

文章编号:1007-5321(2021)06-0067-07

DOI:10.13190/j.jbupt.2021-016

混合噪声下移动受限水声传感器网络自定位算法

胡克勇, 宋相琳, 郭小兰, 孙中卫, 宋传旺

(青岛理工大学 信息与控制工程学院, 青岛 266520)

摘要: 现有的水声传感器网络定位算法需要信标节点辅助定位, 测距噪声服从高斯分布, 定位成本高, 精度低, 对此, 提出一种混合测距噪声下基于最大后验概率的自定位算法. 首先对受限移动节点的移动模式进行建模以获取节点位置的先验信息, 测量节点间距离并基于加性和乘性混合噪声构建似然函数, 在贝叶斯框架下将节点位置的先验与似然信息进行融合, 通过最大化后验概率得到定位目标函数; 然后利用 BFGS 拟牛顿法对目标函数进行优化求解. 仿真结果表明, 相比同类定位方法, 所提方法无需信标节点, 定位精度高, 收敛速度快, 且对测距噪声的变化具有鲁棒性.

关键词: 水声传感器网络; 无信标定位; 最大后验概率估计; 拟牛顿优化

中图分类号: TP212.9

文献标志码: A

Self-Localization Algorithm for Drifting-Restricted Underwater Acoustic Sensor Networks under Mixed Noise

HU Ke-yong, SONG Xiang-lin, GUO Xiao-lan, SUN Zhong-wei, SONG Chuan-wang

(School of Information and Control Engineering, Qingdao University of Technology, Qingdao 266520, China)

Abstract: Existing localization algorithms for underwater acoustic sensor networks need the presence of beacon nodes and assume that measurement noises follow Gaussian distributions, resulting in high cost and low accuracy. To address these problems, a self-localization algorithm based on maximum a posteriori is proposed for drifting-restricted underwater acoustic sensor networks under mixed measurement noises. We analyze nodes' mobility patterns to obtain the prior knowledge for localization, and characterize distance measurements under the assumption of additive and multiplicative noises as the likelihood information for localization. Under the Bayesian framework, the priori and likelihood information are fused to derive localization objective function by maximum a posteriori probability. Then Broyden, Fletcher, Goldfarb and Shanno quasi-Newton method is resorted to solve the objective function. The simulation results show that compared with similar localization methods, the proposed method does not need the presence of beacon nodes, and it has the advantages of high localization accuracy, fast convergence speed, and being robust to changes in measurement noises.

Key words: underwater acoustic sensor networks; beacon-free localization; maximum posterior probability estimation; quasi-Newton optimization

收稿日期: 2021-01-31

基金项目: 国家自然科学基金项目(61902205); 山东省自然科学基金项目(ZR2019BD019, ZR2020MF001); 青岛理工大学本科教学改革与研究项目(F2020-001)

作者简介: 胡克勇(1986—), 男, 副教授.

通信作者: 孙中卫(1989—), 男, 副教授, E-mail: sunzhongwei0423@126.com.

水声传感器网络在水下监测、污染检测、灾害预防等诸多领域得到了广泛应用^[1]. 通过在特定水域部署不同类型的节点,包括浮动传感器节点、海面浮标、水下航行器等^[2],协同感知水下环境,并结合节点位置信息对感知到的数据进行分析,为上层应用提供决策支持. 因此,定位是水声传感器网络中的关键服务之一.

水声传感器网络定位的性能主要取决于测距精度和算法效率. 测距方法主要包括到达时间(TOA, time of arrival)、到达时间差、到达角度和接收信号强度. TOA 方法使用较多,利用数据包发送和接收的时间差来估计距离,但需要发送节点和接收节点之间的时间同步. 复杂的水下环境对 TOA 方法的精度影响较大. 由于存在障碍物,如海面、岩石和海洋动物^[3],声信号会以视距(LOS, line of sight)或非视距(NLOS, non-line of sight)通信链路到达,而水声信道具有时变和频率选择性的特性^[3],LOS 信号并不总具有最强的能量,这会使 NLOS 信号被误认为 LOS 信号,降低 TOA 方法的测距精度;其次,声速随深度、温度和盐度而变化^[4],导致信号沿非直线传播,简单地将信号传播时延与恒定声速相乘会产生较大误差. 现有研究中大多假设上述问题产生的误差服从期望和方差固定的高斯分布,但实际上传播时延的误差往往随 2 个节点之间距离的增大而增加^[5].

传统定位算法一般假设节点随海流自由漂移,需要信标节点辅助定位,且信标节点的数量往往随着网络规模的增大而增加. 这既增加了网络成本,也增加了网络回收和维护的难度. Guo 等^[6]研究了移动受限的水声传感器网络,并提出无信标节点的定位算法(AFLA, anchor-free localization algorithm),利用 3 个相邻节点的几何关系,形成 6 个等式来求解节点位置. 然而,没有考虑随距离变化的噪声,直接在解空间中搜索,计算量大,不能保证算法收敛,难以应用于实际水声传感器网络定位. 针对上述问题,利用网络拓扑结构中隐含的先验定位信息,考虑测距噪声服从加性和乘性噪声的混合高斯分布,提出一种基于最大后验概率的节点自定位(MAPSL, maximum a posteriori based self-localization)算法. 仿真实验结果表明,该算法的定位精度高于同类方法,且对噪声变化不敏感,鲁棒性更好.

1 网络模型和问题定义

1.1 网络模型

移动受限水声传感器网络模型如图 1 所示. 每个节点通过缆绳与锚点相连,节点的移动被限制在一个局部区域内. 以节点 i 为例,令 L_i 为其缆绳的长度, A_i 为其锚点的位置. 在部署阶段,为防止不同节点的缆绳缠绕在一起,节点 i 和节点 j 的锚点距离应大于其缆绳长度之和, $\|A_i - A_j\|_2 \geq L_i + L_j$;为保证节点持续漂浮在水中,缆绳的长度应小于海深 H . 由于缆绳具有张力,各节点的深度应满足 $0 < h_i < L_i$.

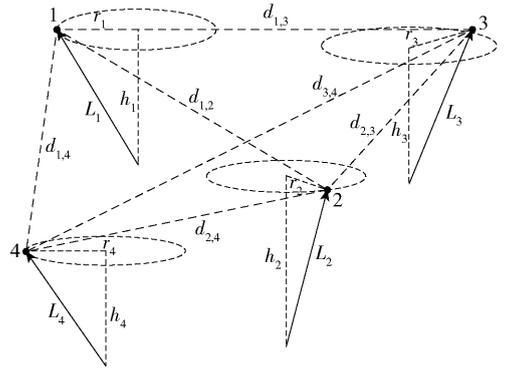


图 1 网络模型

通常情况下,节点的运动受洋流、浮力和缆绳多力作用影响. 在特定的深度,作用力可达到平衡状态,节点可以在这个深度的平面上沿着以锚点为中心的圆移动. 根据勾股定理,对于节点 i ,有

$$h_i^2 + r_i^2 = L_i^2 \quad (1)$$

其中 r_i 为移动圆的半径.

根据式(1), $r_i = \sqrt{L_i^2 - h_i^2}$,深度 h_i 可通过配备廉价的压力传感器获得. 节点 i 的位置被约束在一个以锚点 A_i 为中心,半径为 r_i 的圆上. 这种对节点位置的约束可以看作隐藏在网络拓扑结构中的先验信息,有利于缩小定位解的搜索空间,从而提高定位精度与速度.

为了利用节点间的空间距离关系进行定位,相邻节点之间采用双向 TOA 方法测距. 一方面,双向 TOA 方法可以消除节点之间的时钟偏移,无需时间同步;另一方面,由于水声信道内在的不可靠性,水声传感器网络媒体接入控制(MAC, medium access control)协议通常采用确认机制,即使采用单向 TOA 方法,每个数据包也需要一个确认包来保证传输成功,这与双向 TOA^[7]工作方式类似. 目前已有多种

MAC 协议^[8]用于数据包传输和解决数据包冲突. 以2个节点 A 和 B 为例说明双向 TOA 方法的工作过程. 节点 A 在 t_1 时刻发送一个测距数据包, 节点 B 在 t_2 时刻接收该数据包, 并在 t_3 时刻响应确认, 节点 A 在 t_4 时刻收到响应, 传播时延可计算为

$$t_p = \frac{t_4 + t_2 - t_1 - t_3}{2} \quad (2)$$

则节点 A 和节点 B 之间的距离可以估计为

$$d = t_p c \quad (3)$$

其中 c 为水下声信号的传播速度. 基于先验定位信息和节点间的空间关系, 定位算法需尽可能快速准确地估计出所有节点的位置, 同时降低计算成本.

1.2 问题定义

假设网络中有 N 个节点, 每个节点周期性地获取自身位置, T 为定位周期. 节点 i 在以锚点 A_i 为中心, 半径为 r_i 的圆上移动, 其二维位置可表示为

$$\left. \begin{aligned} x_i &= x_A^i + r_i \cos \theta_i \\ y_i &= y_A^i + r_i \sin \theta_i \end{aligned} \right\} \quad (4)$$

其中: (x_i, y_i) 为节点 i 在 x 轴和 y 轴方向上的位置, (x_A^i, y_A^i) 为锚点 A_i 在 x 轴和 y 轴方向上的位置, θ 为 x 轴与连接锚点和节点连线之间的方位角. 为简化描述, 式(4)省略了第 n 个定位周期节点位置 (x_i^n, y_i^n) 的上标. 通过节点间通信, 找到 M 个节点, 形成一个节点簇 S , 节点的个数应大于3(图1中的节点数为4), 并且这些节点应互为邻居节点, 即簇中任意2个节点 i 和 j 的位置应满足 $\|X_i - X_j\|_2 \leq \min(C_i, C_j)$, 其中 $X_i = (x_i, y_i, h_i)^T$ 表示节点 i 的三维位置, C_i 为节点 i 的通信半径.

根据式(2)和式(3)可得到簇中任意2个节点之间的距离估计 $z_{i,j}$. 在簇 S 中, 共有 $M(M-1)/2$ 对节点, 每对节点都有相应的距离估计, 簇的测距值可表示为 $Z = \{z_{i,j} | \forall i, j = 1, 2, \dots, M, i < j\}$. 以同样方式可以找到网络中的其他簇, 并得到相应的测量值. 对于每个簇, 现在已知簇中各节点的移动轨迹, 并已获得任意2个节点之间的测距值, 这些信息可看作是对簇中节点位置的约束, 定位问题可转变为使用合适的模型将这些信息进行融合, 并利用优化方法精准求解符合这些约束的所有簇节点的位置.

2 MAPSL 算法

2.1 最大后验估计

考虑到实际部署中锚点位移、缆绳长度、节点体积等引起的误差, 节点可能无法准确地沿着其轨迹

移动, 为表征节点的移动模式, 假设每个节点的位置随机分布在移动圆的周围, 则有

$$\left. \begin{aligned} x_i &= \hat{x}_i + w_x^i \\ y_i &= \hat{y}_i + w_y^i \end{aligned} \right\} \quad (5)$$

其中: $\hat{x}_i = x_A^i + r_i \cos \theta_i$; $\hat{y}_i = y_A^i + r_i \sin \theta_i$; w_x^i 和 w_y^i 分别为节点 i 在 x 轴和 y 轴方向上的噪声, 服从均值为零, 精度为 Λ 的高斯分布, 即 $w_x^i \sim \mathcal{N}(0, \Lambda)$ 和 $w_y^i \sim \mathcal{N}(0, \Lambda)$. 将式(5)用向量的形式表示为

$$\mathbf{x}_i = \hat{\mathbf{x}}_i + \mathbf{w}_i \quad (6)$$

其中 $\mathbf{x}_i = (x_i, y_i)$ 表示节点 i 的二维位置, $\hat{\mathbf{x}}_i = (\hat{x}_i, \hat{y}_i)^T$ 且 $\mathbf{w}_i = (w_x^i, w_y^i)^T$. 为简化描述, 假设 w_x^i 和 w_y^i 互不相关. 噪声 w_i 是一个均值为零, 精度矩阵为 $\Lambda \mathbf{I}$ 的高斯变量, 其中精度矩阵为方差矩阵的逆矩阵, \mathbf{I} 为单位矩阵. 为表述方便, 采用文献[9]中的记法, 在概率分布中均用精度表示方差的倒数. 因此, 节点 i 的位置服从均值为 $\hat{\mathbf{x}}_i$, 精度 $\Lambda \mathbf{I}$ 的联合高斯分布:

$$p(\mathbf{x}_i) = \mathcal{N}(\mathbf{x}_i | \hat{\mathbf{x}}_i, \Lambda \mathbf{I}) \quad (7)$$

由于水声信号是非直线传播, TOA 的误差随实际距离相应地增大^[5], 使用加性和乘性噪声^[10]对距离测量进行建模, 节点 i 与 j 之间的测距值可表示为

$$z_{i,j} = (1 + \alpha_{i,j}) d_{i,j} + \beta_{i,j} = d_{i,j} + \eta_{i,j} \quad (8)$$

其中 $d_{i,j} = \|X_i - X_j\|$ 为节点 i 和节点 j 之间的实际距离; $\alpha_{i,j}$ 为乘性噪声, 服从均值为 μ_α 、精度为 λ_α 的高斯分布, 即 $\alpha_{i,j} \sim \mathcal{N}(\mu_\alpha, \lambda_\alpha)$; $\beta_{i,j}$ 为加性噪声, 服从均值为零、精度为 λ_β 的高斯分布, 即 $\beta_{i,j} \sim \mathcal{N}(0, \lambda_\beta)$. 假设这2种类型的噪声互不相关, 总的噪声可用 $\eta_{i,j} = \alpha_{i,j} d_{i,j} + \beta_{i,j}$ 表示, 服从均值为 $\mu_{i,j} = \mu_\alpha d_{i,j}$, 精度为 $\lambda_{i,j} = (\lambda_\alpha^{-1} d_{i,j}^2 + \lambda_\beta^{-1})^{-1}$ 的高斯分布. 在 \mathbf{x}_i 和 \mathbf{x}_j 条件下, $z_{i,j}$ 的条件概率分布可写为

$$p(z_{i,j} | \mathbf{x}_i, \mathbf{x}_j) = \frac{1}{\sqrt{2\pi}} \lambda_{i,j}^{\frac{1}{2}} \exp \left\{ -\frac{1}{2} \lambda_{i,j} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j})^2 \right\} \quad (9)$$

对于簇 S 中的所有测距值 Z , 节点位置 $\mathbf{X} = [\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_M]^T$ 的似然函数为

$$p(Z | \mathbf{X}) = \prod_{z_{i,j} \in Z} p(z_{i,j} | \mathbf{x}_i, \mathbf{x}_j) \quad (10)$$

由式(7)可知, 位置 \mathbf{X} 的先验概率分布为

$$p(\mathbf{X}) = \prod_{i=1}^M p(\mathbf{x}_i) \quad (11)$$

利用贝叶斯定理, 给定测量值 Z , \mathbf{X} 的后验概率分布为

$$p(\mathbf{X} | Z) = p(Z | \mathbf{X}) p(\mathbf{X}) =$$

$$\prod_{z_{i,j} \in Z} p(z_{i,j} | \mathbf{x}_i, \mathbf{x}_j) \prod_{i=1}^M p(\mathbf{x}_i) \quad (12)$$

通过最大后验分布 $p(\mathbf{X} | Z)$ 确定位置 \mathbf{X} , 取 $p(\mathbf{X} | Z)$ 的对数, 可得

$$\ln p(\mathbf{X} | Z) = \sum_{z_{i,j} \in Z} \ln p(z_{i,j} | \mathbf{x}_i, \mathbf{x}_j) + \sum_{i=1}^M \ln p(\mathbf{x}_i) \quad (13)$$

将式(7)、式(9)代入式(13), 后验概率的最大值等价于最小化:

$$F(\mathbf{X}) = \sum_{z_{i,j} \in Z} \hat{\lambda}_{i,j} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j})^2 + \sum_{i=1}^M \Delta I(\mathbf{x}_i - \hat{\mathbf{x}}_i)^2 \quad (14)$$

其中忽略了与未知位置 \mathbf{X} 无关的项. 考虑到 $\lambda_{i,j}$ 依赖于由未知变量 \mathbf{X} 决定的实际距离 $d_{i,j}$, 而 $z_{i,j}$ 与 $d_{i,j}$ 之间的偏差远小于实际距离, 可用 $\hat{\lambda}_{i,j} = (\lambda_\alpha^{-1} z_{i,j}^2 + \lambda_\beta^{-1})^{-1}$ 代替 $\lambda_{i,j}$.

$\hat{\lambda}_{i,j}$ 与 $\hat{\lambda}_{k,l}$ ($z_{i,j}, z_{k,l} \in Z$) 的比值为

$$\frac{\hat{\lambda}_{i,j}}{\hat{\lambda}_{k,l}} = \frac{(\lambda_\alpha^{-1} z_{i,j}^2 + \lambda_\beta^{-1})^{-1}}{(\lambda_\alpha^{-1} z_{k,l}^2 + \lambda_\beta^{-1})^{-1}} \quad (15)$$

将式(15)的分子、分母同时乘以 λ_β^{-1} , 得到

$$\frac{\hat{\lambda}_{i,j}}{\hat{\lambda}_{k,l}} = \frac{(\lambda_\alpha^{-1} \lambda_\beta z_{i,j}^2 + 1)^{-1}}{(\lambda_\alpha^{-1} \lambda_\beta z_{k,l}^2 + 1)^{-1}} \quad (16)$$

考虑 λ_α 和 λ_β 的取值近似, 有 $\lambda_\alpha^{-1} \lambda_\beta z_{i,j}^2 \gg 1$, 则式(16)可简化为

$$\frac{\hat{\lambda}_{i,j}}{\hat{\lambda}_{k,l}} \approx \frac{z_{i,j}^{-2}}{z_{k,l}^{-2}} \quad (17)$$

然后, 可以将式(14)中的 $\hat{\lambda}_{i,j}$ 替换为 $z_{i,j}^{-2}$, 并执行与式(15)~(17)类似的操作. $\hat{\lambda}_{i,j}$ 与 Λ 的比值为

$$\frac{\hat{\lambda}_{i,j}}{\Lambda} \approx \frac{z_{i,j}^{-2}}{\lambda_\alpha^{-1} \Lambda} \quad (18)$$

则目标函数可改写为

$$F(\mathbf{X}) = \sum_{z_{i,j} \in Z} z_{i,j}^{-2} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j})^2 + \sum_{i=1}^M \delta I(\mathbf{x}_i - \hat{\mathbf{x}}_i)^2 \quad (19)$$

其中 $\delta = \lambda_\alpha^{-1} \Lambda$. 分析式(19), 对于第1个求和项, 每个平方误差项的权值与距离测量的平方成反比, 这表明位置解 \mathbf{X} 倾向于拟合高权重平方项. 因为距离较近的节点测距值具有较低的误差; 另一方面, 参数 δ 可以作为先验信息与似然信息之间的惩罚因子. 如果 δ 值较大, 则 \mathbf{X} 主要由先验信息确定, 节点位

置倾向于拟合其移动圆轨迹; 反之, \mathbf{X} 主要由似然信息确定, 节点位置倾向于拟合测距值, 允许每个节点在一定程度上偏离其移动轨迹.

2.2 节点位置估计

由于目标函数是位置变量 \mathbf{X} 的非线性函数, 没有解析解, 可以利用梯度下降法、牛顿法等进行优化求解. 采用 BFGS 拟牛顿法进行节点位置求解的优点在于二阶优化的收敛速度更快, 并且 Hessian 矩阵可以进行迭代更新, 避免了计算 Hessian 矩阵导致的算法运行时间长的问题.

在式(19)中, 除了位置变量 \mathbf{X} , 考虑到每次定位时测距噪声不同导致无法提前确定噪声参数, μ_α 与 δ 应同时进行优化求解, 总的优化变量可以表示为 $\Phi = \{\mathbf{X}, \mu_\alpha, \delta\}$. 应用牛顿法, 变量 \mathbf{X} 的迭代更新公式为

$$\Phi^{(k+1)} = \Phi^{(k)} - \gamma_k \mathbf{H}(\Phi^{(k)})^{-1} \nabla F(\Phi^{(k)}) \quad (20)$$

其中: γ_k 为从 $\Phi^{(k)}$ 出发的最优步长, $\mathbf{H}(\Phi^{(k)})$ 为目标函数在 $\Phi^{(k)}$ 处的 Hessian 矩阵, $\nabla F(\Phi^{(k)})$ 为目标函数在 $\Phi^{(k)}$ 处的梯度. 梯度可表示为

$$\nabla F(\Phi^{(k)}) = \begin{bmatrix} \frac{\partial F}{\partial \mathbf{X}} & \frac{\partial F}{\partial \mu_\alpha} & \frac{\partial F}{\partial \delta} \end{bmatrix}^T$$

其中

$$\frac{\partial F}{\partial \mu_\alpha} = - \sum_{z_{i,j} \in Z} 2d_{i,j} z_{i,j}^{-2} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j}) \quad (21)$$

$$\frac{\partial F}{\partial \delta} = \sum_{i=1}^M (\mathbf{x}_i - \hat{\mathbf{x}}_i)^2 \quad (22)$$

$$\frac{\partial F}{\partial \mathbf{X}} = \begin{bmatrix} \frac{\partial F}{\partial \mathbf{x}_1} & \frac{\partial F}{\partial \mathbf{x}_2} & \dots & \frac{\partial F}{\partial \mathbf{x}_M} \end{bmatrix}^T \quad (23)$$

进一步, $\frac{\partial F}{\partial \mathbf{x}_i} = \begin{bmatrix} \frac{\partial F}{\partial x_i} & \frac{\partial F}{\partial y_i} \end{bmatrix}^T$, 其中

$$\begin{aligned} \frac{\partial F}{\partial x_i} = & - \sum_{z_{i,j} \in Z} 2d_{i,j}^{-1} z_{i,j}^{-2} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j}) \times \\ & (1 + \mu_\alpha) (x_i - x_j) + \sum_{i=1}^M 2\delta (x_i - \hat{x}_i) \end{aligned} \quad (24)$$

$$\begin{aligned} \frac{\partial F}{\partial y_i} = & - \sum_{z_{i,j} \in Z} 2d_{i,j}^{-1} z_{i,j}^{-2} (z_{i,j} - d_{i,j} - \mu_\alpha d_{i,j}) \times \\ & (1 + \mu_\alpha) (y_i - y_j) + \sum_{i=1}^M 2\delta (y_i - \hat{y}_i) \end{aligned} \quad (25)$$

在 $\Phi^{(k+1)}$ 处, 用拟牛顿法构造一个对称矩阵近似 Hessian 矩阵的逆, 该近似矩阵要满足拟牛顿条件, 对目标函数 $F(\Phi)$ 进行二阶泰勒展开, 可得

$$F(\Phi) \approx F(\Phi^{(k+1)}) + \nabla F(\Phi^{(k+1)})^T (\Phi - \Phi^{(k+1)}) + \frac{1}{2} (\Phi - \Phi^{(k+1)})^T \mathbf{H}(\Phi^{(k+1)}) (\Phi - \Phi^{(k+1)}) \quad (26)$$

对式 (26) 两边求导并取 $\Phi = \Phi^{(k)}$ 可得

$$\begin{aligned} \nabla F(\Phi^{(k)}) &\approx \nabla F(\Phi^{(k+1)}) + \\ &H(\Phi^{(k+1)})(\Phi^{(k)} - \Phi^{(k+1)}) \end{aligned} \quad (27)$$

令 $g^{(k)} = \nabla F(\Phi^{(k+1)}) - \nabla F(\Phi^{(k)})$ 和 $u^{(k)} = \Phi^{(k+1)} - \Phi^{(k)}$, 则有

$$g^{(k)} \approx H(\Phi^{(k+1)})u^{(k)} \quad (28)$$

假设 $H(\Phi^{(k+1)})$ 可逆, $H_{k+1} = H(\Phi^{(k+1)})^{-1}$, 则可得拟牛顿条件

$$u^{(k)} \approx H_{k+1}g^{(k)} \quad (29)$$

可通过修正 H_k 得到 H_{k+1} , 即 $H_{k+1} = H_k + \Delta H_k$, BFGS 拟牛顿法给出修正矩阵为

$$\begin{aligned} \Delta H_k = &\frac{(u^{(k)T}g^{(k)} + g^{(k)T}H_k g^{(k)})(u^{(k)}u^{(k)T})}{(u^{(k)T}g^{(k)})^2} - \\ &\frac{H_k g^{(k)}u^{(k)T} + u^{(k)}g^{(k)T}H_k}{u^{(k)T}g^{(k)}} \end{aligned} \quad (30)$$

则可得拟牛顿法变量 Φ 迭代更新公式为

$$X^{(k+1)} = X^{(k)} - \gamma_k H_k \nabla F(X^{(k)}) \quad (31)$$

为方便计算, H_0 可初始化为任意一个对称正定矩阵, 通常取单位矩阵. 在确定步长 γ_k 时, 沿 $-H_k \nabla F(\Phi^{(k)})$ 方向进行搜索, 需满足如下条件:

$$\gamma_k = \arg \min_{\gamma \geq 0} F(\Phi^{(k)} - \gamma H_k \nabla F(\Phi^{(k)})) \quad (32)$$

由于 BFGS 拟牛顿法本质上是一种基于梯度的局部搜索方法, 选择较优的变量初始化值能够防止其陷入局部最优, 以提高定位精度及算法的收敛速度. 考虑到节点运动的连续性, 可使用前一时刻节点位置初始化当前时刻的位置变量, 在目标函数值变化小于阈值 ϵ 或目标函数计算次数大于阈值 J 时停止迭代. 运用 BFGS 拟牛顿法对目标函数 [式 (19)] 进行优化求解的详细步骤如算法 1 所示.

算法 1 节点位置求解

输入: 簇节点间测距值 Z , 簇节点锚点位置 $\{x_A^i, y_A^i\}_{i=1}^M$ 及移动半径 $\{r_i\}_{i=1}^M$, 阈值 ϵ, J

输出: 所有簇节点位置 $\{x_i\}_{i=1}^M$

① 初始化 $\Phi^{(0)}$, $\mu_\alpha = 0$, $\delta = 1$, $H_0 = I$, 根据式 (21) ~ 式 (25) 计算梯度 $\nabla F(\Phi^{(0)})$, 若节点 i 的前一时刻已定位, x_i 赋值为前一时刻位置; 否则, $x_i = (x_A^i + r_i, y_A^i)$

② while 不收敛 do

③ 确定搜索方向 $-H_k \nabla F(\Phi^{(k)})$, 根据式 (32) 确定步长 γ_k

④ 根据式 (31) 更新解 $\Phi^{(k+1)}$

⑤ 根据式 (21) ~ 式 (25) 计算目标函数在

$\Phi^{(k+1)}$ 处的梯度 $\nabla F(\Phi^{(k+1)})$

⑥ 计算 $g^{(k)} = \nabla F(\Phi^{(k+1)}) - \nabla F(\Phi^{(k)})$ 及 $u^{(k)} = \Phi^{(k+1)} - \Phi^{(k)}$

⑦ 根据式 (30) 计算 ΔH_k , 更新 $H_{k+1} = H_k + \Delta H_k$

⑧ $k = k + 1$

⑨ end while

3 仿真结果与分析

基于 Matlab R2018a, 对提出的算法进行仿真以验证其有效性. 在仿真中, 16 个未知节点随机部署在一个 $200 \text{ m} \times 200 \text{ m} \times 20 \text{ m}$ 的区域内, 每个节点通过长度 20 m 的缆绳连接到固定的锚点, 节点深度随机分布在 $[4, 16]$ 范围内, 以保证每个节点都漂浮在水下, 具有一定的监测覆盖范围, 所有节点的最大通信范围为 120 m.

节点位置噪声的精度为 50, 乘性噪声的均值和精度分别为 0.02 和 800, 加性噪声的精度为 500, 目标函数值变化阈值 10^{-6} . 为消除随机性影响, 每种不同条件的仿真独立运行 500 次, 每次仿真均持续 100 s, 定位周期为 1 s. 采用均方根误差 (RMSE, root mean squared error) 作为衡量定位精度的指标.

3.1 算法参数选取

节点数 M 对算法的定位精度和收敛速度有重要影响. 为确定最优的 M 值, 在定位过程中分别统计 M 为 4 ~ 11 时的平均 RMSE 及目标函数计算次数, 结果如图 2 所示. 由图可知, RMSE 总体上随 M 值的增大而持续降低, 这主要是由于节点间测距值数量随簇节点个数呈平方增长, 对节点位置施加了更严格的约束, 使得节点位置估计值更接近真实值. 同时, RMSE 在 M 处于 4 ~ 8 之间时下降较快, 随后

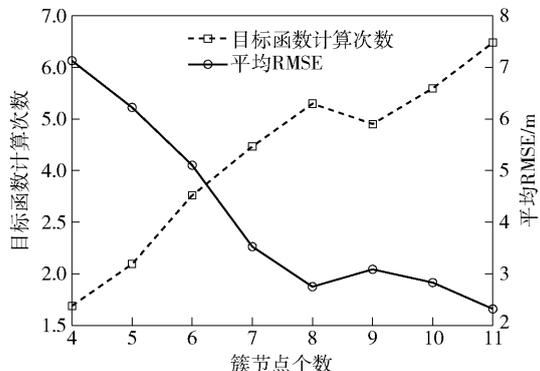


图 2 目标函数计算次数和平均 RMSE

下降变缓,表明簇节点的个数在增长到一定阈值后对提升定位精度的作用较小. 目标函数计算次数随 M 值的增大呈近似线性增加,这主要是因为优化变量 Φ 的维度随 M 值增加,在高维空间中搜索并确定最优步长时的计算次数也随之增加. 综合考虑定位误差和计算成本,簇节点数的最优值为 8.

为节省计算成本,确定最优的目标函数计算次数,针对不同大小簇分别统计目标函数计算次数取不同值时的定位误差,结果如图 3 所示. 由图 3 可知, RMSE 总体上随目标函数计算次数增大而持续降低,且下降速度先快后慢,随后趋于稳定,这表明目标函数计算次数在增长到一定阈值后对定位精度的提升有限. 对于不同的簇大小,定位误差随目标函数的计算次数下降趋势不同,导致阈值各不相同. 簇节点个数为 8 时目标函数计算次数阈值 J 为 3 500.

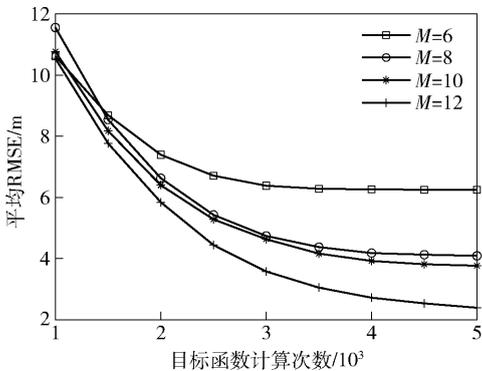


图 3 不同目标函数计算次数下的平均 RMSE

3.2 算法性能评估

加性噪声服从零均值高斯分布,设 μ_α 和 λ_α 分别为测距噪声水平和测距噪声精度, μ_α 分别取 0.05 和 0.1, λ_α 从 20 dB 增长到 50 dB,不同测距噪声精度下的平均 RMSE 如图 4 所示. 由图 4 可知,随着 λ_α 的增大,MAPSL 和 AFLA 算法的 RMSE 值都随之下降,这是由于 λ_α 越大测距噪声水平变化越小,定位越精确. 总体上,MAPSL 算法的 RMSE 明显低于 AFLA 算法的 RMSE,且 MAPSL 算法在 μ_α 为 0.05 和 0.1 时 RMSE 相差很小,对噪声水平的变化具有鲁棒性. 这主要是由于 MAPSL 算法同时兼顾了乘性和加性噪声,并通过在目标函数[式(19)]中的第 1 个求和项中减去 $\mu_\alpha d_{i,j}$ 而降低了测距噪声的影响.

为研究节点密度对算法性能的影响,定义节点密度为节点通信范围内的平均节点数量,通过调整

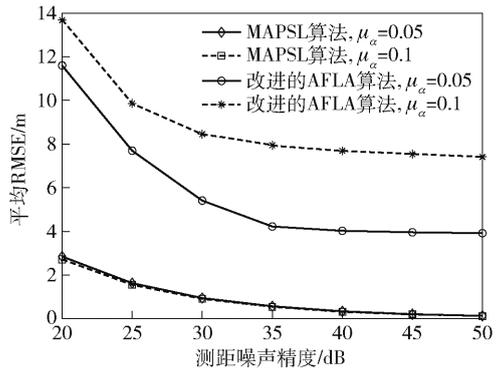


图 4 不同测距噪声精度下的平均 RMSE

网络中部署节点的数量,使节点密度由 8 变化到 13,不同节点密度下的平均 RMSE 如图 5 所示. 由图 5 可知,MAPSL 算法的定位性能明显优于 AFLA 算法,2 种算法的 RMSE 值在节点密度为 10 时有显著下降,在节点密度大于 10 时 RMSE 值趋于稳定. 这表明节点密度在增长到一定程度后对定位精度的提升较小. 根据此结果能够间接确定网络部署时的节点数量,从而以较小的网络成本实现高精度的节点定位.

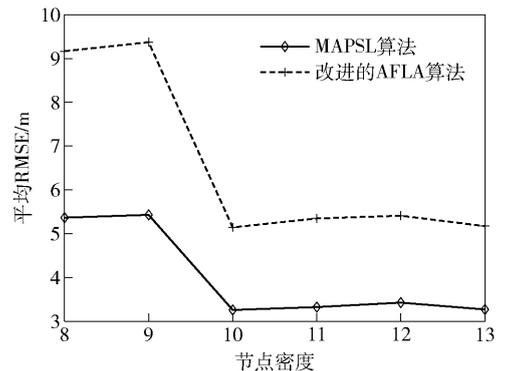


图 5 不同节点密度下的平均 RMSE

4 结束语

针对节点移动受限和水声传感器网络的定位问题,提出了自定位算法,融合了节点移动模式提供的先验信息和距离测量提供的似然信息,无需信标节点,定位精度高且对测距噪声变化具有鲁棒性. 后续将利用节点移动轨迹在时间上的连续性来提高定位性能.

参考文献:

- [1] 郭忠文, 罗汉江, 洪锋, 等. 水下无线传感器网络的研究进展[J]. 计算机研究与发展, 2010, 47(3): 377-389.

- Guo Zhongwen, Luo Hanjiang, Hong Feng, et al. Current progress and research issues in underwater sensor networks[J]. *Journal of Computer Research and Development*, 2010, 47(3): 377-389.
- [2] 闫敬, 张立, 罗小元, 等. 异步时钟下基于信息物理融合的水下潜器协同定位算法[J]. *自动化学报*, 2019, 45(4): 739-748.
- Yan Jing, Zhang Li, Luo Xiaoyuan, et al. Cyber-physical cooperative localization algorithms for underwater vehicle with asynchronous time clock[J]. *Acta Automatica Sinica*, 2019, 45(4): 739-748.
- [3] Diamant R, Tan H P, Lampe L. LOS and NLOS classification for underwater acoustic localization [J]. *IEEE Transactions on Mobile Computing*, 2014, 13(2): 311-323.
- [4] Zhang Yixin, Li Yuzhou, Zhang Yu, et al. Underwater anchor-AUV localization geometries with an isogradient sound speed profile: a CRLB-based optimality analysis[J]. *IEEE Transactions on Wireless Communications*, 2018, 17(12): 8228-8238.
- [5] Ramezani H, Leus G. Ranging in an underwater medium with multiple isogradient sound speed profile layers[J]. *Sensors*, 2012, 12(3): 2996-3017.
- [6] Guo Ying, Liu Yutao. Localization for anchor-free underwater sensor networks[J]. *Computers & Electrical Engineering*, 2013, 39(6): 1812-1821.
- [7] Zhou Feng, Li Yushi, Wu Hejun, et al. ProLo: localization via projection for three-dimensional mobile underwater sensor networks[J]. *Sensors*, 2019, 19(6): E1414.
- [8] Zhu Yibo, Zheng Peng, Cui Junhong, et al. Toward practical MAC design for underwater acoustic networks[J]. *IEEE Transactions on Mobile Computing*, 2015, 14(4): 872-886.
- [9] Zhou Bingpeng, Chen Qingchun, Wymeersch H, et al. Variational inference-based positioning with nondeterministic measurement accuracies and reference location errors[J]. *IEEE Transactions on Mobile Computing*, 2017, 16(10): 2955-2969.
- [10] Wang Xingbo, Fu Minyue, Zhang Huanshui. Target tracking in wireless sensor networks based on the combination of KF and MLE using distance measurements[J]. *IEEE Transactions on Mobile Computing*, 2012, 11(4): 567-576.