta'} V_i \quad (4)$$

式中 δ 为视觉校准加强常数。

1.3 经历图的构建

经验 E 、编码位姿细胞 P 、视觉细胞 V 和经历间的拓扑关系 d 如式(5)所示:

$$E = \{P, V, d\} \quad (5)$$

拓扑关系 d 如式(6)所示:

$$\Delta d_i = \alpha \left[\sum_{j=1}^{N_f} (d_j - d_i - \Delta P_{ij}) + \sum_{k=1}^{N_i} (d_k - d_i - \Delta P_{ki}) \right] \quad (6)$$

式中: α 为学习常量; N_f 是从经历 i 到其他经历的转移个数; N_i 是从其他经历到经历 i 的转移个数。实验表明, 学习常量 α 取 0.5 可使构建的地图收敛到一个稳定的状态, 模型如图1所示。

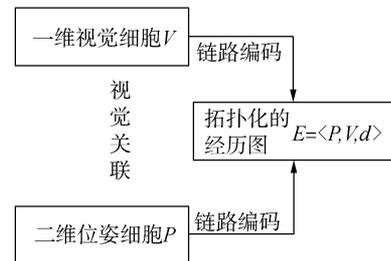


图1 RatSLAM 模型
Fig.1 RatSLAM model

2 DGSOM 算法下的 RatSLAM 模型

神经科学研究表明,视觉皮层与其海马脑区的细胞存在竞争性输入^[12-13],而传统的 SOM 算法^[14-19]为确定初始网络结构需进行大量复杂的运算。本文提出一种具有神经元方向和特征的特征 DGSOM 神经网络模型,通过引入方向参数减少学习次数从而降低系统的复杂度,通过引入特征参数避免感知混淆,将该模型应用于 RatSLAM 模型中以改进现有基于鼠类海马体导航机制的细胞导航模型。

方向参数 D 决定了 RatSLAM 模型中视觉细胞和位姿细胞的激活特性,激活值 m_i^k 和 $m_{x'y'}^k$ 取 1, 0, -1。特征参数 F 决定了 RatSLAM 模型中视觉细胞和位姿细胞的环境特征,其特征可分别表达为 n_i^k 及 $n_{x'y'}^k$, 输入参数 C 可表达为 $c_i^k = m_i^k n_i^k$ 和 $c_{x'y'}^k = m_{x'y'}^k n_{x'y'}^k$, 其中上标 k 表示第 k 个平面。

视觉细胞特征如式(7)所示:

$$c_i^k = \begin{cases} n_i^k, & m_i^k = 1 \\ 0, & m_i^k = 0 \\ -n_i^k, & m_i^k = -1 \end{cases} \quad (7)$$

位姿细胞特征如式(8)所示:

$$c_{x'y'}^k = \begin{cases} n_{x'y'}^k, & m_{x'y'}^k = 1 \\ 0, & m_{x'y'}^k = 0 \\ -n_{x'y'}^k, & m_{x'y'}^k = -1 \end{cases} \quad (8)$$

1) 创建 DGSOM 网络

引入输入神经元 $C = \langle D, F \rangle$, DGSOM 模型神经元的创建过程如图 2 所示,其中第 3 个神经元是竞争出的胜者,第 $m+1$ 个神经元是新产生的神经元。

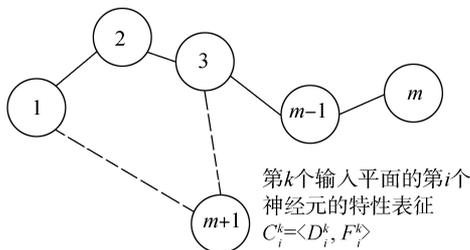


图 2 DGSOM 模型神经元的创建过程

Fig.2 Neurons created in DGSOM model

2) 计算权值向量与输入的距离

在第 k 个输入 v^k 平面中,到每一个神经元 i 的距离 d_i 可由已知的 m 个神经元计算得出,可选取的方法包括曼哈顿距离、欧氏距离、径向基等,这里采用输入样本与获胜神经元连接强度的欧氏距离进行判断,计算方法如式(9)和式(10)所示:

$$d_i = \left[\sum_{j=1}^m (c_i^k - \omega_{ij}^k)^2 \right]^{\frac{1}{2}} \quad (9)$$

$$d_{\min} = \min(d_i) \quad (10)$$

3) 获取最佳匹配单元

通过引入阈值参数 α 选择是否需引入新的神经元,获取最佳匹配单元的数学模型,如式(11)所示:

$$d_i = \begin{cases} 0, & i \text{ 为已引入的神经元} \\ 1 - \frac{d_{\min}}{\alpha}, & i \text{ 为已引入的神经元,且 } d_{\min} < \alpha \\ 1, & i \text{ 为新引入的神经元,且 } d_{\min} \geq \alpha \end{cases} \quad (11)$$

4) 调节神经元的权重

新引入的神经元如式(12)所示:

$$\omega_{ij}^{t+1} = c_{ij}^k \quad (12)$$

已引入的神经元如式(13)所示:

$$\omega_{ij}^{t+1} = \begin{cases} \omega_{ij}^t + \beta^t (c_{ij}^k - \omega_{ij}^t), & j = \operatorname{argmin} d_j \\ \omega_{ij}^t, & \text{其他} \end{cases} \quad (13)$$

式中: $\beta^t = \beta_0 e^{-\frac{t}{\rho}}$, β_0 赋初值 0.1, ρ 为允许在神经元 i 处创建的新节点数目;权重满足约束条件 $\|\omega_{ij}\| \leq 1$ 。

5) 构建一个新的神经元

通过移动机器人在环境中探索,重复过程 1) ~ 4), 构建一个新的神经元。

6) 将 DGSOM 模型应用于 RatSLAM

DGSOM 下的 RatSLAM 模型如图 3 所示。通过摄像头获取局部场景,利用视觉里程计信息整合至位姿细胞从而影响经历图的构建;融合 DGSOM 神经网络模型的视觉细胞,一方面对位姿细胞进行视觉关联,另一方面直接影响经历图的构建。

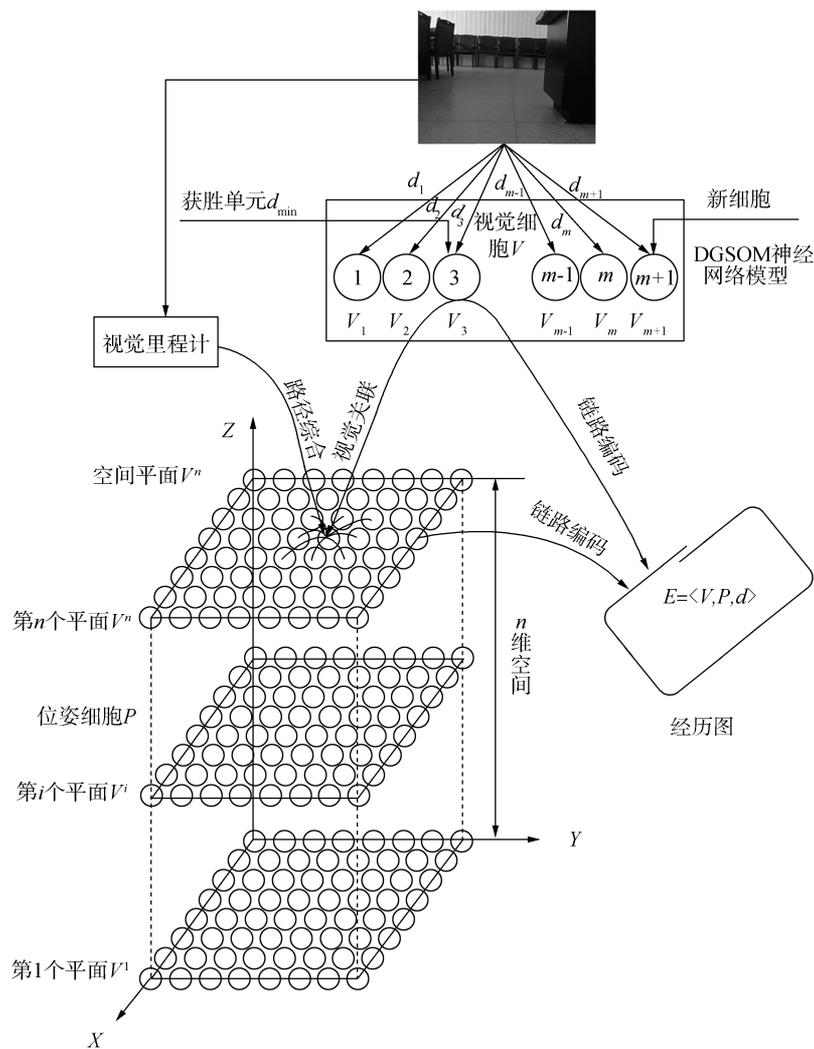


图 3 融入 DGSOM 神经网络的 RatSLAM 模型

Fig.3 RatSLAM model with DGSOM neural network

3 实验与结果分析

3.1 实验设计

本实验通过如图 4 所示的“旅行家 II 号”轮式机器人摄像头模块进行局部场景的采集,将采集的图像传至上位机并通过 MATLAB 进行算法分析验证。实验选取的室内场景如图 5 所示。



图 5 实验场景

Fig.5 Experiments scene



图 4 “旅行家 II 号”轮式机器人

Fig.4 The wheeled mobile robot Voyager II

3.2 实验结果与分析

1) 改进前后 RatSLAM 模型中位姿细胞的活性转移过程及 DGSOM-RatSLAM 模型的实时性验证实验

位姿细胞的位姿转移过程如图 6 所示,每组 3 幅图分别表示摄像头实际读取的图像信息、RatSLAM 模型中位姿感知细胞活性状态信息以及 DGSOM-RatSLAM 模型位姿感知细胞活性状态信息;图 6(a)~(i)所示的过程表示移动机器人在 18~

23 s 时位姿细胞的活性转移过程。从图 6 所示的组图中可以看出, 随时间推移, RatSLAM 模型和 DGSOM-RatSLAM 模型的位姿细胞左侧活性强度逐渐降低, 中间及右侧活性强度逐渐增加; 文献[6]证明了 RatSLAM 模型在一天中的不同时段都能对同

一场景实现闭环检测, 但如图 6(j) ~ (l) 所示, 该模型无法在场景重现的第一时间(67 s 时刻)进行闭环检测, 而改进后的 DGSOM-RatSLAM 模型能够在这第一时间及时地辨识出先前出现的场景, 实现闭环检测, 其改进模型的实时性得到了验证。

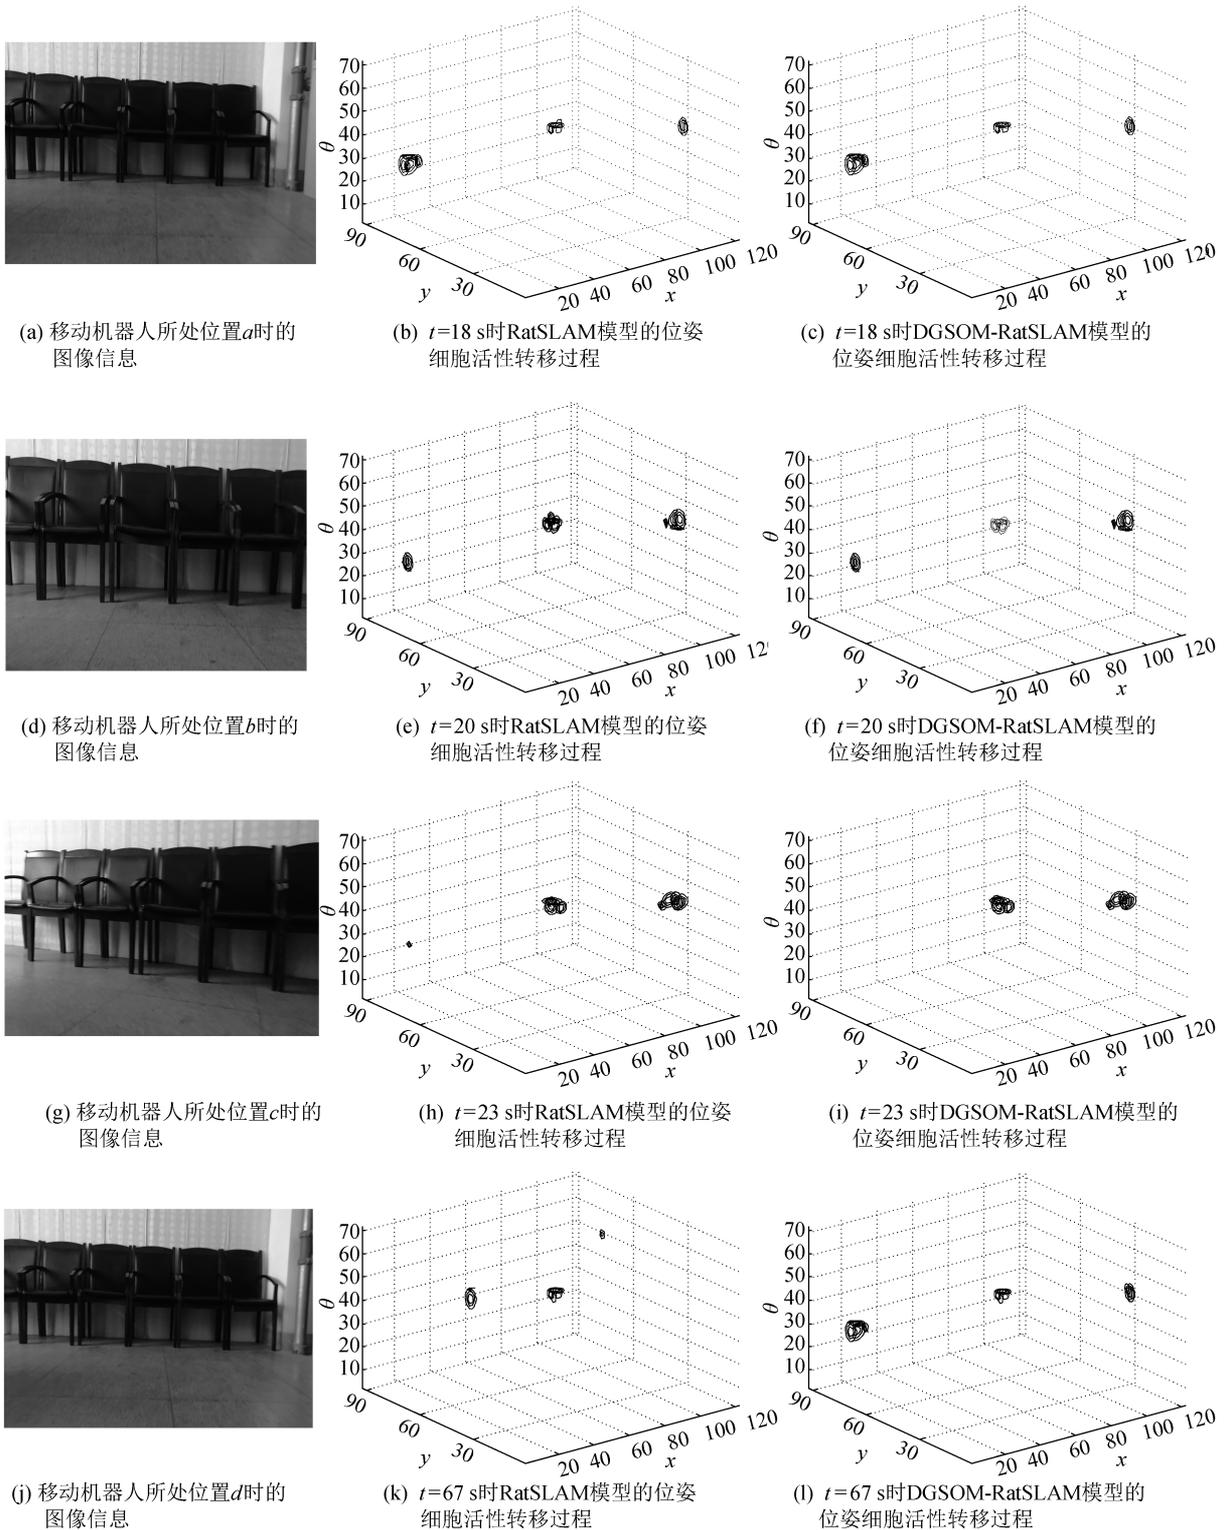


图 6 两种模型位姿细胞活性转移过程

Fig.6 The transfer of pose cells activity in two models

2) RatSLAM 模型与 DGSOM-RatSLAM 模型的定性分析

RatSLAM 模型与融入 DGSOM 神经网络的 RatSLAM 模型的性能对比如图 7 所示,相比于现有的 RatSLAM 模型, DGSOM-RatSLAM 模型采集相同场景时所需视觉细胞的个数更少,能够更快地进行场景重定位且匹配效果更佳。

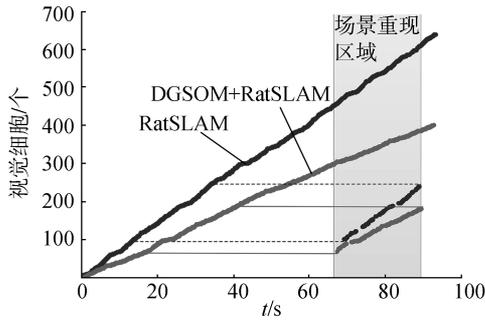


图 7 RatSLAM 模型与 DGSOM-RatSLAM 模型性能对比
Fig.7 Performance comparison between RatSLAM and DGSOM-RatSLAM

3) 高斯噪声干扰下的 RatSLAM 模型与 DGSOM-RatSLAM 模型的定性分析

为进一步验证 DGSOM-RatSLAM 模型的有效性,给所需处理的图像添加随机高斯噪声,其中正态分布的均值 μ 取 0,标准差 σ 取随机值 [0.02, 0.08]。高斯噪声干扰下的 RatSLAM 模型与 DGSOM-RatSLAM 模型性能对比如图 8 所示,相比于 RatSLAM 模型, DGSOM-RatSLAM 模型采集相同场景时所需视觉细胞的个数更少,能够更快地实现闭环且匹配效果更佳。

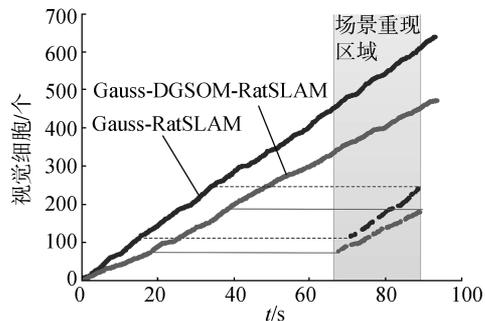


图 8 Gauss-RatSLAM 模型与 Gauss-DGSOM-RatSLAM 模型性能对比

Fig.8 Performance comparison between Gauss-RatSLAM and Gauss-DGSOM-RatSLAM

4) 准确率与召回率对闭环检测的定量分析

引入准确率 P 、召回率 R 及 F 值对两种系统进行评估,数学模型如式 (14) ~ (16) 所示:

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$F_a = \frac{a^2 + 1}{a^2} \frac{PR}{P + R} \quad (16)$$

式中:正阳性 (true positive, TP) 指正确识别的闭环经验节点单元,假阳性 (false positive, FP) 指错误检测出的闭环经验节点单元,假阴性 (false negative, FN) 指未检测到的真实闭环经验节点单元,这里取 $a = 1$,有

$$F_1 = \frac{2PR}{P + R} \quad (17)$$

经计算, RatSLAM 算法和 DGSOM-RatSLAM 算法的准确率 P 分别为 93.26% 和 94.74%, 差异性不显著;但相比于 RatSLAM 模型, DGSOM-RatSLAM 模型的召回率 R 有显著的提升,其中, RatSLAM 算法的召回率 R 仅为 75.28%, 即该算法在场景重定位中会导致较多的假阴性判断, DGSOM-RatSLAM 算法的召回率 R 改进至 86.88%, 两种模型的 F_1 值分别为 83.31% 与 90.64%, 可以看出, DGSOM-RatSLAM 算法性能得到了一定的改进, 数据对比如表 1 所示。

表 1 RatSLAM 模型与 DGSOM-RatSLAM 模型性能对比

Table1 Performance comparison between RatSLAM model and DGSOM-RatSLAM model %

模型	准确率 P	召回率 R	F_1 值
RatSLAM	93.26	75.28	83.31
DGSOM-RatSLAM	94.74	86.88	90.64%

在每一帧图像中加入高斯噪声, 得出其改进前后的 Gauss-RatSLAM 模型及 Gauss-DGSOM-RatSLAM, 其准确率 P 分别为 91.42% 和 86.70%, 召回率 R 分别为 71.33% 和 80.25%, 计算得 F_1 值分别为 80.14% 和 83.35%, 数据如表 2 所示。

表 2 Gauss-RatSLAM 模型与 Gauss-DGSOM-RatSLAM 模型性能对比

Table 2 Performance comparison between Gauss-RatSLAM model and Gauss-DGSOM-RatSLAM model %

模型	准确率 P	召回率 R	F_1 值
Gauss-RatSLAM	91.42	71.33	80.14
Gauss-DGSOM-RatSLAM	86.70	80.25	83.35

对比两模型的准确率、召回率及 F_1 值可以看出, 融入 DGSOM 的鼠类导航细胞模型整体性能得到了一定的改进。

5) 实验场景匹配效果对比

RatSLAM 模型与融入 DGSOM 神经网络的 RatSLAM 模型的实验场景匹配效果对比如图 9 所示, DGSOM-RatSLAM 模型在闭环匹配中具有更好

的鲁棒性和快速性。

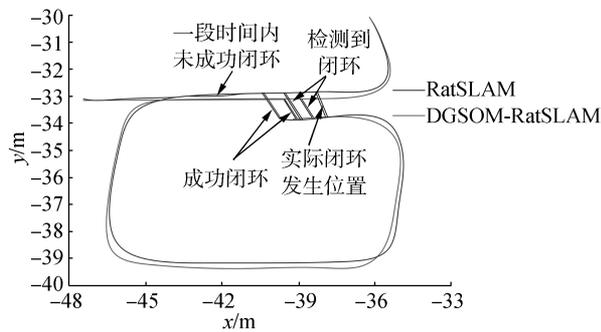


图9 RatSLAM模型与DGSOM-RatSLAM模型实验场景匹配效果对比

Fig.9 Matching effect of experiment scene between RatSLAM and DGSOM-RatSLAM

4 结束语

与现有的 RatSLAM 模型相比,本文提出的 DGSOM-RatSLAM 模型将 DGSOM 神经网络融入视觉细胞,通过减少所需细胞的数量降低了系统的复杂度,并且通过位姿细胞活性状态实验与视觉细胞实验分别验证了 DGSOM-RatSLAM 模型能够更早地匹配到闭环,使系统具有更好的快速性能,优化了匹配效果,其准确率、召回率及 F_1 值与传统 RatSLAM 模型相比有一定的改进,分别达 94.74%、86.88% 和 90.64%,进一步进行鲁棒性测试可知融入高斯噪声干扰下的改进模型的准确率、召回率及 F_1 值分别达 86.70%、80.25%、83.35%。

参考文献:

- [1] KOHONEN T. Self-organized formation of topologically correct feature maps[J]. Biological cybernetics, 1982, 43(1): 59-69.
- [2] MARTINEZ T M, BERKOVICH S G, SCHULTEN K J. Neural-gas network for vector quantization and its application to time-series prediction[J]. IEEE transactions on neural networks, 1993, 4(4): 558-569.
- [3] 尹峻松, 胡德文, 陈爽, 等. DSOM: 一种基于 NO 时空动态扩散机理的新型自组织模型[J]. 中国科学 E 辑: 信息科学, 2004, 34(10): 1094-1109.
YIN Junsong, HU Dewen, CHEN Shuang, et al. DSOM: a new self-organization model based on NO space-time dynamic diffusion mechanism[J]. Science in China ser. E information sciences, 2004, 34(10): 1094-1109.
- [4] 王春东, 虞鹤峰, 王怀彬. Grey self-organizing map based intrusion detection[J]. Optoelectronics letters, 2009, 5(1): 64-68.
- [5] 于乃功, 王丽. 双目立体视觉和 GSOM 相结合的机器人自主地图构建方法[J]. 计算机测量与控制, 2011, 19(11): 2810-2813.
- [6] YU Naigong, WANG Li. Autonomous mapping for robot using a combination of binocular stereo vision and GSOM[J]. Computer measurement and control, 2011, 19(11): 2810-2813.
- [7] MILFORD M J, PRASSER D P, WYETH G F. Effect of representation size and visual ambiguity on RatSLAM system performance[C]// Australasian Conference on Robotics and Automation. Australian Robotics and Automation Society (ARAA), 2006: 1-8.
- [8] MILFORD M, SCHULZ R, PRASSER D, et al. learningspatial concepts from RatSLAM representations[J]. Robotics and autonomous systems, 2007, 55(5): 403-410.
- [9] MILFORD M, WYETH G, PRASSER D. RatSLAM on the edge: revealing a coherent representation from an overloaded rat brain [C]// Ieee/rsj International Conference on Intelligent Robots and Systems, IROS 2006, October 9-15, 2006, Beijing, China. 2006: 4060-4065.
- [10] 王丽娟, 陶璨, 张光伟, 等. 小鼠初级听皮层 SOM 中间神经元突触输入的时空特性研究[J]. 第三军医大学学报, 2017, 39(5): 417-422.
WANG Lijuan, TAO Can, ZHANG Guangwei, et al. Spatial-temporal characteristics of synaptic inputs received by SOM+ interneurons in mouse primary auditory cortex [J]. Journal of third military medical university, 2017, 39(5): 417-422.
- [11] 于乃功, 方略, 罗子维, 等. 大鼠脑海马结构认知机理及其在机器人导航中的应用[J]. 北京工业大学学报, 2017, 43(3): 434-442.
YU Naigong, FANG Lue, LUO Ziwei, et al. Cognitive mechanism of rat hippocampal formation and its application in robot navigation [J]. Journal of Beijing university of technology, 2017, 43(3): 434-442.
- [12] 刘帅师, 程曦, 郭文燕, 等. 深度学习研究方法研究新进展[J]. 智能系统学报, 2016, 11(5): 567-577.
LIU Shuishi, CHENG Xi, GUO Wenyan, et al. Progress report on new research in deep learning [J]. CAAI transactions on intelligent systems, 2016, 11(5): 567-577.
- [13] 丁永生. 计算智能的新框架: 生物网络结构[J]. 智能系统学报, 2007, 2(2): 26-30.
DING Yongsheng. A new scheme for computational intelligence: bio-network architecture [J]. CAAI transactions on intelligent systems, 2007, 2(2): 26-30.
- [14] 芮小平, 张立强. 基于 SOM 的多维信息可视化研究[J].

应用基础与工程科学学报, 2011, 19(3): 379-388.

RUI Xiaoping, ZHANG Liqiang. Multi-dimensional information visualization based on SOM[J]. Journal of basic science and engineering, 2011, 19(3): 379-388.

- [15] 尹柏强, 何怡刚, 朱彦卿. 一种广义 S 变换及模糊 SOM 网络的电能质量多扰动检测和识别方法[J]. 中国电机工程学报, 2015, 35(4): 866-872.

YIN baiqiang, HE Yigang, ZHU Yanqing. Detection and classification of power quality multi-disturbances based on generalized S-transform and fuzzy SOM neural network[J]. Proceedings of the CSEE, 2015, 35(4): 866-872.

- [16] 於东军, 吴小俊, HANCOCK Edwin R, 等. 广义 SOM 及其在人脸性别识别中的应用[J]. 计算机学报, 2011, 34(9): 1719-1725.

YU Dongjun, WU Xiaojun, HANCOCK Edwin R, et al. Generalized SOM with application to facial gender identification[J]. Chinese journal of computers, 2011, 34(9): 1719-1725.

- [17] 刘艳, 陈丽安. 基于 SOM 的真空断路器机械故障诊断[J]. 电工技术学报, 2017, 32(5): 49-54.

LIU Yan, CHEN Li'an. Mechanical fault diagnosis of vacuum circuit breaker based on SOM[J]. Transactions of China electrotechnical society, 2017, 32(5): 49-54.

- [18] 邱天宇, 申富饶, 赵金熙. 自组织增量学习神经网络综述[J]. 软件学报, 2016, 27(9): 2230-2247.

QIU Tianyu, SHEN Furao, ZHAO Jinxi. Review of self-organizing incremental neural network [J]. Journal of software, 2016, 27(9): 2230-2247

- [19] 赵建华, 李伟华. 有监督 SOM 神经网络在入侵检测中的应用[J]. 计算机工程, 2012, 38(12): 110-111.

ZHAO Jianhua, LI Weihua. Application of supervised SOM neural network in intrusion detection [J]. Computer engineer, 2012, 38(12): 110-111.

作者简介:



许瞳, 男, 1993 年生, 硕士研究生, 主要研究方向为机器视觉和仿生导航算法。



凌有铸, 男, 1962 年生, 研究生导师, 主要研究方向为传感器信号处理和机器人地图构建等。主持省自然科学基金、省科技计划项目等 10 余项, 获安徽省科学技术奖 4 项, 发表学术论文 60 余篇。



陈孟元, 男, 1984 年生, 副教授, 主要研究方向为移动机器人地图构建及同步定位等。主持安徽省高等学校自然科学研究项目等 10 余项, 发表学术论文 30 余篇, 授权国家发明专利 4 项。