

基于判别图模型的激光点云数据关联决策

孙作雷¹, 张波², 曾连荪¹, 朱大奇¹

(1. 上海海事大学 信息工程学院, 上海 201306; 2. 中国科学院 上海高等研究院, 上海 201210)

摘要: 提出一种激光点云数据关联决策算法. 基于判别图模型, 提取并智能管理激光点云的多重形状特征, 通过最大伪似然学习优化局部特征和配对特征的权重; 应用最大和概率推理实现对图模型隐节点状态的估计, 进而将激光点关联映射为最大后验概率的配置回溯问题; 实验结果验证了所提出算法比传统算法具有更好的性能.

关键词: 激光点云; 判别图模型; 数据关联; 概率推理

中图分类号: TP273

文献标志码: A

Laser point clouds data association decision based on discriminative graphical model

SUN Zuo-lei¹, ZHANG Bo², ZENG Lian-sun¹, ZHU Da-qi¹

(1. College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China; 2. Shanghai Advanced Research Institute, Chinese Academy of Sciences, Shanghai 201210, China. Correspondent: SUN Zuo-lei, E-mail: sunzuolei@gmail.com)

Abstract: A laser point clouds data association decision algorithm is proposed. The multi-geometric feature extraction and intelligent management for the laser point clouds are investigated with the discriminative graphical model. The maximum pseudo-likelihood learning is employed to optimize the weights of the local and pairwise features. And the states of the hidden nodes in the graph are estimated with max-sum probabilistic inference. Furthermore, the laser point association is tackled as the maximum a posteriori (MAP) configuration backtracking problem. The experiment results demonstrate that the proposed algorithm outperforms traditional algorithms.

Key words: laser point cloud; discriminative graphical model; data association; probabilistic inference

0 引言

激光传感器在机器人导航中的应用可以追溯到20世纪80年代末. 一些研究者直观地认识到激光点云的轮廓可以配准环境中景物的轮廓. Cox^[1]假设机器人运行在由规则的多边形障碍物组成的已知环境中, 通过匹配激光点云与已知地图中障碍物的轮廓来估计机器人的方位. 虽然先验规则地图的假设并不具有普适性, 但该研究中用于激光点云与地图吻合度验证的迭代最小二乘法启发了后来的研究者. Besl等^[2]提出了旨在配准三维点集、曲线和面的高效算法—迭代最近点(ICP); Lu等^[3]将迭代最近点算法应用于基于相邻激光点云匹配的移动机器人自身的方位估计中, 奠定了激光点云匹配在机器人导航领域应用的基础. 然而, 在相邻激光点云数据关联的决策问题上, 迭代最近点算法存在如下缺陷: 1) 用经纬坐标

投影后的两激光点间的空间欧氏距离作为判断两激光点关联的尺度, 方式过于单一; 2) 依赖于对相对运动的猜测, 初始值的选取直接影响迭代的次数和算法最终收敛值的精度; 3) 没有对激光点云数据关联决策质量表征的概率依据; 4) 在算法设计上没有考虑对决策质量的自映射机制. 在决策大量程、形状复杂、采集于高动态运动状态下的激光点云数据关联时, 这些缺陷会导致迭代最近点法性能不佳.

本文基于判别图模型, 智能提取并管理相邻两激光点云中激光点的多种特征, 从机器学习的角度决策相邻激光点云间的数据关联, 性能比传统算法更好.

1 激光点云匹配原理

激光传感器在移动机器人导航领域的应用通常基于激光测距原理. 在 t 时刻的测量值由若干距离读数构成, 某时刻测量得到的激光点云是指若干二维

收稿日期: 2013-01-03; 修回日期: 2013-03-26.

基金项目: 国家自然科学基金项目(61105097, 51279098); 上海市教育委员会科研创新项目(13YZ081).

作者简介: 孙作雷(1982—), 男, 讲师, 从事移动机器人导航的研究; 张波(1978—), 男, 副研究员, 从事机器视觉、移动机器人等研究.

激光点组成的序列. 假设机器人相继途经参考方位 P_{ref} 和新方位 P_{new} 时, 测得两激光点云: 参考激光点云 L_{ref} 和新激光点云 L_{new} . 当机器人的行进速度较低或传感器采样频率足够高时, 激光传感器在相邻两方位处的视野会有部分重叠, 即新激光点云中的一些激光点与参考激光点云中的一些激光点两两对应于实际环境景物表面的相同物理点, 这种激光点间的对应关系称为关联. 新激光点云中的一些激光点在参考激光点云中找不到对应的激光点, 这些激光点称为孤立点. 两激光点云中所有激光点间的两两关联关系的集合称为激光点数据关联配置. 图 1 为实地实验中一组相邻时刻测得的激光点云数据关联决策的例子. 基于该关联配置决策, 可计算 P_{new} 相对于 P_{ref} 所产生的相对运动 $\text{RT}^{[3]}$.




图 1 一组激光点云数据关联实例

2 从激光点云关联决策到图模型的映射

2.1 判别图模型的构建

判别图模型是一种构建于判别概率框架的机器学习方法, 通常以无向图模型构建^[4-5]. 在判别图模型中, 因为待推理的对象向量在全局中受观测量 z 影响, 所以与传统的生成式概率框架相比, 判别图模型关注并直接对观测量与待推理变量状态间的条件概率 $p(x|z)$ 建模, 而非联合概率 $p(x, z)$, 这避免了建模观测量间关系 $p(z)$ 的复杂性^[6]. 因此, 判别图模型更适合于数据在空间和时间上具有较大相关性的激光点云匹配问题. 本文使用判别图模型中的一种典型方式——成双条件随机场^[7-9], 它包含两种势函数: 局部势和配对势. 将参考激光点云和新激光点云所包含的激光点作为观测量 z ; $\{L_{\text{ref}}^1, L_{\text{ref}}^2, \dots, L_{\text{ref}}^N\}$ 表示参考激光点云中的 N 个激光点, 它们各自可能的关联状态映射为条件随机场图中的节点; $\{L_{\text{new}}^1, L_{\text{new}}^2, \dots, L_{\text{new}}^M\}$ 表示新激光点云中的 M 个激光点; 条件随机场图中的每个节点 x_i 都对应了 $M+1$ 种状态的似然, 例如 x_i 的状态 1 表示 x_i 所对应的参考激光点云中的激光点 L_{ref}^i 与新激光点云的激光点 L_{new}^1 关联的似然, 状态 $M+1$ 表示 L_{ref}^i 在新激光点云中找不到相关联激光点的似然, 即 L_{ref}^i 是孤立点的似然.

求取两相邻激光点云激光点关联配置的问题可以等效为推理条件概率 $p(x|z)$, 即基于相邻两束激光点云的观测数据, 求参考激光点云中激光粒子与新激光点云粒子之间的关联的概率. 本文所构建的条件随机场的概率表示为

$$p(x|z) = \frac{1}{Z(z)} \prod_{i \in \mathcal{V}} \phi_l(x_i) \prod_{(i,j) \in \mathcal{E}} \phi_p(x_i, x_j). \quad (1)$$

其中: $Z(z)$ 为分割函数; $\phi_l(x_i)$ 为局部势, 是节点 x_i 基于观测量判断自身隶属不同状态的概率^[10], 本文中 $\phi_l(x_i)$ 为具有 $M+1$ 个元素的向量, 它的第 j 个元素在推理 L_{ref}^i 与 L_{new}^j 关联的概率中发挥作用; $\phi_p(x_i, x_j)$ 为配对势, 对应连接节点 x_i 和 x_j 的边, 它描述了 x_i 与 x_j 推理状态概率间的关系, 保证了单个节点推理间的全局一致性. 局部势和配对势可进一步表示为^[7]

$$\phi_l(x_i) = \exp(w_l \cdot f_l(z, x_i)), \quad (2)$$

$$\phi_p(x_i, x_j) = \exp(w_p \cdot f_p(z, x_i, x_j)). \quad (3)$$

其中: f_l 和 f_p 分别表示局部特征函数和配对特征函数, 它们基于相邻激光点云的测量值计算得到; w_l 和 w_p 是这两种特征函数通过参数学习得到的权重.

2.2 特征提取

2.2.1 局部特征

本节讨论 3 种特征: 基础几何特征, Boosting 特征和 ICP 关联特征. 基础几何特征和 ICP 关联特征从激光传感器测量值中计算提取, Boosting 特征基于基础几何特征构建^[5]. 它们构成局部特征函数 f_l .

遍历计算参考激光点云中的每个点, 并提取它们与新激光点云中所有激光点的 4 种基础几何特征: 距离、角、测地线和辐射. 例如, 辐射特征计算为

$$f_{\text{rad}}(i, j) = \frac{\| \|O_{\text{ref}} - L_{\text{ref}}^i\| - \|O_{\text{new}} - L_{\text{new}}^j\| \|}{\sigma}. \quad (4)$$

其中: $\| \|$ 表示计算欧氏距离; O_{ref} 和 O_{new} 分别表示机器人处于参考方位和新方位时机器人中心坐标系的原点; σ 表示学习数据中的标准差.

本文共构建两种 Boosting 特征: 数据 Boosting 和孤立点 Boosting. 前文提取的基础几何特征并不直接作为局部特征输入图模型, 而是输入到一种简单的分类器 AdaBoost 中^[11], 再将其输出值作为局部特征, 这种做法能更好地处理数据中的非线性. 把所有基础几何特征直接输入 AdaBoost, 将得到与基础几何特征元素个数相同的向量, 即为数据 Boosting 特征. 数据 Boosting 特征中的元素同样表征了相似度或激光点关联的似然. 将各基础几何特征中最小的元素提取出来并输入 AdaBoost, 输出的结果为一个标量, 即为孤立点 Boosting 特征, 它表征了相应的参考激光点云中激光点为孤立点的似然.

ICP 关联特征结合了迭代最近点算法在机器人相对运动不是特别大时的优势. 在机器人装配有里程计时, 它能有效地将航位推算数据结合进系统.

2.2.2 配对特征

配对特征函数 f_p 描述了判别图模型节点间的关系. 本文使用两类配对特征^[5]: 1) 利用激光点云数据关联决策问题的内在结构; 2) 从两束激光点云的测量值中计算得到.

配对序列特征. 在不存在孤立点的理想状态下, 当 L_{ref}^i 与 L_{new}^j 关联时, L_{ref}^{i+1} 很大似然上与 L_{new}^{j+1} 关联. 本文提取配对序列特征来映射这种关联特性, 它是一系列带有主对角线向上偏移的单位矩阵. 当非零的对角线向上偏移1时, 表示了如下关联关系: 如果 $L_{\text{ref}}^i \rightarrow L_{\text{new}}^j$, 则 $L_{\text{ref}}^{i+1} \rightarrow L_{\text{new}}^{j+1}$. 但在实际环境中, 孤立点不可避免, 例如, 当 $L_{\text{ref}}^i \rightarrow L_{\text{new}}^j$, $L_{\text{ref}}^{i+1} \rightarrow O$ 且 $L_{\text{ref}}^{i+2} \rightarrow L_{\text{new}}^{j+1}$ 时, 配对序列特征中 L_{ref}^{i+2} 对应列的非零元素将上移2. 本文选用1~7作为偏移量.

配对孤立点. 该特征描述了孤立点在关联状态转换中的变换. 分为3种情况: 1) 当 $L_{\text{ref}}^i \rightarrow O$ 时, $L_{\text{ref}}^{i+1} \rightarrow O$, 使用 $M \times 1$ 的向量建模, 称为孤立点列特征; 2) 当 $L_{\text{ref}}^i \rightarrow O$ 时, $L_{\text{ref}}^{i+1} \rightarrow O$, 使用 $1 \times M$ 的向量建模, 称为孤立点行特征; 3) 当 $L_{\text{ref}}^i \rightarrow O$ 时, $L_{\text{ref}}^{i+1} \rightarrow O$, 使用一个标量建模, 称为孤立点角特征. 这里, 符号 \rightarrow 代表不关联.

可以将配对序列特征、孤立点列特征、孤立点行特征和孤立点角特征组合成为 $(M+1) \times (M+1)$ 的向量, 输入至条件随机场的图模型中.

第2类配对特征与基础几何特征类似, 它们使用图模型中的一个边所连接的两个节点对应的参考激光点云中两激光点之间的一种测量尺度与新激光点云中所有可能的激光点组合间计算的该测量尺度相比较. 在实现中, 使用距离作为尺度.

3 激光点关联估计

3.1 特征权重学习

基于标定数据, 局部特征和配对特征的权重 $w_c = [w_l, w_p]$ 通过参数学习过程获得. 本文采用了最大伪似然 (MPL) 学习^[12]. 最大似然学习算法所计算的伪似然可表示为

$$pl(x | z, w) \triangleq \prod_{i=1}^N p(x_i | \text{MB}(x_i), w) = \prod_{i=1}^N \frac{\exp\{w_c^T \cdot f(x_i, \text{MB}(x_i), z)\}}{Z(\text{MB}(x_i), w)}. \quad (5)$$

其中: N 表示条件随机场图中的节点个数, 也对应于参考激光点云中激光点的个数; $\text{MB}(x_i)$ 表示节点 x_i 的马尔可夫毯; $p(x_i | \text{MB}(x_i), w)$ 表示节点 x_i 的局部似然; $f(x_i, \text{MB}(x_i), z)$ 表示局部特征值; $Z(\text{MB}(x_i), w) = \sum_{x'_i} \exp\{w_c^T \cdot f(x'_i, \text{MB}(x'_i), z)\}$ 表示局部分割函数.

考虑实际运算中的可操作性, 对伪似然的优化通常以负对数形式进行, 表示为

$$\mathcal{PL}(w) = - \sum_{i=1}^N \log p(x_i | \text{MB}(x_i), w) + \frac{(w - \tilde{w})^T (w - \tilde{w})}{2\sigma^2}. \quad (6)$$

上式右边的第2项是收缩因子, 用来避免 w 的解偏向两极, 同时保证解服从高斯先验概率分布. 本文

实验中使用0均值的均匀先验概率, 因此 $\tilde{w} = 0$; 然后, 使用基于梯度的优化算法最小化 $\mathcal{PL}(w)$, 便可以求出针对于所提取特征的最佳权重.

3.2 最大和推理

基于前文所述的最优化权重 w 和观测量 z , 本文使用最大和推理 (max-sum) 算法估计图模型中每个节点的关联概率. 最大和推理可解决最大后验概率 (MAP) 问题, 而且可找到对应于最大后验概率的配置. 最大和推理基于置信传播实现, 本文使用的链式图模型中, 每个节点有不多于两个的相邻节点, 这简化了消息构建

$$m_{ij}^{\max}(x_j) = \max_{x_i} (\ln \phi_l(x_i) + \ln \phi_p(x_i, x_j) + m_{ki}^{\max}(x_i)). \quad (7)$$

其中: $m_{ij}^{\max}(x_j)$ 表示链式条件随机场图中的节点 x_i 传向节点 x_j 的消息; $m_{ij}^{\max}(x_j)$ 表示节点 x_i 对节点 x_j 状态的推理; $\phi_l(x_i)$ 和 $\phi_p(x_i, x_j)$ 表示前文所述的局部势和配对势. 节点 x_k 是节点 x_j 除节点 x_i 外的相邻节点. 在一个条件随机场图中, 消息由任意选定的叶节点向根节点传播, 待消息传至根节点 x_r 处时, 可通过下式获得最大后验概率:

$$p^{\max}(x | z) \propto \max_{x_r} (\phi_l(x_r) + m_{jr}^{\max}(x_r)). \quad (8)$$

消息沿叶节点到根节点方向传播一遍, 最大和推理便可求得最大后验概率. 然后, 通过最大化配置回溯求得各节点最大化状态为新激光点云中激光点的索引, 这些激光点依次与参考激光点云中的激光点关联.

4 实验及结果分析

使用10组在室外不规则环境下采集的激光点云, 分别用传统基于迭代最近点 (ICP) 和本文所提出算法决策激光点云激光点间的数据关联配置. 其中, 迭代最近点算法的相对运动猜想设定为0. 实验中对激光点云匹配的精度 (即准确率) 计算如下:

$$V = \frac{\hat{n}_{\text{inlier}}}{n_{\text{assoc}}} \cdot 100\%. \quad (9)$$

其中: n_{assoc} 为由激光点云数据关联决策算法估计的所有存在关联关系的激光点对的个数, \hat{n}_{inlier} 为该算法决策的激光点关联与相应的真实值相一致的个数. 表1为分别采用传统迭代最近点算法和本文所提出的算法对上述10组激光点云数据关联决策的准确率对比. 图2直观地展示了表1的结果. 由结果知, 迭代最近点法对10组激光点云的平均数据关联决策正确率为54.71%, 而本文所提出算法较之高出约14%.

图3(a)~(c)为上述两种数据关联决策算法针对第2组激光点云的数据关联细节. 图中激光点间的关联关系使用连接两激光点的直线表征. 该组激光点云对中的参考激光点云和新激光点云分别在移动机器人途经一系列杂乱无章的点和面的障碍物的相邻时刻测得, 表现为一组形状高度不连续性的点序列. 如图3(b)所示, 传统的迭代最近点法估计出的激光

表1 10组激光点云数据关联决策准确率对比

激光点云序号	1	2	3	4	5	6
传统算法ICP	44.60	45.98	43.77	54.02	58.73	33.80
本文提出算法	68.70	98.61	45.98	67.87	48.20	72.58
激光点云序号	7	8	9	10	平均	
传统算法ICP	70.64	64.82	79.78	50.97	54.71	
本文提出算法	95.01	67.87	73.13	51.25	68.92	




图2 两种算法的精度对比

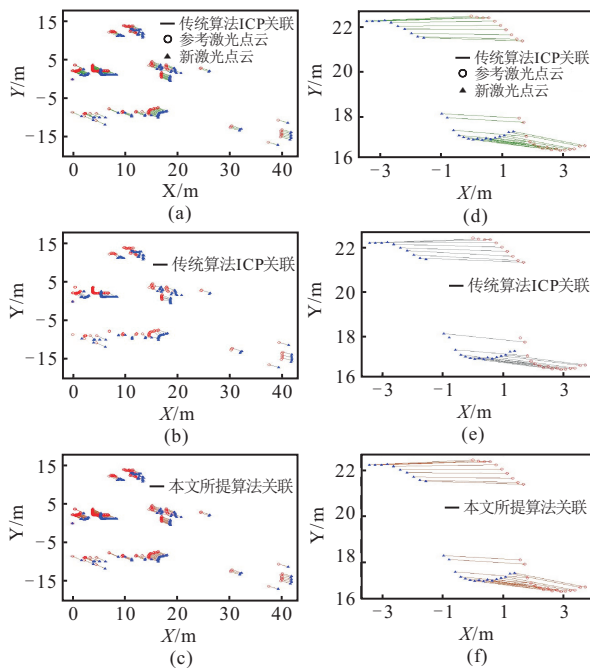


图3 两组激光点云的激光点数据关联关系

点关联配置与真实值相比, 误关联较多, 正确率仅为45.98%, 这是由于杂乱的点序列使最近点关联尺度性能下降, 忽视了激光点之间形状的相关性. 而本文所提算法对激光点局部和全局几何特征的合理建模与智能管理, 使激光点数据关联决策取得较高的正确率, 为98.61%. 图3(d)~(f)为第7组激光点云数据关联的局部细节图. 该组激光点云对测量的机器人新方位相对于参考方位的相对运动较大, 相对转角 $R = -11.82^\circ$, 沿 x 方向的相对位移 $T_x = -1.20$ m, 沿 y 方向的相对位移 $T_y = 0.01$ m, 而0相对运动的迭代初始配置使迭代最近点法收敛于局部最小, 进而引入激光点误关联. 对照图3(d)和3(e), 迭代最近点的估计发生“错位”, 而图3(f)所示的基于判别图模型的激光点云数据关联决策算法更好地捕捉了激光点间的关联关系, 决策准确率为94.18%.

5 结论

本文提出了基于判别图模型的激光点云数据关联决策算法, 用于推理移动机器人相邻时刻所采集激光点云中激光点的关联关系. 通过对链式成双条件随机场的合理建模, 将激光点云匹配问题映射为机器学习问题, 并将对激光点云特征的智能管理融入算法的参数学习和概率推理过程中. 本文所提出算法的匹配精度优于传统的迭代最近点法.

参考文献(References)

- [1] Cox I J, Blanche: An experiment in guidance and navigation of an autonomous robot vehicle[J]. IEEE Trans on Robotics and Automation, 1991, 7(2): 193-204.
- [2] Besl P J, McKay H D. A method for registration of 3-D shapes[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [3] Lu F, Milios E. Robot pose estimation in unknown environments by matching 2D range scans[J]. J of Intelligent and Robotic Systems, 1997, 18(3): 249-275.
- [4] Lin Liao, Dieter Fox, Henry Kautz. Extracting places and activities from GPS traces using hierarchical conditional random fields[J]. The Int J of Robotics Research, 2007, 26(1): 119-134.
- [5] Fabio Ramos, Dieter Fox, Hugh Durrant-Whyte. CRF-Matching: Conditional random fields for feature-based scan matching[C]. Robotics: Science and Systems III. Atlanta: IEEE Press, 2007: 201-208.
- [6] Charles Sutton, Andrew McCallum. An introduction to conditional random fields for relational learning[C]. Introduction to Statistical Relational Learning. Cambridge: MIT Press, 2006: 93-122.
- [7] Bertrand Douillard. Vision and laser based classification in urban environments[D]. Sydney: Australian Centre for Field Robotics (ACFR), The University of Sydney, 2009.
- [8] Lafferty J, McCallum A, Pereira F. Conditional random fields: Probabilistic models for segmenting and labeling sequence data[C]. Int Conf on Machine Learning, Williamstown: Morgan Kaufmann, 2001: 282-289.
- [9] Sanjiv Kumar. Models for learning spatial interactions in natural images for context-based classification[D]. Pittsburgh: The Robotics Institute, Carnegie Mellon University, 2005:.
- [10] Christopher M Bishop. Pattern recognition and machine learning[M]. Secaucus: Springer-Verlag, 2006: 359-422.
- [11] Freund Y, Schapire R E. Experiments with a new boosting algorithm[C]. Int Conf on Machine Learning. Bari: IEEE Press, 1996: 148-156.
- [12] Besag J. Statistical analysis of non-lattice data[J]. The Statistician, 1975, 24(3): 179-195.

(责任编辑: 齐 霖)