

文章编号:1004-9037(2014)06-1010-06

基于典型相关回归的多跳非测距定位方法

程炳华¹ 严筱永^{2,3} 胡勇¹

(1. 金陵科技学院计算机工程学院,南京,211169;2. 金陵科技学院智能科学与控制工程学院,南京,211169;
3. 东南大学仪器科学与工程学院,南京,210096)

摘要:多跳非测距定位方法是一种有效的、简单的节点定位方法,然而其一般仅适用于各向同性,节点密集网络。针对在各向异性网络中,多跳非测距定位方法定位性能低的问题,提出了基于典型相关回归非测距定位方法。该方法通过典型相关回归获得节点间跳数与欧氏距离精确的映射模型,并利用该映射获得未知节点到已知节点估计距离。仿真实验表明,该方法与现有算法相比具有更高的定位精度和定位稳定性。

关键词:无线传感器网络;非测距定位;典型相关回归

中图分类号:TP393 **文献标志码:**A

Multihop Range-Free Localization Algorithm Based on Canonical Correlation Regression

Cheng Binghua¹, Yan Xiaoyong^{2,3}, Hu Yong¹

(1. School of Computer Engineering, Jinling Institute of Technology, Nanjing, 211169, China;
2. School of Intelligence Science and Control, Jinling Institute of Technology, Nanjing, 211169, China;
3. School of Instrument Science and Engineering, Southeast University, Nanjing, 210096, China)

Abstract: Multihop range-free localization method is an effective and simple method to determine node location. However, it is generally suitable for isotropic and the node intensive network. Since the low performance of multihop range-free localization method in anisotropic networks, an improved scheme is proposed based on canonical correlation. This method obtains a high precision mapping model by canonical correlation regression between nodes hops and Euclidean distance, then obtains the estimated distance between unknown node and known node using the measurement of hop-count. It also solves the problem of multi-hop range free localization method, which the performance is low in anisotropic network. Experimental simulation results show that this method achieves higher accuracy and stability than other location algorithms.

Key words: wireless sensor network; range-free localization; canonical correlation regression

引 言

随着无线传感器网络(Wireless sensor network, WSN)技术快速的发展,传感器网络的应用越来越多。在各种应用中,检测到事件后关键的一个重要问题就是该事件发生的位置^[1]。据相关文献统计^[2],约80%的上下文感知信息与节点位置

有关。在许多传感器网络应用中节点的位置信息起着关键性的作用。例如,在商业应用中,需要知道仓库中物品的存放位置,又如,在养老院中需要确切的获知老人的位置;在公共的安全和军事应用中定位系统可被用于跟踪监狱中的犯人和导航公安干警、消防战士以完成他们的任务。

通过在传感器节点上加装GPS设备的方式可以很方便地获取节点位置信息,但它仅适用于室外

基金项目:国家自然科学基金面上(61375001)资助项目;江苏省高校自然科学研究(12KJD510006, 13KJD520004)资助项目;金陵科技学院学院博士启动金(JIT-B-201411)资助项目。

收稿日期:2014-05-31; **修订日期:**2014-06-30

无遮挡条件下,且受制于天空中的 GPS 卫星,在战争期间甚至可能将无法使用 GPS。此外,GPS 需要昂贵、高能耗的电子设备来精确控制卫星同步,故通过在每个节点上加装 GPS 设备获取节点的位置信息较难实现。因此,在传感器网络监测区域内,节点的位置一般是借助部分已知位置的节点通过一定的估计算法计算出来。

经过多年的研究和发展,研究人员提出了众多的位置估计方法。依据定位过程中是否测量节点间的距离,可以把定位算法分为基于测距定位算法和非测距定位算法^[3-6]。基于测距技术的定位方法精度一般高于非测距定位方法,但其性能受制于测距技术,由于节点的传输半径受到节点自身硬件、监测环境的限制,因而,基于测距的定位方法多用于小规模定位场景。非测距方法大多数是通过节点之间的连接关系来获得节点间的跳数,进而用跳距(平均每跳距离×跳数)来代替节点间的物理距离,获取节点的估计位置,因而非常适合大规模场景下的定位应用。然而,非测距算法一般只适用于各向同性的密集网络,在复杂环境下的各向异性网络中定位性能较差。针对复杂区域导致的各向异性的无线传感器网络中的节点定位问题,本文提出一种基于典型相关回归的多跳非测距定位方法—(Canonical correlation regression-multihop range-free, CCR-MRFL)。

典型相关分析(Canonical correlation analysis, CCA)^[7-8]是一种可行且强大的多元分析方法,它特别适合被用来处理和分析两类相关数据。CCA 更适合处理数据对,它更多地考虑具有相关性数据之间数据处理和分析,因而它也更适合回归算法。利用基于 CCA 为先驱的 CCR 可以更为有效和正确地构建非测距定位中的跳数到欧式距离映射关系,因此以此为基础的非测距方法定位性能优于以往方法。

1 背景知识和相关研究

对于一个传感器网络,假设存在一个映射函数 $f: \mathbf{R}^{2d} \rightarrow \mathbf{R}$, 描述了传感器节点对间的真实距离和测量距离映射关系。假设节点 x_i 到 x_j 的测量距离描述为 $h_{ij} = f(x_i, x_j)$, 而节点间的真实欧式距离为 d_{ij} , 当 $h_{ij} = f(x_i, x_j) = g(d_{ij})$, 其中, $g: \mathbf{R} \rightarrow \mathbf{R}$, 则此时的 WSN 被称为各向同性, 否则称为各向异性^[9]。各向同性网络在实际环境下非常少见,

而大多数存在的网络都为各向异性网络,各向异性主要是由于障碍物、部署不均匀以及部分节点不能工作等原因造成节点部署区域内有大的空洞。图 1 显示了等间隔规则部署的各向同性和 C 形随机部署的各向异性的网络拓扑图。

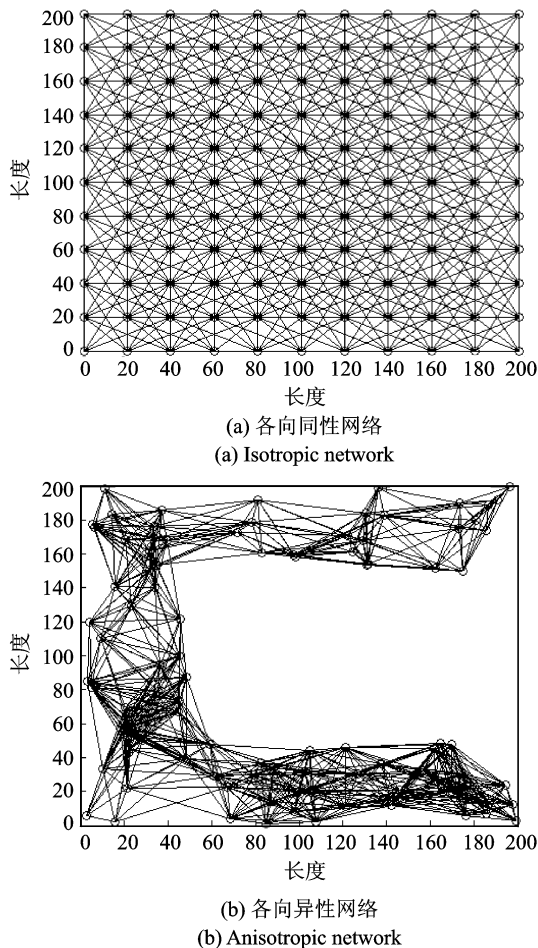


图 1 两类网络拓扑结构

Fig. 1 Two kinds of network topology

距离向量-跳段(distance vector-hop, DV-Hop)^[10-11]是一种典型的非测距方法,其假设节点间的最短跳数和单跳距离估计的路径长度与实际的欧式距离之间存在函数映射关系,利用跳距代替真实欧式距离对未知节点位置进行估计。DV-Hop 具有较好的分布性和可扩展性,它的定位精度主要依靠估计的平均每跳距离的精确度,但跳距与节点之间的实际距离相比较存在一定的误差,并且网络的拓扑结构也对定位的精度产生一定的影响,因而 DV-Hop 算法一般只适用于各向同性的密集网络,在各向异性网络中定位性能较差。

近几年以来,借助统计学习对定位机制进行建模和算法设计已成为研究热点之一^[12-14]。该方法利用利用节点之间的相似度或不相似度训练一个

预测模型;而后利用预测模型来估计节点的相对坐标或绝对坐标。由于通过统计学习方法可以获得优化转换矩阵,该矩阵能够实现对各向异性问题所造成的距离误差进行补偿,获得较为准确的跳数与欧式距离映射关系,使得算法能适应不同的环境。Shang 等人依据节点之间的连通性提出了基于学习方法 MDS-MAP 定位算法^[15],在假设网络中没有孤立的节点基础上,通过计算任意两个节点之间的最小跳数作为它们的距离,然后将定位问题转化为降维问题。该方法对节点的节点度要求高且需要网络全局连通,同样在网络拓扑各向异性环境下最短跳数距离与两点之间的欧氏距离相差较大,使得定位性能明显下降。针对各向异性问题,Hyuk 等人^[16]提出了一种基于截断奇异值分解 (Truncated singular value decomposition, TSVD)^[17] 的临近距离映射 (Proximity-distance map, PDM) 定位算法,其想法是:通过建立跳数与距离映射关系的基础上,采用矩阵变换的方法把测量距离(跳数)转换成估计距离。在各向异性网络中,PDM 算法一定程度上实现了对节点间测量距离的修正,提高了非测距定位方法对环境的适应能力,但其不足之处也十分明显,这些问题主要有 2 个方面,即:(1) TSVD 是通过设置一个阈值 k 直接将奇异值中小于阈值 k 的设置为零,如果 k 值选择合理,TSVD 的解稳定,反之则会使算法性能下降;(2) PDM 方法未对跳数与真实距离进行标准化处理,不同的量纲造成一定程度数据淹没现象。本文所提方法 CCR-MRFL 正是受 PDM 方法启发,针对其不足之处采用典型相关回归方法进行改进,该方法利用最大协方差指导构建跳数与真实距离映射,此外还用抽取的成分作回归,在一定程度上减弱了多重相关性的影响,因而,基于 CCR 的这种性质增强了非测距定位方法估计精度,提高了定位方法的性能。

2 CCR-MRFL 方法

2.1 问题描述

本文考虑由 n 个节点 X_i ($i=1,2,\dots,n$) 组成的无线传感器网络 $\{X_1, X_2, \dots, X_n\}$ 部署在 2 维的监测区域中。节点的 ID 分别为 $1, 2, \dots, n$, 节点 X_i 的真实坐标为 $c_i = (x_i, y_i)$, $\mathbf{C} = [c_1, c_2, \dots, c_n]^T$ 表示节点坐标矩阵。设 n 个节点中前 m ($m \ll n$) 个节点为信标节点,并令 $\mathbf{C}_b = [c_1, c_2, \dots, c_m]^T$ 表示信标节点的坐标矩阵。节点定位的目的是计算未知节点坐标的估计值 \hat{c}_i ($i=m+1, m+2, \dots, n$), 使

得估计坐标 \hat{c}_i 尽可能地接近未知节点的真实坐标 c_i 。信标节点在通信一段时间后采集到两组数据集:信标节点间的跳数矩阵 $\mathbf{H} = [h_1, \dots, h_m]$ 和欧式距离矩阵 $\mathbf{D} = [d_1, \dots, d_m]$, 其中 $\mathbf{h}_i = [h_{i1}, h_{i2}, \dots, h_{im}]^T$ 为第 i 个信标节点到其余已知节点的最小跳数。

2.2 定位算法

基于 CCR 方法的节点定位分两个阶段:训练阶段和定位阶段。在训练阶段通过对已知节点间跳数和物理距离学习训练出测量到真实距离的映射,建立定位模型;在定位阶段,未知节点通过它到信标节点的跳数,运用训练得出的映射模型对未知节点进行位置估计。

假设在训练阶段,信标节点在接受一段时间的信号值后,获得节点间的跳数矩阵 \mathbf{H} ($\mathbf{H} \in \mathbf{R}^p$) 和距离矩阵 \mathbf{D} ($\mathbf{D} \in \mathbf{R}^q$), 并设两组数据矩阵已进行过中心化处理。由于信标节点间的跳数与实际距离存在着一种关联关系,此时跳数与真实距离之间的关系表示为

$$\mathbf{D} = \mathbf{H}\boldsymbol{\mu} + \boldsymbol{\delta} \quad (1)$$

式中: $\boldsymbol{\mu} = (\mu_1, \mu_2, \dots, \mu_m)^T$ 为回归系数; $\boldsymbol{\delta}$ 为随机误差。

训练阶段 CCA 算法主要被用作寻找 \mathbf{H} 的线性组合 $\mathbf{w}_H^T \mathbf{H}$ 和 \mathbf{D} 的线性组合 $\mathbf{w}_D^T \mathbf{D}$, 使得它们具有最大互相关性,也就是说求下列等式的最大值

$$\rho = \frac{E[\mathbf{w}_H^T \mathbf{H} \mathbf{D}^T \mathbf{w}_D]}{\sqrt{E[\mathbf{w}_H^T \mathbf{H} \mathbf{H}^T \mathbf{w}_H] E[\mathbf{w}_D^T \mathbf{D} \mathbf{D}^T \mathbf{w}_D]}} = \frac{\mathbf{w}_H^T \mathbf{C}_{HD} \mathbf{w}_D}{\sqrt{\mathbf{w}_H^T \mathbf{C}_{HH} \mathbf{w}_H \mathbf{w}_D^T \mathbf{C}_{DD} \mathbf{w}_D}} \quad (2)$$

式中: $\mathbf{C}_{HH} \in \mathbf{R}^{p \times p}$, $\mathbf{C}_{DD} \in \mathbf{R}^{q \times q}$ 分别是 \mathbf{H} 和 \mathbf{D} 变量的集合内协方差矩阵, $\mathbf{C}_{HD} \in \mathbf{R}^{p \times q}$ 表示集合间协方差矩阵,且 $\mathbf{C}_{HD} = \mathbf{C}_{HD}^T \in \mathbf{R}^{p \times q}$ 。

相关性函数 ρ 关于 \mathbf{w}_H 和 \mathbf{w}_D 尺度无关,通过约束 \mathbf{H} 和 \mathbf{D} 集合内协方差 \mathbf{C}_{HH} 和 \mathbf{C}_{DD} , CCA 可表述为下列等式的优化问题的解

$$\begin{cases} \max_{\mathbf{w}_H, \mathbf{w}_D} \mathbf{w}_H^T \mathbf{C}_{HD} \mathbf{w}_D \\ \text{s. t. } \mathbf{w}_H^T \mathbf{C}_{HH} \mathbf{w}_H = 1, \mathbf{w}_D^T \mathbf{C}_{DD} \mathbf{w}_D = 1 \end{cases} \quad (3)$$

为了求式(3)这个最优问题,可以通过构建拉格朗日等式获得最优解,即

$$\begin{aligned} L(\mathbf{w}_H, \mathbf{w}_D, \lambda_1, \lambda_2) &= \mathbf{w}_H^T \mathbf{C}_{HD} \mathbf{w}_D + \\ &\frac{1}{2} \lambda_1 (1 - \mathbf{w}_H^T \mathbf{C}_{HH} \mathbf{w}_H) \\ &\frac{1}{2} \lambda_2 (1 - \mathbf{w}_D^T \mathbf{C}_{DD} \mathbf{w}_D) \end{aligned} \quad (4)$$

分别对式(4)用 w_H 和 w_D 求偏导,有

$$\begin{cases} \frac{\partial L}{\partial w_H} = C_{HD}w_D - \lambda_1 C_{AA}w_A \\ \frac{\partial L}{\partial w_D} = C_{DH}w_H - \lambda_2 C_{DD}w_D \end{cases} \quad (5)$$

为了获得最优解,令式(5)为零,得

$$\begin{cases} C_{HD}w_D = \lambda_1 C_{HH}w_H \\ C_{DH}w_H = \lambda_2 C_{DD}w_D \end{cases} \quad (6)$$

对式(6)两边分别左乘 w_H 和 w_D , 易得 $\lambda_1 = \lambda_2$, 记 $\lambda_1 = \lambda_2 = \lambda$, 则式(6)可化简为

$$\begin{cases} C_{HD}w_D = \lambda C_{HH}w_H \\ C_{DH}w_H = \lambda C_{DD}w_D \end{cases} \quad (7)$$

设 C_{DD} 可逆, 由式(7)中第 2 式可得 $w_D =$

$\frac{1}{\lambda} C_{DD}^{-1} C_{DH} w_H$, 代入式(7)中第 1 式, 整理得

$$\begin{cases} C_{HD} C_{DD}^{-1} C_{DH} w_H = \lambda^2 C_{HH} w_H \\ C_{DH} C_{HH}^{-1} C_{AD} w_D = \lambda^2 C_{DD} w_D \end{cases} \quad (8)$$

这时, CCA 的求解转化为解两个大小分别为 $p \times p$ 和 $q \times q$ 的矩阵广义特征值-特征向量问题。这样 CCA 问题等价地刻画为广义特征值问题

$$\begin{pmatrix} & HD^T \\ DH^T & \end{pmatrix} \begin{pmatrix} w_H \\ w_D \end{pmatrix} = \lambda \begin{pmatrix} HH^T & \\ & DD^T \end{pmatrix} \begin{pmatrix} w_H \\ w_D \end{pmatrix} \quad (9)$$

式(9)可以简记为 $Xw = \lambda Yw$, 其中 X, Y 分别对应于式(9)的左右两矩阵, $w = [w_H^T, w_D^T]^T$, 因此可知 w_H 和 w_D 分别是 $(H^T H)^{-1} H^T D (D^T D)^{-1} D^T H$ 和 $(D^T D)^{-1} D^T H (H^T H)^{-1} H^T D$ 的特征向量。

CCR^[18] 是将最小二乘与典型相关分析相结合, 其目标是在最大相关意义下优化求解回归系数。基于 CCA 的回归方法, 由于其采用互补原理, 最大化不同模态数据之间的相关性, 从而减少数据之间的不确定性, 达到增强识别能力的目的; 此外 CCR 关注输出、输入变量之间的相关性, 可以被看作是一种高级的两组多元变量之间的回归方法, 是多元线性回归^[7] (Multiple linear regression, MLR) 的推广, 也被称为是一种“多对多”的回归方法。典型相关回归的回归系数可以通过下列等式计算

$$\hat{\mu}_{CCR} = (W_k W_k^T) H^T D \quad (10)$$

式中: $W_k = [w_H^1, w_H^2, \dots, w_H^k]$ 由前 k 个最大特征向量组成。

至此, 定位模型为

$$D_{\text{pred}} = H \hat{\mu}_{CCR} = H_t (W_k W_k^T) H^T D \quad (11)$$

此时, 将未知节点到已知节点的跳数矩阵 H_t

带入式(11), 则可以获得相应的未知节点到已知节点的估计距离 D_{pred} 。最后, 结合已知节点坐标 (3 个以上信标节点) 和估计距离利用最小二乘法对未知节点进行估计获取估计坐标。

2.3 算法复杂度

CCR-MRFL 算法的复杂度主要包括: 通信复杂度和计算复杂度两部分。CCR-MRFL 算法的通信过程与 DV-Hop, PDM 方法类似, 都是通过 flood 方式计算节点间的跳数, 它们的通信开销约为 $O(n^2)$, 其中 n 为节点个数。对于计算复杂度而言, DV-Hop 方法需接受、发送反馈信息, 因此, 其计算复杂度约为 $O(n)$; PDM 方法的核心算法为 SVD, 其复杂度受制于 SVD 的复杂度, 其复杂度约为 $O(n^3)$; 本文所提出的 CCR-MRFL 方法, 其核心算法为 CCA, 因此其复杂度约为 $O(n^3 \log n)$ 。

3 CCR-MRFL 性能验证

为了检验 CCR-MRFL 算法的性能, 本文采用 Matlab 2013b 仿真软件进行了一系列试验比较。实验针对两类网络拓扑进行了验证, 即各向同性网络和各向异性网络。此外, 为了避免单次实验对实验结果的影响, 每种实验都进行了 100 次仿真, 每次试验里节点都将重新随机分布在实验区域, 统计每次的实验结果, 并取 100 次平均误差的平方^[19] 均值作为评价依据。实验还与同类型的 DV-Hop, PDM 算法进行了比较。为了公平起见, PDM 方法对 TSVD 设定舍弃特征值门限, 设舍去特征值小于等于 5 相对应的特征向量。

3.1 各向同性网络

在这组实验中, 共有 441 个节点, 这些节点规则、均匀的部署在 $600 \text{ m} \times 600 \text{ m}$ 方形区域内, 节点间的间隔为 30。实验假设信标节点数以步进为 2 从 40 逐步递增至 60。首先, 考察某次 CCR-MRFL 方法的最终定位结果 (图中信标节点数为 50), 如图 2 所示, 圆圈表示未知节点, 方块表示信标节点, 直线连接未知节点的真实坐标和它的估计坐标, 直线越长, 定位误差越大, 其 RMS 误差为 4.146。

图 3 显示的是 DV-Hop, PDM 和本文所提出的 CCR-MRFL 方法随信标节点数量变化而变化的 RMS 误差曲线图。理论上 DV-Hop 在各向同性密集网络中的定位效果较好, 但从图 3 显示方向




图2 CCR-MRFL方法在各向同性网络中的定位结果
Fig.2 Localization result based CCR-MRFL under isotropic network

并非如此,通过考察 DV-Hop 算法流程发现,它也是一种基于信标节点定位方法,在最后利用最小二乘定位时由于信标节点在一条直线上产生多重共线现象,使得算法估计不稳定,且误差较大,这就造成其 RMS 误差曲线上起伏、RMS 值较大。PDM 方法由于通过 TSVD 去除部分小特征值相对应的数据,但 TSVD 方法的舍弃门限是人为设定,且未考虑跳数和真实距离量纲问题,使得 PDM 定位性能有所改进,但改进效果较小。本文所提出的 CCR-MRFL 考虑到制约非测距定位性能的问题所在之处,因此从图 3 可以发现其 RMS 随信标节点数量的增加而减少,且相对其余两种方法在同样条件下 RMS 值最小。




图3 各向同性网络中 RMS 变化曲线

Fig.3 RMS error of different methods under isotropic network with different number of beacons

3.2 各向异性网络

在本组实验中共有 400 个节点随机的部署与一个含有障碍物的 $600\text{ m} \times 600\text{ m}$ 方形区域,障碍物大小为 $350\text{ m} \times 300\text{ m}$ 。实验同样假设信标节点数以步进为 2 从 40 逐步递增至 60。同样实验首

先考察一次 CCR-MRFL 方法的最终定位结果(图中信标节点数为 50),如图 4 所示此次实验的 RMS 误差为 4.45。




图4 CCR-MRFL方法在各向异性网络中的定位结果
Fig.4 Localization result based CCR-MRFL under anisotropic network

图 5 表示的是 DV-Hop, PDM 和本文所提出的 CCR-MRFL 方法在各向异性网络中随信标节点数量变化而变化的 RMS 误差曲线图。从图 5 可以看出, DV-Hop 对各向异性网络非常敏感, RMS 曲线不仅变化无规律,且 RMS 值较大,最大值接近 13。PDM 的定位性能在各向异性网络中相对有所改善但其 RMS 值最小也大于 5。本文所提出方法 RMS 值不仅小于 PDM 和 DV-Hop 两种方法,且从图 3 与图 5 两图中发现两条 RMS 曲线值较为接近,因此从另外一个方面可以看出 CCR-MRFL 方法既能适应各向同性网络又能适应各向异性网络,且定位精度较高。

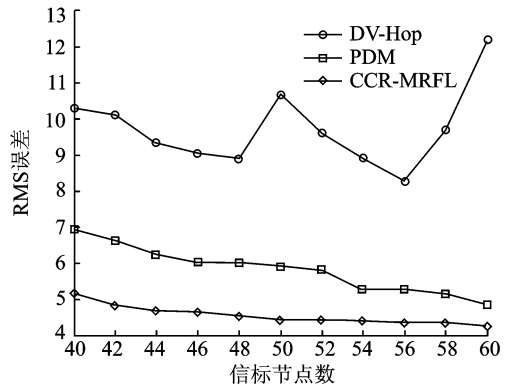


图5 各向异性网络中 RMS 变化曲线

Fig.5 RMS error of different methods under anisotropic network with different number of beacons

4 结束语

本文研究了基于典型相关回归的多跳非测距

定位方法。该方法的基本思想是通过典型相关回归构建信标节点间的跳数与真实距离构建跳数与距离的映射,进而将节点间的测量跳数转化为实际距离,实现在复杂环境下对距离估计的补偿。方法继承了原有多跳非测距方法的优点,同时在复杂的各向异性环境下保持优良的定位性能。然而与众多关键技术一样,CCR-MRFL 仍然存在诸多技术难题亟待解决,特别当信标节点数量较少或较多时都会给 CCR 的计算带来一定的困难,进一步的研究工作是在现有的基础上进行改进,以提高算法的适应性。

参考文献:

- [1] 李协,张效义,于旭,等. 相对定位估计的修正克拉美罗界[J]. 数据采集与处理, 2013, 28(2): 195-200.
Li Xie, Zhang Xiaoyi, Yu Xu, et al. Modified Cramer-rao bound for relative location estimation[J]. Journal of Data Acquisition and Processing, 2013, 28(2): 195-200.
- [2] 周艳. 智能空间中定位参考点的优化选择及误差分析[D]. 沈阳: 东北大学, 2009.
Zhou Yan. The optimizing selection and error analysis of position reference nodes in smart space[D]. Shenyang: Northeastern University, 2008.
- [3] Liu Y, Yang Z. Location, localization, and localizability location-awareness technology for wireless networks[M]. New York: Springer, 2011.
- [4] Mao G, Fidan B. Localization algorithms and strategies for wireless sensor networks: monitoring and surveillance techniques for target tracking[M]. New York: Information Science Reference, 2009.
- [5] Chen Z, Xia F, Huang T, et al. A localization method for the internet of things[J]. The Journal of Supercomputing, 2013, 63(3): 657-674.
- [6] Yanping Z, Daqing H. Localization algorithm using distance and angle information in wireless sensor networks[J]. Transactions of Nanjing Aeronautics and Astronautics, 2009, 26(1): 58-64.
- [7] 孙廷凯. 增强型典型相关分析研究与应用[D]. 南京: 南京航空航天大学, 2006.
Sun Tingkai. Research on enhanced canonical correlation analysis with applications [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2006.
- [8] 顾晶晶, 陈松灿, 庄毅. 用局部保持典型相关分析定位无线传感器网络节点[J]. 软件学报, 2010, 21(11): 2883-2891.
Gu Jingjing, Chen Songcan, Zhuang Yi. Localization in wireless sensor network using locality preserving canonical correlation analysis [J]. Journal of Software, 2010, 21(11): 2883-2891.
- [9] Zhou G, He T, Krishnamurthy S, et al. Models and solutions for radio irregularity in wireless sensor networks[J]. ACM Transactions on Sensor Networks (TOSN), 2006, 2(2): 221-262.
- [10] Niculescu D, Nath B. DV based positioning in ad hoc networks [J]. Telecommunication Systems, 2003, 22(1/4): 267-280.
- [11] Wu G, Wang S, Wang B, et al. A novel range-free localization based on regulated neighborhood distance for wireless ad hoc and sensor networks[J]. Computer Networks, 2012, 56(2012): 3581-3593.
- [12] Lee J, Choi B, Kim E. Novel range-free localization based on multidimensional support vector regression trained in the primal space[J]. IEEE Transactions on Neural Networks and Learning Systems, 2013, 24(7): 1099-1113.
- [13] Fang S H, Lin T N. Principal component localization in indoor WLAN environments[J]. IEEE Transactions on Mobile Computing, 2012, 11(1): 100-110.
- [14] 陈祠, 牟楠, 张晨, 等. 基于主成分分析的室内指纹定位模型[J]. 软件学报, 2013, 24(S1): 98-107.
Chen Ci, Mu Nan, Zhang Chen, et al. Indoor fingerprint positioning model based on principal component analysis[J]. Journal of Software, 2013, 24(S1): 98-107.
- [15] Shang Y, Ruml W, Zhang Y, et al. Localization from mere connectivity[C]//MobiHoc '03 Proceedings of the 4th ACM International Symposium on Mobile ad Hoc Networking & Computing. [S. l.]: ACM, 2003: 201-212.
- [16] Lim H, Hou J C. Distributed localization for anisotropic sensor networks[J]. ACM Transactions on Sensor Networks (TOSN), 2009, 5(2): 1-26.
- [17] Hogben L. Handbook of linear algebra[M]. United Kingdom: CRC Press, 2007.
- [18] Hyötyniemi H. Multivariate regression-techniques and tools[EB/OL]. <http://autsys.aalto.fi/en/publications/25041,2001-07-01>.
- [19] Huang J, Xue Y, Yang L. An efficient closed-form solution for joint synchronization and localization using TOA [J]. Future Generation Computer Systems, 2013, 29(3): 776-781.

作者简介:程炳华(1977-),男,讲师,研究方向:无线传感网络、模式识别、机器学习等,E-mail:cbh@jit.edu.cn;严筱永(1977-),男,博士后,讲师,研究方向:机器学习、人工智能、物联网等;胡勇(1972-),男,博士,副教授,研究方向:模式识别、图像处理。