

无线传感器网络中的分布式节点定位方法

李善仓¹, 傅鹏², 张德运¹

(1. 西安交通大学电子与信息工程学院, 710049, 西安; 2. 广东省电信规划设计院有限公司, 510630, 广州)

摘要: 提出一种基于流形学习的分布式 Hessian 局部线性嵌入(DHLLE)定位方法,给出了基于流形学习算法的定位框架. DHLLE 方法采用同情最邻近算法来选择节点邻居列表,并应用 Hessian 局部线性嵌入(HLLE)算法获取传感器网络节点的局部映射,再通过对局部映射合并获得所有节点的全局映射,最后通过对参考节点进行坐标匹配以取得所有节点的全局坐标. 仿真结果表明, DHLLE 方法能够快速、准确地对节点进行定位,且复杂度低,节点能耗小,其性能超过了分布式加权多维定标等算法.

关键词: 传感器网络; 分布式节点; 定位方法

中图分类号: TP393.17 **文献标识码:** A **文章编号:** 0253-987X(2007)12-1418-05

Distributed Nodes Localization Method in Wireless Sensor Networks

Li Shancang¹, Fu Peng², Zhang Deyun¹

(1. School of Electronics and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 2. Guangdong Planning and Designing Institute of Telecommunications Co. Ltd., Guangzhou 510630, China)

Abstract: A novel distributed Hessian local linear embedded (DHLLE) localization method and framework based on manifold learning were presented, in which the algorithm of sympathy the nearest was used to select the neighbors list, and the HLLE algorithm was used to obtain the local map of sensor network's nodes. Then, by combining local maps the global map of all nodes was acquired. Finally, the global coordinates of all nodes could be obtained through matching to reference coordinates. The simulation results demonstrate that DHLLE can localize the nodes accurately and rapidly with lower complexity and less energy consumption in nodes, and its performance is superior to the distributed weighted multi-dimension localization algorithm.

Keywords: sensors network; distributed node; localization method

在传感器网络(WSN)的各类应用中,传感器节点的自身定位是其关键问题之一^[1-3]. 现有的传感器网络规模庞大、节点数多,这就要求其成本低廉、能耗低、生命周期长,要是按位置规律布置节点或者在每个节点上安装 GPS 模块等都是不现实的. 因而,开发高效、低能耗、健壮节点自身定位系统迫在眉睫.

目前,分布式定位算法主要是基于连通性模型开发的^[3],尤其是基于流形学习算法的定位方法^[4],如分布式加权多维定标(dwMDS)算法^[2]、Laplacian 特征映射算法^[3]、多维定标映射(MDSMAP)^[5]算法

等,但这些算法的计算过于复杂,不适用于分布式节点的定位.

本文提出了一种基于流形学习的分布式 Hessian 局部线性嵌入(DHLLE)定位方法,该方法计算量小,适用于分布式计算,也是一种基于数据关联进行节点定位的方法.

1 DHLLE 中的基本模型与方法

1.1 连通性测量模型

当采样时间序列 $t=1, \dots, T$ 时, n 个传感器节

点将在高维数据空间 $\mathbf{R}^{nT}$ 上生成一个数据点. 例如, 可将二维传感器位置估计看作是数据从 $\mathbf{R}^{nT}$ 简约到 $\mathbf{R}^{2n}$, 同理也可扩展到三维空间.

选择节点邻居列表主要是依据节点间的连通性模型, 通常用一个布尔变量来表示 2 个节点的连通性(是否可以通信), 即对节点信号能量设置一个阈值, 如果节点 i 收到节点 j 发来的信号, 接收能量高于阈值, 则表示 2 个节点可以通信, 反之则表示 2 个节点不能通信. 连通性表达式为

$$Q_{ij} = \begin{cases} 1 & P_{ij} \geq P_1 \\ 0 & P_{ij} < P_1 \end{cases} \quad (1)$$

式中: P_{ij} 为节点 i 收到节点 j 发射的信号能量; P_1 为信号能量阈值, 它与节点间的距离阈值有关. 至于 P_{ij} 的计算与测量, 详见参考文献[1]. 在连通性模型的基础上, 采用同情 K 最邻近(TPKNN)算法可以计算出每个节点的邻居节点列表[1].

1.2 与空间相关的数据模型

假设 WSN 中有 n 个盲节点, m 个参考节点, 第 i 个节点的坐标为 $\mathbf{z}_i = [x_i, y_i]^T$, 则节点坐标可以表示为 $\{\mathbf{z}_i, i=1, \dots, m+n\}$ [4], 盲节点坐标的估计值为 $\boldsymbol{\theta} = [\mathbf{X}^T, \mathbf{Y}^T]^T$, $\mathbf{X} = [x_1, \dots, x_n]^T$, $\mathbf{Y} = [y_1, \dots, y_n]^T$, 则在 t 时刻节点 i 测得的数据为 $s_i(t)$. 假设有节点 $1, \dots, n+m$ 在时间 t 测得的数据为 $\mathbf{S}(t) = [s_1(t), \dots, s_{n+m}(t)]^T$, 此时测量噪声是均值为 μ 、方差为 $\mathbf{R}(\boldsymbol{\theta})$ 的高斯噪声[2], 即

$$[\mathbf{R}(\boldsymbol{\theta})]_{ij} = \sigma^2 \varphi(\|\mathbf{z}_i - \mathbf{z}_j\|) \quad (2)$$

式中: $\varphi(\cdot)$ 是一个各项同性的协方差函数[1].

1.3 基于流形学习算法的定位方法

通常, 测量值与节点间距呈线性关系, 也可以在包含一个节点及 K 个邻近节点的区域呈局部线性关系, 据此根据局部流形可推导出学习流形的全局现状. DHLLE 方法将局部欧氏距离作为输入, 它要求每个节点估计一个 N_i 的权重, 然后计算单值分解并用 Gram-Schmidt 正交来估计局部 Hessian 距离. 该方法利用了节点 i 和 N_i 中的数据, 并输出 N_i 中节点的非 0 权重(由于 $K \ll (n+m)$, 局部权重构成的权重矩阵是一个稀疏矩阵), 然后求解对应于 3 个最小特征值的特征向量. 如果节点选择本地簇头, 基于流形学习的分布式算法可以使用数据分发技术来减小通信量. 由于 DHLLE 方法在求解中只需求解可测、分布的稀疏矩阵, 因此在分布式定位计算中应优先选用 DHLLE 方法.

DHLLE 方法输出每个节点坐标的相对映射, 通过参考节点坐标的匹配, 即经过缩放、变换以及映

射等方法, 将参考节点坐标估计值与已知坐标进行匹配. 由于最终优化设计使得 $m \ll n$, 所以可以通过计算单个节点的输出、选中、变换、缩放, 并将节点坐标的映射关系广播给那些盲节点, 使得它们能够计算自身的坐标估计值.

2 基于 DHLLE 的定位方法

节点 i 在时间 $t=1, \dots, \tau$ 中采集到的数据 $\mathbf{s}_i = [s_i(1), \dots, s_i(\tau)]$ 是一个多维向量, 其向量维数与采样周期有关. 假设 k_i 为可以与节点 i 直接通信的节点数目, K 为邻接节点数目, 经过一个采样周期之后, 节点 i 向中继节点发送的数据为 s_i . 如果 $k_i < K$, 节点 i 查询下一跳甚至第二跳的节点, 直至获取 K 个节点的数据; 如果 $k_i \geq K$, 节点 i 只接收从 k_i 个节点传来的数据. 节点 i 在 $\mathbf{R}^r$ 中计算自身数据与邻居节点 j 的欧氏距离的计算式为

$$\delta_{ij} = \|\mathbf{s}_i - \mathbf{s}_j\| \quad (3)$$

基于 DHLLE 定位方法的流程如图 1 所示, 主要有 4 个步骤: 选择邻居节点、计算距离矩阵、建立相对映射关系以及匹配参考节点.

(1) 选择邻居节点. 在 WSN 中的节点通过 K 最邻近(KNN)算法、对称 K 最邻近(SKNN)算法和 TPKNN 算法选择邻居节点列表.

(2) 计算距离矩阵. 在 WSN 中通常有两种情况, 一种是已知节点间的距离, 另外一种只是知道节点与其邻居节点的连通性信息, 无需知道具体距离. 若节点间连通, 则取其距离为 1, 再采用最短路径算法 Dijkstra 或 Floyd 求节点间的距离.

(3) 建立节点坐标的映射关系. 根据式(2)中的距离矩阵, 采用 DHLLE 方法计算 WSN 中节点坐




图1 基于流形学习算法的定位方法基本框架

标的局部相对映射,并将其合并成全局 WSN 中的节点坐标相对映射。

(4)匹配参考节点. 如果需要节点的绝对坐标,则根据参考节点并在二维环境下采用至少 3 个节点来求出相对坐标的绝对坐标映射。

2.1 邻居节点选择算法

一个节点可通过自身与周围节点的欧氏距离 δ_{ij} 来选择邻接节点, dwMDS 算法采用 KNN 作为邻居节点选择方法, ISOMAP 算法选择 SKNN 作为邻居节点选择方法, DHLLE 选择 TPKNN 作为邻居节点选择算法^[3,6]. TPKNN 算法的伪代码如图 2 所示。

```

Initial  $N_i$  using KNN for all nodes;
for( $i=0; i<N; i++$ )
{
    if(node  $k$  has less than  $L_{\min}$  nodes which
    consider it as a neighbor)
    {
        node  $k$  is 'lonely' node;
        forced to include  $k$  as  $L_{\min}$  closest
        neighbors;
    }
    else
        continued;
}
Output : neighbors list

```

图 2 TPKNN 算法的伪代码

2.2 DHLLE 方法描述及实现

当选择了邻居节点以后,可应用 DHLLE 方法对传感器采集到的高维数据 s_i 进行降维处理,通过数据约简,可以将高维数据约简为二维环境下的局部映射,具体算法描述如下。

输入: 距离矩阵 $\mathbf{M}$ 上的样本数据 ($m_i; i=1, \dots, N$), N 为节点数。

参数: 参数空间的维数为 d , 邻居节点数为 k 。

约束: $\min(k, n) > d$ 。

输出: 空间 $\mathbf{R}^n$ 中 N 个点的二维坐标集合 ($w_i, i=1, \dots, N$), 它是算法恢复的参数。

步骤 1: 确认邻居节点, 即对于每一个数据点 $m_i, i=1, \dots, n$, 在欧氏空间中根据 TPKNN 算法找出对应于点的 k 个邻近邻居节点, 则 N_i 为节点 i 的邻居节点列表。这些邻居节点形成一个 $k \times n$ 阶矩阵 $\mathbf{M}$, 该矩阵行中心点为 $m_j - \bar{m}_i, j \in N_i, \bar{m}_i = \text{Ave}\{m_j; j \in N_i\}$ 。

步骤 2: 获得切坐标^[1], 即对 $\mathbf{M}$ 进行单值分解, 得到矩阵 $\mathbf{U}, \mathbf{D}$ 及 $\mathbf{V}$ 。 $\mathbf{U}$ 是 $\min(k, n)$ 中的 k , $\mathbf{U}$ 的前 d 列给出了 N_i 中点的切坐标。

步骤 3: 开发 Hessian 估计器, 开发 Hessian 最

小二乘估计的构造参数。矩阵 $\mathbf{H}^i$ 具有这种属性: 如果 f 是一个平滑函数 $f: \mathbb{R}^d \rightarrow \mathbb{R}$, 而且 $f_i = (f(m_i))$, 则从 f 获得的向量 $\mathbf{v}^i$ 与邻域节点 N_i 的点对应, 矩阵向量积 $\mathbf{H}^i \mathbf{v}^i$ 给出一个 $d(d+1)/2$ 维向量, 其成分近似 Hessian 矩阵 $\partial^2 f / (\partial U_i \partial U_j)$ 的成分。

步骤 4: 构建二次模型, 即建立对称矩阵, 则有 $H_{ij} = \sum_l \sum_r ((H^l)_{r,i} (H^l)_{r,j})$, 其中 $\mathbf{H}^l$ 为 $d(d+1)/2 \times k$ 维矩阵, 它是 N_1 上的海森估计, 行 r 对应于海森矩阵特定入口, 列 i 对应于邻域中的特定点。

步骤 5: 寻找逼近空间, 即对 $\mathbf{H}$ 进行特征分析, 确认对应于 $d+1$ 个最小特征值的 $d+1$ 维子空间, 其中可能会有一个与常数函数子空间相关的特征值 0, 其余 d 个特征值对应于 d 维空间 $\hat{\mathbf{V}}_d$ 的特征向量, 而在 $\hat{\mathbf{V}}_d$ 中可以找到嵌入坐标^[1]。

步骤 6: 寻找基本空间^[7], 即对于特定、固定邻域 N_0 的约束, 根据正交基属性 $\hat{\mathbf{V}}_d$ 选择一个基, 给定的基具有基向量 $w^1, \dots, w^d$, 其为嵌入坐标。

DHLLE 方法输出节点坐标的相对映射。

2.3 参考节点匹配

DHLLE 方法输出所有节点坐标的相对映射, 再通过参考节点的坐标相对映射匹配来寻找相对映射与绝对映射的转换、缩放以及其他变换, 使参考节点坐标在最小二乘意义上与相对映射网络相匹配。该阶段的输出为一个 $D \times D$ 转换矩阵。

3 仿真与实验

在 NS2 环境下进行了仿真, 选定 600 m $\times$ 600 m 的区域, 节点数为 300, 节点随机均匀放置。距离估计采用指数函数(式(3), 其中 $\delta=1$), $\alpha=1, K=7^{[2]}$, 并进行 100 次迭代运算, 最终结果取 100 次迭代的平均值。实验考察了下述性能。

(1)传感器网络的联通性. 对 300 个节点随机布置, 分别取 $K=7, 8, 9$. 采用各种邻居节点选择算法, 并应用局部线性嵌入(LLE)、DHLLE、ISOMAP 等方法进行位置估计, 由此获得的网络联通图如图 3 所示。结果表明, 当 $K=7, L_{\min}=3$, 邻居节点选择 TPKNN 算法、位置估计选择 DHLLE 方法时, 可以取得最优估计。

(2)定位精度. 节点随机布置, 令 $T=100$, 比较 DHLLE 方法、dwMDS 算法的估计位置与真实位置。DHLLE 方法、dwMDS 算法的估计值均具有 CRB(Cramer-Rao Bound)方差^[2], 但 dwMDS 和






图3 采用三维 DHLLE 算法时的连通图

MDS(Multidimensional Scaling)类算法的估计是有偏的,因为局部线性只是一个近似值,此类算法的估计值高于测地线^[2],而 DHLLE 几乎是无偏的,与实际位置更接近.因此,当节点随机撒播时,DHLLE 方法优于其他定位方法.dwMDS 算法是 MDS 类算法中性能最好的,因此下面仅给出 DHLLE 方法、dwMDS 算法的估计性能比较,如图4所示.

(3)每个点的估计位置与实际位置的均方根误差(RMSE) r_{RMSE} .图4中的位置均方根误差如图5所示,图中结果是2种方法在300个节点上运行



(a)二维 DHLLE 方法



(b)二维 dwMDS 算法

图4 DHLLE 方法与 dwMDS 算法的估计结果($K=7$)

200 次 Mento Carlo 后的平均 RMSE,其中 $K=7$.在实验中发现,当 K 取值不同时,DHLLE 的 RMSE 仍然最小,因此 DHLLE 方法定位精度比较高.




图5 各种流形学习算法性能与邻居节点数目的选择关系

(4)连通性阈值.连通阈值对 DHLLE 方法的定位精度有很大影响^[8],随机均匀分布的传感器网络测量结果的 RMSE 与连通阈值之间的关系如图6所示.从中可知,当测距阈值 $D=0.5$ 时,算法性能最好.距离测量的准确性会受到 D 的影响,因此算法可选择距离,使其不能过大.




图6 测距阈值对 RMSE 的影响

当节点密度过大时,DHLLE 方法性能下降,因为对于随机均匀分布的节点,测量噪声会导致局部近似不够精确.如果节点分布过密,连通度大于 15,必须附加其他手段对 DHLLE 方法进行补偿.

4 结 论

本文给出了基于流形学习算法的节点定位框架,相应地提出了 DHLLE 方法.使用 WSN 节点数据的相对关联关系可以确定坐标,减小单个节点的运算负载,提高传感器网络的定位精度,延长传感器网络的生命周期.与目前其他定位方法相比,DHLLE 方法的定位精度更高,算法复杂度较低.由

于其具有特异性能,所以该方法在无线传感器网络定位估计上具有广泛的应用前景.

参考文献:

- [1] Donoho D L, Grimes C. Hessian eigenmaps: locally linear embedding techniques for high-dimensional data [J]. Science, 2003, 100(10):5591-5596.
- [2] Patwari N, Ash J. Locating the nodes: cooperative localization in wireless sensor networks [J]. IEEE Signal Processing Magazine, 2005, 22(4):54-69.
- [3] Shang Y, Ruml W, Zhang Y, et al. Localization from mere connectivity[C]// Proceedings of the 4th ACM International Symp on Mobile Ad Hoc Networking & Computing. New York: ACM Press, 2003:201-212.
- [4] Costa J A, Patwari N, Hero III A O. Distributed multidimensional scaling with adaptive weighting for node localization in sensor networks [J]. ACM Trans on Sensor Networks, 2006, 2(1):39-64.
- [5] 张军平. 流形学习及应用 [D]. 北京:中国科学院研究生院, 2003.
- [6] 李善仓, 张德运. 无线传感器网中基于多维定标技术的节点定位方法 [J]. 西安交通大学学报, 2006, 40(12):127-130.
Li Shancang, Zhang Deyun. Distributed weighted MDS self-localization algorithm of wireless sensors network [J]. Journal of Xi'an Jiaotong University, 2006, 40(12):127-130.
- [7] Shang Y, Ruml W. Improved MDS-based localization [C]// Proceedings of the 23rd Conference of the IEEE Communications Society. Piscataway, USA: IEEE, 2004:2640-2651.
- [8] Patwari N, Hero III A O, Perkins M, et al. Relative location estimation in wireless sensor networks [J]. IEEE Trans on Sig Proc, 2003, 51(8):2137-2148.

(编辑 苗凌)