

DOI: 10.13382/j.jemi.B2407860

双参不确定的无线传感器网络三阶定位算法*

梅骁峻¹ 吴华锋¹ 陈信强² 鲜江峰² 吴中岱³

(1. 上海海事大学商船学院 上海 201306; 2. 上海海事大学物流科学与工程研究院 上海 201306;

3. 上海船舶运输科学研究所有限公司 上海 200135)

摘要: 节点定位是位置信息获取的重要手段,已成为无线传感器网络(WSNs)关键技术之一。针对WSNs基于信号衰减模型中发射功率(TP)、路径损耗因子(PLE)等参数不确定性导致定位精度下降的问题,提出一种由粗至细的三阶定位方法(CFTL)。首先,通过差分形式,消除TP不确定影响,应用泰勒级数一阶展开式和对数换底操作,将定位问题转化为自然常数的最小二乘估计(NC-LSE)框架,并通过线性无偏估计法求得粗粒度位置;其次,基于粗粒度信息,构建PLE为变量的目标优化函数,引入美洲狮优化(PO)算法,优化模型中PLE值;最后,代入优化后的PLE,建立差分广义信赖域子问题(DGTRS)框架,并运用二分法求得细粒度位置。此外,应用分块矩阵广义逆定理,还推导得到双参不确定条件下的克拉美罗下界(CRLB),以评估提出算法的有效性。仿真实验及实测结果表明,所提出方法能够在不同条件下,相比于现有方法在双参不确定情况的定位精度提升至少10.96%,最高达32.18%。

关键词: 定位;无线传感器网络;双参不确定;广义信赖域子问题;克拉美罗下界

中图分类号: TN92;TP393

文献标识码: A

国家标准学科分类代码: 510.40

Three-step localization algorithm in WSNs under two uncertain parameters

Mei Xiaojun¹ Wu Huafeng¹ Chen Xinqiang² Xian Jiangfeng² Wu Zhongdai³

(1. Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China;

2. Institute of Logistics Science and Engineering, Shanghai Maritime University, Shanghai 201306, China;

3. Shanghai Ship and Shipping Research Institute Co., Ltd., Shanghai 200135, China)

Abstract: Node localization is a critical technique for acquiring location information and has emerged as a fundamental technology within wireless sensor networks (WSNs). Localization accuracy in wireless sensor networks (WSNs) can deteriorate due to uncertainties in the transmit power (TP) and path loss exponent (PLE). To address this challenge, a coarse-to-fine third-order localization method (CFTL) is proposed. First, TP uncertainty is mitigated using differential forms. The problem is then reformulated into a natural constant-based least squares estimation (NC-LSE) framework through first-order Taylor expansion and logarithmic transformations, with coarse-grained positions obtained via a linear unbiased estimation method. Second, an optimization function with PLE as the variable is constructed, and the puma optimization (PO) algorithm is employed to estimate the PLE. Third, the optimized PLE is incorporated into the differential-based generalized trust region subproblem (DGTRS) framework, and the fine-grained position is calculated using the bisection method. Additionally, the generalized inverse theorem for block matrices is applied to derive the Cramér-Rao lower bound (CRLB) under dual-parameter uncertainty, assessing the algorithm's effectiveness. Simulation and practical results demonstrate that the proposed method enhances localization accuracy by at least 10.96% and up to 32.18% compared to existing methods across various conditions.

Keywords: localization; WSNs; two uncertain parameters; GTRS; CRLB

收稿日期:2024-09-28 Received Date: 2024-09-28

* 基金项目:国家自然科学基金(52201401, 52331012, 52071200, 52201403, 52102397)、国家重点研发计划(2021YFC2801000)、上海市优秀学术/技术带头人计划(22XD1431000)、上海市科学技术委员会重点项目(23010502000)、上海市教育发展基金会和上海市教育委员会“晨光计划”(24CGA52, 23CGA61)、水路交通控制全国重点实验室开放课题(QZ2022-Y016)项目资助

0 引言

无线传感器网络(wireless sensor networks, WSNs)是环境监测、资源开发等应用重要支撑手段之一^[1]。其中,定位是 WSNs 关键技术,可为路由、拓扑控制或数据处理分析等研究提供关键的位置信息^[2]。通常而言,WSNs 定位分为基于测距和基于非测距场景,相比于非测距场景,基于测距的场景能够获取较好的定位精度,是目前较为理想的定位手段^[3-4]。在基于测距的场景中,定位主要分为两个阶段:1) 测算距离;2) 位置解算。前者主要通过信号强度(received signal strength, RSS)、到达时间(time of arrival, TOA)、到达角度(angle of arrival, AOA)及到达时间差(time difference of arrival, TDOA)等技术获取,而后者主要通过一系列算法,并结合距离来求解^[5]。

相比于基于 TOA、AOA 或 TDOA 等手段的定位技术,基于 RSS 的技术无需时钟同步及其他额外设备的介入,因此被认为是低成本且可靠的定位方案^[6],并被学者们广泛研究^[7-8]。比如,郑安琪等^[9]针对定位匹配冗余问题,提出了空间双精简定位算法。潘志远等^[10]运用启发式方法的思想,提出利用蜣螂算法优化的定位方案。Wang 等^[11]考虑 RSS 测距有偏误差,设计了基于 l_1 和 l_2 范数的半定规划方案。Du 等^[12]提出一种权值最小距离定位方法以提高 RSS 定位的精度。张大龙等^[13]结合 RSS 和修正因子,优化跳数和跳距,并融合多策略的启发式算法求解目标位置。Mei 等^[6]针对 RSS 存在拜占庭攻击和非视距导致的异常测量值,将高度非凸问题转化为加权最小二乘框架,并提出了一种拜占庭容忍的定位方法。

上述相关研究均在设备和环境参数已知情况下展开。然而,该假设并不完全成立,比如,发射功率(transmit power, TP)会因设备的老化等因素而产生不确定性,导致实际 TP 和额定 TP 存在偏差,进而降低了定位精度^[3,14]。另一种不确定因素则是来自于环境中的路径损耗因子(path loss exponent, PLE),它会因湿度、温度的改变而变化,进而导致 RSS 观测值存在偏差,从而增加了定位误差^[15-16]。TP 和 PLE 的不确定性,使得基于 RSS 的定位技术仍然面临着严峻的挑战^[17]。一些学者分别针对 TP 或 PLE 不确定情况提出了相应的解决方案。比如,在 TP 不确定场景方面,Zhang 等^[18]通过差分操作,随后结合块坐标更新和有效集的方法,提出一种混合高斯噪声下的鲁棒定位算法。Yan 等^[19]同样考虑了混合高斯的场景,提出一种新的变分推理框架,联合估计 TP 和目标位置。在 PLE 不确定场景方面,Mei 等^[20]通过多次泰勒级数一阶展开,将 PLE 线性化为变量,通过

一种多阶线性化定位算法,联合估计目标位置和 PLE。Sari 等^[21]将 PLE 视为随机变量,随后推导得到基于最大似然的闭环表达式,以求解 PLE 位置情况下的目标位置。

但当 TP 和 PLE 双参数同时不确定时,上述的方案并不能取得良好的定位效果。为此,Najarro 等^[22]融合差分进化、对立学习和自适应重定向等方法,提出一种双参联合估计定位算法。Zhang 等^[23]运用一种递归椭圆集员滤波,该算法在预测阶段,限制每一瞬间可靠置信区域,并结合泰勒级数展开和交替递归的方式解决双参未知的定位场景。Zou 等^[24]针对双参未知的定位场景,通过松弛操作,将非凸的定位问题转化为一种新结构的半正定规划框架,联合估计双参和目标位置。Kang 等^[25]利用卡尔曼滤波估算双参,并根据角度信息初步估算目标位置。随后,结合估计的参数,融合角度和 RSS 信息进一步矫正目标位置。

然而,现有针对双参同时不确定时的定位方法大多基于先验知识进行研究。遗憾的是,当所处环境的先验知识未知时,该类方法的定位精度不能得到保障。因此,本文提出一种粗粒度至细粒度的三阶定位(coarse-to-fine three-step localization, CFTL)方法。该方法无需知道对应的先验知识,通过引入差分思想和美洲狮优化(puma optimization, PO),消除不确定性,并建立一种三阶的定位框架,保障双参不确定时的定位精度。

本文引入差分思想,消除了 TP 不确定的影响,并随机选取 PLE,构造基于自然常数的最小二乘估计(natural constant-based least squares estimation, NC-LSE)框架,结合线性无偏估计求得粗粒度位置,并基于此,综合考虑收敛性和求解精度,融合元启发优化算法,求得最优 PLE;基于优化后的 PLE,建立差分广义信赖域子问题(differential-based generalized trust regional subproblem, DGTRS)框架,利用二分法对细粒度位置进行估计。同时,结合分块矩阵广义逆定理,构建基于克拉美罗下界(Cramér-Rao lower bound, CRLB)的审查机制,评估算法的有效性;仿真和实测结果表明,提出的方法(CFTL)能够在双参不确定场景下保持较好的定位性能。并且在不同条件下,与现阶段提出的定位算法相比,定位精度得到了一定的提升。

1 问题描述

考虑 WSNs 网络中含有 N 个锚节点和 1 个待定位目标节点,第 i 个锚节点位置为 $\mathbf{a}_i = [a_{i1}, a_{i2}]^T$,其中 T 表示转置;待定位目标节点位置为 $\mathbf{x} = [x_1, x_2]^T$ 。假设锚节点和待定位目标节点可通过无线电信号进行信息交互,则锚节点收到来自目标节点的 RSS 值可表示为^[6]:

$$P_{ii} = P_0 - 10\alpha \log_{10} \frac{\|\mathbf{x} - \mathbf{a}_i\|}{d_0} + \gamma_i \quad (1)$$

式中: P_{ii} 表示第 i 个锚节点收到来自目标节点的 TP; d_0 为参考距离, 通常为 1 m; P_0 为目标节点的发射功率; α 表示 PLE, 经验值通常为 $[2, 6]$; $\|\cdot\|$ 表示二阶范数; γ_i 是均值为零方差为 σ_i^2 的高斯分布噪声。

令 $\mathbf{P}$ 表示 RSS 的观测向量, 则对于 N 个锚节点而言, $\mathbf{P} = [P_{i1}, P_{i2}, \dots, P_{iN}]^T$, 对应的联合概率密度分布函数 (probability density function, PDF) 可表示为:

$$p(\mathbf{P} | \mathbf{x}, P_0, \alpha) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma_i^2}} \cdot \exp \left\{ - \frac{\left(P_{ii} - P_0 + 10\alpha \log_{10} \frac{\|\mathbf{x} - \mathbf{a}_i\|}{d_0} \right)^2}{2\sigma_i^2} \right\} \quad (2)$$

当 TP 和 PLE 已知时, 可通过最大化式 (2) 的 PDF 获取目标节点的位置。然而, 由于设备的老化和环境参数的变化, TP 和 PLE 存在不确定性, 这使得式 (2) 呈现高度的非凸特性, 较难求得其闭环解。为此, 本文将原定位问题转化至 NC-LSE 估计框架, 并分 3 步进行联合估计, 以提高双参不确定条件下目标节点的定位精度。

2 CFTL 算法

本文提出的 CFTL 算法在 TP 和 PLE 不确定情况下的求解过程主要分为 3 步: 1) 结合差分操作, 建立 NC-LSE 框架, 并通过线性无偏估计获取目标节点粗粒度位置; 2) 基于粗粒度估计, 引入 PO 算法, 对 PLE 进行估计; 3) 代入优化后的 PLE, 建立 DGTRS 框架, 并通过二分法求解目标节点细粒度位置。

2.1 一阶粗粒度位置估计

引入 GPS 差分技术的思想, 选取第 1 个锚节点作为参考点, 对式 (1) 模型进行差分操作, 则可得到:

$$\tilde{P}_{j,1} = -10\alpha \log_{10} \frac{\|\mathbf{x} - \mathbf{a}_j\|}{\|\mathbf{x} - \mathbf{a}_1\|} + \tilde{\gamma}_{j,1} \quad (3)$$

式中: $\tilde{P}_{j,1} = P_{j1} - P_{11} (j = 2, \dots, N)$; $\tilde{\gamma}_{j,1} = \gamma_j - \gamma_1$ 。

由式 (3) 可知, 差分的操作可消除 TP 不确定性。随后将式 (3) 对数进行换底, 可得:

$$\frac{1}{10} \tilde{P}_{j,1} \ln 10 = -\alpha \ln \frac{d_j}{d_1} + \frac{1}{10} \tilde{\gamma}_{j,1} \ln 10 \quad (4)$$

式中: $d_j = \|\mathbf{x} - \mathbf{a}_j\|$; $d_1 = \|\mathbf{x} - \mathbf{a}_1\|$ 。

引入自然常数 e , 对式 (4) 进行移项及平方操作后可得:

$$e^{-\frac{2}{\alpha} \tilde{P}_{j,1}} = \left(\frac{d_j}{d_1} \right)^2 e^{-\frac{2}{\alpha} \tilde{\gamma}_{j,1}} \quad (5)$$

根据自然常数泰勒级数一阶展开式^[26], 将式 (5) 进行线性化展开:

$$e^{-\frac{2}{\alpha} \tilde{P}_{j,1}} \approx \left(\frac{d_j}{d_1} \right)^2 e^{\frac{2}{\alpha} (\lambda_j^2 + \lambda_1^2)} \quad (6)$$

式中: $\lambda_j^2 = \frac{1}{100} (\ln 10)^2 \sigma_j^2$; $\lambda_1^2 = \frac{1}{100} (\ln 10)^2 \sigma_1^2$ 。

令 $\rho_{j,1} = e^{-\frac{2}{\alpha} \tilde{P}_{j,1} - \frac{2}{\alpha} (\lambda_j^2 + \lambda_1^2)}$, 则式 (6) 可转化为:

$$\rho_{j,1} d_1^2 \approx d_j^2 \quad (7)$$

定义变量 $\boldsymbol{\theta} = [x_1, x_2, \chi]^T$, 其中 $\chi = \|\mathbf{x}\|^2$, 则原定位问题可进一步转化为 NC-LSE 框架:

$$\arg \min_{\boldsymbol{\theta}} \|\mathfrak{S}\boldsymbol{\theta} - \boldsymbol{\Psi}\|^2 \quad (8)$$

式中:

$$\mathfrak{S} = \begin{bmatrix} 2a_{21} - 2\rho_{2,1}a_{11} & 2a_{22} - 2\rho_{2,1}a_{12} & \rho_{2,1} - 1 \\ 2a_{31} - 2\rho_{3,1}a_{11} & 2a_{32} - 2\rho_{3,1}a_{12} & \rho_{3,1} - 1 \\ \vdots & \vdots & \vdots \\ 2a_{N1} - 2\rho_{N,1}a_{11} & 2a_{N2} - 2\rho_{N,1}a_{12} & \rho_{N,1} - 1 \end{bmatrix} \quad (9)$$

$$\boldsymbol{\Psi} = \begin{bmatrix} \|\mathbf{a}_2\|^2 - \rho_{2,1}\|\mathbf{a}_1\|^2 \\ \|\mathbf{a}_3\|^2 - \rho_{3,1}\|\mathbf{a}_1\|^2 \\ \vdots \\ \|\mathbf{a}_N\|^2 - \rho_{N,1}\|\mathbf{a}_1\|^2 \end{bmatrix} \quad (10)$$

通过式 (11) 的差分线性 LS 估计方法, 可得到目标节点初始位置估计值:

$$\boldsymbol{\theta} = (\mathfrak{S}^T \mathfrak{S})^{-1} \mathfrak{S}^T \boldsymbol{\Psi} \quad (11)$$

尽管通过差分操作消除了 TP 不确定影响, 但 PLE 的不确定性仍会使式 (11) 估计值存在较大误差。为此, 提出一种线性无偏估计方法提高初始位置估计精度。令 $\hat{x}_1^\circ, \hat{x}_2^\circ, \hat{x}_3^\circ$ 分别为式 (11) 求解得到 $\hat{\boldsymbol{\theta}}$ 的 3 个元素, 且 $\hat{\mathbf{x}}^\circ = [\hat{x}_1^\circ, \hat{x}_2^\circ]^T$ 。运用泰勒级数一阶展开式, 对 $(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}})$ 在 $\hat{\mathbf{x}}^\circ$ 接近 $\mathbf{x}$ 处进行线性展开:

$$(\boldsymbol{\theta} - \hat{\boldsymbol{\theta}}) = \boldsymbol{\Xi} + \boldsymbol{\Gamma}(\hat{\mathbf{x}}^\circ - \mathbf{x}) \quad (12)$$

式中: $\boldsymbol{\Xi} = [\mathbf{0}_{2 \times 1}, \|\hat{\mathbf{x}}^\circ\|^2 - \hat{x}_3^\circ]^T$; $\boldsymbol{\Gamma} = [\mathbf{I}_2, 2(\hat{\mathbf{x}}^\circ)^T]^T$; $\mathbf{I}$ 为单位矩阵。

修正后的粗粒度估计值 $\hat{\mathbf{x}}_c$ 则可表示为:

$$\hat{\mathbf{x}}_c = \hat{\mathbf{x}}^\circ - (\boldsymbol{\Gamma}^T \mathfrak{S}^T \mathfrak{S} \boldsymbol{\Gamma})^{-1} \boldsymbol{\Gamma}^T \mathfrak{S}^T \boldsymbol{\Xi} \quad (13)$$

2.2 二阶 PLE 估计

根据一阶粗粒度估计值, 分别根据欧氏几何距离公式, 计算对应的估计距离 $\hat{d}_j = \|\hat{\mathbf{x}}_c - \mathbf{a}_j\|$ 和 $\hat{d}_1 = \|\hat{\mathbf{x}}_c - \mathbf{a}_1\|$ 。根据式 (7) 所示, 以 α 为变量, 构建优化函数为:

$$\hat{\alpha}^* = \arg \min_{2 \leq \hat{\alpha}^* \leq 6} \sum_{j=2}^N (\rho_{j,1} d_1^2 - d_j^2)^2 \quad (14)$$

PO 算法是 Mirjalili 等根据美洲狮搜寻猎物 and 狩猎行

为新设计的一种元启发式算法,相比于现阶段最新提出的元启发式算法而言,其收敛速度和求解精度占据一定优势^[27]。PO 算法考虑了美洲狮狩猎行为的历史经验,创新性地提出一种相变机制,在前 3 次迭代同时运行勘探(搜寻)和开发(狩猎)步骤,模拟美洲狮早期对生活空间不熟悉,有猎物地区不明确的问题。在第 4 次迭代开始切换对应机制,每次根据条件只执行勘探或开发的操作,模拟美洲狮熟悉环境后的狩猎行为。由于篇幅限制,PO 对应原理不在本文进行描述,详细过程可参考文献[27]。运用 PO 元启发式算法,以式(14)为目标优化函数,进而求得最优的不确定参量 $\hat{\alpha}^*$ 。

2.3 三阶细粒度位置估计

根据第 2 阶段计算的 $\hat{\alpha}^*$ 代入式(3)后,可得:

$$\tilde{P}_{j,1} = -10\hat{\alpha}^* \log_{10} \frac{d_j}{d_1} + \tilde{\gamma}_{j,1} \quad (15)$$

对式(15)进行移项,并对指数项进行泰勒级数一阶展开:

$$10^{\frac{\tilde{P}_{j,1}}{10\hat{\alpha}^*}} d_j \approx d_1 \left(1 + \frac{\ln 10}{10\hat{\alpha}^*} \tilde{\gamma}_{j,1} \right) \quad (16)$$

随后可进一步构造差分 LS 框架:

$$\arg \min_x \sum_{j=2}^N \left(10^{\frac{\tilde{P}_{j,1}}{5\hat{\alpha}^*}} d_j^2 - d_1^2 \right)^2 \quad (17)$$

令 $\mathbf{Q} = [\mathbf{x}^T, \|\mathbf{x}\|^2]^T$, 引入矩阵乘子:

$$\mathcal{H} = \begin{bmatrix} -1 & \mathbf{I}_{(N-1) \times N} \end{bmatrix}_{(N-1) \times N} \quad (18)$$

式中: -1 为矩阵中所有元素为 -1 的矩阵。

将式(17)中每一项进行平方操作后整理可得到 DGTRS 框架:

$$\arg \min_{\mathbf{Q}} \|(\mathcal{H}^T)^{-1/2} \tilde{\mathbf{Z}} \mathbf{Q} - (\mathcal{H} \mathcal{H}^T)^{-1/2} \tilde{\Psi}\|^2 \quad (19)$$

s. t. $\mathbf{Q}^T \mathcal{D} \mathbf{Q} + 2 \mathcal{B}^T \mathbf{Q} = 0$

式中: $\mathcal{D} = [\mathbf{I}_2, \mathbf{0}_{2 \times 1}; \mathbf{0}_{1 \times 2}, 0]$, 0 为所有元素为 0 的矩阵; $\mathcal{B} = [\mathbf{0}_{2 \times 1}; -0.5]$ 。

$$\tilde{\mathbf{Z}} = \begin{bmatrix} 2\mathbf{a}_1^T - 2 \cdot 10^{\frac{\tilde{P}_{r2,1}}{5\hat{\alpha}^*}} \mathbf{a}_2^T & 10^{\frac{\tilde{P}_{r2,1}}{5\hat{\alpha}^*}} - 1 \\ \vdots & \vdots \\ 2\mathbf{a}_1^T - 2 \cdot 10^{\frac{\tilde{P}_{r2,1}}{5\hat{\alpha}^*}} \mathbf{a}_N^T & 10^{\frac{\tilde{P}_{r2,1}}{5\hat{\alpha}^*}} - 1 \end{bmatrix} \quad (20)$$

$$\tilde{\Psi} = \begin{bmatrix} \|\mathbf{a}_1\|^2 - \|\mathbf{a}_2\|^2 \cdot 10^{\frac{\tilde{P}_{r2,1}}{5\hat{\alpha}^*}} \\ \vdots \\ \|\mathbf{a}_1\|^2 - \|\mathbf{a}_N\|^2 \cdot 10^{\frac{\tilde{P}_{rN,1}}{5\hat{\alpha}^*}} \end{bmatrix} \quad (21)$$

令 $\tilde{\mathbf{Z}}^0 = (\mathcal{H} \mathcal{H}^T)^{-1/2} \tilde{\mathbf{Z}}$; $\tilde{\Psi}^0 = (\mathcal{H} \mathcal{H}^T)^{-1/2} \tilde{\Psi}$; $\Phi = \mathbf{Q}^T \mathcal{D} \mathbf{Q} + 2 \mathcal{B}^T \mathbf{Q}$; 式(19)可通过引入拉格朗日乘子,构造函数式(22)进行求解:

$$L(\mathbf{Q}; \lambda) = (\tilde{\mathbf{Z}}^0 \mathbf{Q} - \tilde{\Psi}^0)^T (\tilde{\mathbf{Z}}^0 \mathbf{Q} - \tilde{\Psi}^0) + \lambda \Phi \quad (22)$$

式中: λ 为拉格朗日乘子。

对式(22)函数以 $\mathbf{Q}$ 为变量,求偏导后可得:

$$\frac{\partial L(\mathbf{Q}; \lambda)}{\partial \mathbf{Q}} = 2(\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0 \mathbf{Q} - 2\tilde{\mathbf{Z}}^0 \tilde{\Psi}^0 + 2\lambda \mathcal{D} \mathbf{Q} + 2\lambda \mathcal{B} \quad (23)$$

若式(23)趋近 0 , 可得拉格朗日乘子估计方程:

$$\hat{\mathbf{Q}}(\lambda) = ((\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0 + \lambda \mathcal{D})^{-1} ((\tilde{\mathbf{Z}}^0)^T \tilde{\Psi}^0 + \lambda \mathcal{B}) \quad (24)$$

式中: $\hat{\mathbf{Q}}(\cdot)$ 表示对于 λ 的函数。

由于 λ 未知,以 λ 为变量,将式(24)方程等价于 0 后,利用式(25)对 λ 进行求解:

$$\lambda = \text{fun}(\Theta, 0) \quad (25)$$

式中: $\text{fun}(\Theta, 0)$ 表示对 Θ 为 0 时的函数表达式,其中 $\Theta = \hat{\mathbf{Q}}(\lambda)^T \mathcal{D} \hat{\mathbf{Q}}(\lambda) + 2 \mathcal{B}^T \hat{\mathbf{Q}}(\lambda)$ 。

但通过式(25)求得的拉格朗日乘子并非最优。因此,定义区间 I :

$$I = \left(-\frac{1}{\lambda_1((\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0, \mathcal{D})}, \infty \right) \quad (26)$$

式中: $\lambda_1((\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0, \mathcal{D})$ 表示对于 $((\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0, \mathcal{D})$ 最大的特征值。

根据文献[28]定理可知, $\hat{\mathbf{Q}}(\lambda)$ 在区间 I 是严格递减函数,可通过二分法来寻找最优拉格朗日乘子 λ^* 。随后代入 λ^* ,并根据式(27)求得细粒度位置:

$$\hat{\mathbf{x}}_f = \{((\tilde{\mathbf{Z}}^0)^T \tilde{\mathbf{Z}}^0 + \lambda^* \mathcal{D})^{-1} ((\tilde{\mathbf{Z}}^0)^T \tilde{\Psi}^0 + \lambda^* \mathcal{B})\} \big|_{1:2} \quad (27)$$

式中: $\hat{\mathbf{x}}_f$ 为细粒度估计位置; $\cdot \big|_{1:2}$ 表示对应向量的前两项。

3 双参不确定的 CRLB

CRLB 被认为是评估无偏估计最为有效的手段之一,它可表示为费雪信息矩阵逆的迹^[29]。当 TP 和 PLE

不确定,且跟 γ_i 独立同分布时,即 $\tilde{P}_0 = P_0 + \eta$; $\tilde{\alpha}_i = \alpha_i + \tau_i$, 其中 η 和 τ_i 表示服从均值为 0 , 方差分别为 ε^2 和 s_i^2

的高斯分布噪声; $\tilde{P}_0$ 和 $\tilde{\alpha}_i$ 分别表示不确定 TP 和 PLE 的值,则双参不确定的 CRLB 表示为:

$$\text{CRLB} = \text{Tr}(\mathbf{FIM}^{-1}) = \text{Tr} \left[\frac{\partial^2 \ln(\mathcal{F}; \mathcal{M})}{\partial \mathcal{M} \partial \mathcal{M}^T} \right]^{-1} \quad (28)$$

式中: $\text{Tr}(\cdot)$ 为迹函数; $\mathcal{F} = [\mathbf{P}^T, \tilde{\mathbf{P}}_0, \tilde{\boldsymbol{\alpha}}^T]^T$; $\mathcal{M} = [\mathbf{x}^T, P_0, \boldsymbol{\alpha}^T]^T$, 其中 $\tilde{\boldsymbol{\alpha}} = [\tilde{\alpha}_1, \dots, \tilde{\alpha}_N]^T$, $\boldsymbol{\alpha} = [\alpha_1, \dots, \alpha_N]^T$ 。

式(28)中的费雪信息矩阵为 $(N+3)$ 的方阵, 其中仅有左上 (3×3) 子方阵有效, 可表示为:

$$\frac{\partial^2 \ln(\mathcal{F}; \mathcal{M})}{\partial \mathcal{M} \partial \mathcal{M}^T} = \begin{bmatrix} \mathbf{A} & \mathbf{B} & \mathbf{C} \\ \mathbf{B}^T & \mathbf{D} & \mathbf{E} \\ \mathbf{C}^T & \mathbf{E}^T & \mathbf{F} \end{bmatrix} \quad (29)$$

式中:

$$\mathbf{A} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \mathbf{x}} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \mathbf{x}} \right) \quad (30)$$

$$\mathbf{B} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \mathbf{x}} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial P_0} \right) \quad (31)$$

$$\mathbf{C} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \mathbf{x}} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \boldsymbol{\alpha}} \right) \quad (32)$$

$$\mathbf{D} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial P_0} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial P_0} \right) + \varepsilon^{-2} \quad (33)$$

$$\mathbf{E} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial P_0} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \boldsymbol{\alpha}} \right) \quad (34)$$

$$\mathbf{F} = \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \boldsymbol{\alpha}} \right)^T \boldsymbol{\sigma}^{-1} \left(\frac{\partial \ln(\mathbf{P}; \mathbf{x})}{\partial \boldsymbol{\alpha}} \right) + \mathbf{S}^{-1} \quad (35)$$

式中: $\boldsymbol{\sigma} = [\sigma_1^2, \dots, \sigma_N^2]^T$; $\mathbf{S} = [\mathbf{s}_1^2, \dots, \mathbf{s}_N^2]^T$ 。

根据分块矩阵广义逆定理, 将式(29)进行分块操作, 可进一步表示为:

$$\begin{bmatrix} \mathbf{A} & [\mathbf{B} \ \mathbf{C}] \\ [\mathbf{B}^T] & [\mathbf{D} \ \mathbf{E}] \\ [\mathbf{C}^T] & [\mathbf{E}^T \ \mathbf{F}] \end{bmatrix}^{-1} = \begin{bmatrix} \mathbf{G} & -\mathbf{A}^{-1} \mathbf{K} \mathbf{Z}^{-1} \\ -\mathbf{Z}^{-1} \mathbf{H} \mathbf{A}^{-1} & \mathbf{Z}^{-1} \end{bmatrix} \quad (36)$$

式中: $\mathbf{G} = \mathbf{A}^{-1} + \mathbf{A}^{-1} \mathbf{K} \mathbf{Z}^{-1} \mathbf{H} \mathbf{A}^{-1}$; $\mathbf{K} = [\mathbf{B}, \mathbf{C}]$; $\mathbf{H} = [\mathbf{B}^T; \mathbf{C}^T]$;

$$\mathbf{Z}^{-1} = \begin{bmatrix} \mathbf{L}^{-1} + \mathbf{L}^{-1} \mathbf{M} \mathbf{N}^{-1} \mathbf{O} \mathbf{L}^{-1} & -\mathbf{L}^{-1} \mathbf{M} \mathbf{N}^{-1} \\ -\mathbf{N}^{-1} \mathbf{O} \mathbf{L}^{-1} & \mathbf{N}^{-1} \end{bmatrix} \quad (37)$$

式中: $\mathbf{L} = \mathbf{D} - \mathbf{B}^T \mathbf{A}^{-1} \mathbf{B}$; $\mathbf{M} = \mathbf{E} - \mathbf{B}^T \mathbf{A}^{-1} \mathbf{C}$; $\mathbf{O} = \mathbf{E}^T - \mathbf{C}^T \mathbf{A}^{-1} \mathbf{B}$; $\mathbf{N} = \mathbf{F} - \mathbf{C}^T \mathbf{A}^{-1} \mathbf{C} - \mathbf{O} \mathbf{L}^{-1} \mathbf{M}$ 。

定义 $\mathbf{U} = \mathbf{C} - \mathbf{B} \mathbf{L}^{-1} \mathbf{M}$ 和 $\mathbf{V} = \mathbf{C}^T - \mathbf{O} \mathbf{L}^{-1} \mathbf{B}^T$, 根据伍德伯里矩阵恒等式, 可得:

$$\mathbf{FIM}^{-1} = \mathbf{A}^{-1} + \mathbf{A}^{-1} (\mathbf{B} \mathbf{L}^{-1} \mathbf{B}^T + \mathbf{U} \mathbf{N}^{-1} \mathbf{V}) \mathbf{A}^{-1} \quad (38)$$

4 仿真实验

为验证本文提出 CFTL 方法的有效性, 实验在 MATLAB R2022b 平台进行, 仿真区域为 $20 \text{ m} \times 20 \text{ m}$ 。各锚节点和目标节点在每次蒙特卡洛实验中利用 *rand* 函数在仿真区域中随机生成^[3], 以均方根误差 (root mean square error, RMSE) 作为评价定位精度的基准:

$$RMSE_x = \sqrt{\frac{\sum_{mc=1}^{MC} (\hat{\mathbf{x}} - \mathbf{x})^2}{MC}} \quad (39)$$

式中: MC 为蒙特卡洛实验总次数, 设置为 1 000; mc 为当前次数; $\hat{\mathbf{x}}$ 是细粒度位置估计值, 即 $\hat{\mathbf{x}} = \hat{\mathbf{x}}_f$ 。

仿真中设置节点的真实 $P_0 = -55 \text{ dBm}$, $\alpha = 3.5$, 再结合噪声 γ_i , 以此模拟获取真实情况下锚节点收到的 RSS 值。随后根据获取到的 RSS 值, 进行三阶定位。虽然 PLE 存在不确定性, 但根据文献[30]可知, 其取值范围通常为 $[2, 6]$ 。因此, 在每次蒙特卡洛实验中根据经验范围取值, 通过该方式在一阶计算阶段求得粗粒度估计, 并基于此进入二阶计算步骤。根据文献[27]可知, 实验中在二阶 PLE 估计的固定参数设置如下: $PF_1 = 0.5$, $PF_2 = 0.5$, $PF_3 = 0.3$, $\kappa = 2$, $L = 0.67$, $M = 30$, $MaxIter = 100$ 。此外, 对于双参不确定的 CRLB 的噪声设置如下^[20,31]: $\varepsilon^2 = 1 \text{ dB}$, $\mathbf{s}_i^2 = 3$ 。

4.1 PLE 估计误差

由于 CFTL 的细粒度估计阶段需要代入第 2 阶段估计的 PLE, 因此第 2 阶段的估计误差也影响着算法的定位精度。为探究 CFTL 第 2 阶段 PO 对于 PLE 的估计误差, 令 $N = 8$, $\sigma_i^2 = 3 \text{ dB}$, 以 RMSE 为评估指标: $RMSE_\alpha = \sqrt{\sum_{mc=1}^{MC} (\hat{\alpha} - \alpha)^2 / MC}$, 其中 $\hat{\alpha}$ 表示估计的 PLE。同时分别对比近年来新提出的元启法式优化方法, 包括黑翅鸢优化算法 (black-winged kite algorithm, BKA)^[32]、小龙虾优化算法 (crayfish optimization algorithm, COA)^[33]、鹅优化算法 (goose optimization algorithm, GOOSE)^[34]、河马优化算法 (hippopotamus optimization algorithm, HO)^[35]、鲸鱼优化算法 (whale optimization algorithm, WOA)^[36] 以及多重试验向量的改进差分进化算法 (multi-trial vector-based differential evolution algorithm, MTDE)^[37]。相关估计误差结果如图 1 所示。




图 1 不同优化方法对于 PLE 的估计误差

Fig. 1 Estimate error of PLE by different optimization methods

α 的大小能够一定程度判断室内外环境,当 α 值较小时,其信号传播环境更偏向于室外^[38],因此基于 RSS 的定位精度有所下降,而第 2 阶段的 PLE 估计又与第 1 阶段的估计精度有关。为此,从图 1 可知,当 α 值较小时,对应的估计误差偏大。随着 α 值增大,对应估计误差趋于稳定,并处于上下波动的情况。对于 PO 方法而言,在绝大多数场景下,其对于 PLE 的估计误差相比于其他方法来得低,具体误差情况如表 1 所示。在 α 较小时,其 PLE 估计误差偏大,随着 α 的增大,逐渐在 $RMSE_{\alpha} = 1$ 处波动。从结果可看出,PO 方法较适用于定位场景中对于 PLE 的估计。

表 1 各优化方法的估计误差值

算法	$\alpha = 2.5$	$\alpha = 3.5$	$\alpha = 4.5$	$\alpha = 5.5$
BKA	2.054 3	1.333 9	1.012 3	1.215 0
COA	2.003 0	1.360 8	1.015 6	1.113 2
GOOSE	2.002 5	1.344 4	1.026 7	1.132 6
HO	2.262 6	1.809 3	1.509 2	2.266 4
MTDE	1.996 5	1.332 1	0.995 3	1.159 7
WOA	2.016 9	1.343 7	1.037 9	1.188 1
PO	1.984 5	1.301 7	0.989 8	1.125 2

4.2 不同锚节点数量场景定位误差

为进一步探究本文提出方法的有效性,在锚节点数量变化进行仿真实验,设置 $\sigma_i^2 = 3 \text{ dB}$,并分别对比基于差分的简精定位方法 (accurate and simple source localization, ASSL)^[39]、比率 and 搜索定位方法 (ratio and search, RAS)^[40]、有效集定位方法 (active set method, ASM)^[3],以及本文提出方法 CFTL 第 1 阶段 (CFTL-1) 和推导得到的 CRLB。相关定位误差如图 2 所示。




图 2 不同算法在 N 变化时的定位误差
Fig. 2 Localization error of different algorithms in variable N

由于锚节点数量的增多,可用于定位的信息亦得到了增长。为此,当 N 增大时,各算法的定位误差逐渐减小。从图 2 可知,ASM、RAS 和 CFTL-1 在锚节点数量较

少时,定位精度较为接近,但随着 N 增大,它们的定位误差各不相同,其中 RAS 由于在过程中采用线性搜索的方式得到估计的 PLE,因此其定位误差在 N 较大时比 ASM、CFTL-1 来得小。而 ASM 由于在算法中增加了约束,使其在解算的时候排除了异常解,故其定位精度略优于 CFTL-1。

相比于其他方法而言,本文提出的方法尽管在第 1 阶段 CFTL-1 粗粒度估计的误差较大,但由于增加了 PO 和细粒度估计阶段,其定位精度得到了显著的提升,比如,在 $N = 14$ 时,CFTL 比定位效果最好的 RAS,定位精度提升 10.96%;在 $N = 6$ 时,CFTL 比定位效果最好的 ASM,定位精度提升 26.71%。它的优越性在累积概率密度函数 (cumulative distribution function, CDF) 上得到了进一步的体现。以 $N = 6$ 为例,不同算法在该条件的 CDF 对比情况如图 3 所示。在 1 000 次的蒙特卡洛实验中,CFTL 在 $\|\hat{\mathbf{x}} - \mathbf{x}\| \leq 7.63 \text{ m}$ 的情况占比达到 90%,同等百分比条件下,ASSL 误差为 11.01 m;ASM 误差为 9.18 m;RAS 误差为 10.07 m。因此,本文提出的三阶定位方法能够在双参不确定情况,且锚节点数量变化时,取得较好的定位效果。






图 3 不同算法在 $N = 6$ 时的 CDF
Fig. 3 CDF of different algorithms when $N = 6$

4.3 不同噪声场景定位误差

环境噪声的增加往往会对定位精度产生不利的影响,为进一步探究本文提出方法在环境噪声变化的定位效果,设置 $N = 8$ 。相关定位误差如图 4 所示。当 $\sigma_i^2 = 1 \text{ dB}$ 时,本文提出的算法非常接近于 CRLB,但随着噪声的增大,定位精度随之下降,与 CRLB 曲线间隙亦逐渐增加。由图 4 可知,虽 CFTL 的定位误差增加,但其误差增长的变化率在降低。而其他方法在噪声变化情况下的定位误差相比于 CFTL 均明显增加。特别是 ASM,当 $\sigma_i^2 = 1 \text{ dB}$ 时,由于其设定的约束条件,定位效果接近于 CFTL,但随着噪声增大,它的定位精度却发生了较大幅度的下降。

图4 不同算法在 σ_i^2 变化时的定位误差Fig. 4 Localization error of different algorithms in variable σ_i^2

总体而言,本文提出的 CFTL 在不同噪声场景下的定位效果相比于其他方法均有所提升,比如,在 $\sigma_i^2=1$ dB 时,CFTL 比定位效果最好的 ASM,定位精度提升 17.94%;在 $\sigma_i^2=9$ dB,CFTL 比 CFTL-1 和 RAS,定位精度分别提升 21.15%和 22.68%。如图 5 所示,其良好的定位效果得到了进一步的呈现。在 1 000 次的蒙特卡洛实验中,CFTL 在 $\|\hat{\mathbf{x}} - \mathbf{x}\| \leq 7.86$ m 的情况占比达到 90%,而同等条件下,ASSL 误差为 11.26 m;ASM 误差为 10.46 m;RAS 误差为 9.05 m。由此可见,本文提出的 CFTL 在环境噪声变化情况下仍能保持较好的定位效果。

图5 不同算法在 $\sigma_i^2=9$ dB 时的 CDFFig. 5 CDF of different algorithms when $\sigma_i^2=9$ dB

4.4 各算法的计算时间开销

算法的时间开销是衡量其定位效率的重要指标之一。为此,针对上述不同锚节点数量和噪声场景,分别统计各算法定位的时间成本。相关时间开销如图 6 所示,其中图 6(a)为 $\sigma_i^2=3$ dB 情况下不同算法在锚节点变化的时间开销,图 6(b)为 $N=8$ 情况下不同算法在噪声变化的时间开销。从图 6(a)可知,各算法的时间开销分层

较为明显,本文提出的第 1 阶段粗粒度估计方法 CFTL-1 计算开销时间较少,平均维持在 4.28×10^{-8} s,相比于 ASSL 的 5.63×10^{-6} s,其计算效率有一定提升。由于 CFTL 采用了三阶段从粗至细的估计方法,平均计算开销比仅有一阶求解过程的 ASSL 和 CFTL-1 来得多,大约为 5.58×10^{-5} s。但其效率总体比多阶估计方法 RAS 的 3.5×10^{-3} s 来得显著。同样的结论在图 6(b)中得到了进一步的验证,本文提出的 CFTL 在不同噪声场景下平均计算时间开销为 5.73×10^{-5} s,较优于 ASM 和 RAS。尽管 CFTL 的计算时间开销高于 CFTL-1 和 ASSL,但它的定位精度在图 2 和 4 的结果中要显著高于这两单阶的定位方法。因此,综合定位精度、计算开销和效率之间的考量,本文提出的 CFTL 方法可作为在 TP 和 PLE 均未知情况的有效定位方案。




图6 不同算法在不同场景的时间开销

Fig. 6 Time consumption of different algorithms in variable scenarios

4.5 室内实测试验

相比于普通的室内环境,船舶的机舱室由于存放大型设备,对无线信号的传播会产生不利的影响^[41],加上钢板对无线信号的反射、吸收等效应,其 PLE 不确定性程度更为显著。为进一步验证提出方法在实际复杂环境的有效性,在上海海事大学吴淞轮机舱室设备层进行实验,其中设备室长 8.4 m,宽 6 m,连廊部分总长 14 m,宽 1.8 m,空间内部有大量金属仪器、设备以及管线,相关实测环境如图 7 所示。部署的锚节点位置(坐标单位为 m)分别为 $\mathbf{a}_1 = [10.17; 3.88]$, $\mathbf{a}_2 = [15.40; 2.11]$, $\mathbf{a}_3 = [20.95; 3.88]$, $\mathbf{a}_4 = [2.75; 4.57]$, $\mathbf{a}_5 = [7.55; 2.98]$, $\mathbf{a}_6 = [10.19; 2.11]$, $\mathbf{a}_7 = [20.95; 2.11]$ 。同时分别在 3 处位置进行实验,目标节点位置(坐标单位为 m)分别为 $\mathbf{x}_1 = [6.45; 2.20]$, $\mathbf{x}_2 = [9.15; 3.00]$, $\mathbf{x}_3 = [12.65; 3.00]$ 。对应的平面结构简图、锚节点和目标节点布置情况如图 8 所示。



图 7 室内实测环境
Fig. 7 Practical environment




图 8 节点布置
Fig. 8 Node placement

为避免偶然发生的异常值影响,分别获取相同目标节点位置间隔 5 s 的 10 条连续 RSS 数据进行实验,对应的结果如图 9 所示。




图 9 不同算法在实测场景中的定位误差
Fig. 9 Localization error of different algorithms in the practical scenario

对于目标节点 1, RAS 的定位精度较差,定位误差的中位数约为 27.10 m,这主要是由于其所位置相较于锚节点所部署形成的几何中心较远。已有实验及理论表明,当目标节点所在位置处于锚节点包围形成的范围内,比如,当锚节点所部署的范围为圆,目标节点在其圆内,对应的定位误差要比圆外小^[42]。因此,目标节点 1 的定位误差相较于目标节点 2 和 3 有所增加。尽管如

此,本文提出的 CFTL 对 3 个目标节点的定位精度相比于其他方法有所提高,其中目标节点 1、目标节点 2 及目标节点 3 的定位误差中位数分别约为 6.39、4.29 和 4.32 m。相比于其他方法而言,对于目标节点 1 的定位误差中位数, CFTL 相比于 CFTL-1(9.38 m),精度提升了 31.87%;对于目标节点 2 的定位误差中位数, CFTL 相比于 CFTL-1(4.98 m),精度提升了 13.85%;对于目标节点 3 的定位误差中位数, CFTL 相比于 RAS(6.37 m),精度提升了 32.18%。

5 结 论

本文针对 TP 和 PLE 同时不确定情况下的 WSNs 定位进行研究,提出了一种三阶定位算法。引用差分思想首先消除了 TP 不确定性,将原非凸定位问题转化为 NC-LSE 框架进行求解,得到粗粒度位置信息。随后利用 PO 量化 PLE 不确定性,在第 2 阶段得到最优 PLE,并基于此代入第 3 阶段 DGTRS 的框架,结合二分法求得细粒度位置。此外,还运用分块矩阵广义逆定理,推导双参不确定的 CRLB,建立算法的评估机制。仿真和实测结果表明,本文算法在不同场景下具有较好的定位精度。未来将进一步对移动场景下多参量不确定的节点定位技术展开研究,特别是在锚节点位置不准确或是存在异常测量值时的鲁棒性定位问题。

参考文献

[1] OLIVEIRA L L D, EISENKRAEMER G H, CARARA E A, et al. Mobile localization techniques for wireless sensor networks: Survey and recommendations[J]. ACM Transactions on Sensor Networks, 2023, 19(2): 1-39.

[2] LALAMA Z, BOULFEKHAR S, SEMECHEDINE F. Localization optimization in WSNs using meta-heuristics optimization algorithms: A survey[J]. Wireless Personal Communications, 2022, 122(2): 1197-1220.

[3] MEI X, WU H, XIAN J. Matrix factorization based target localization via range measurements with uncertainty in transmit power [J]. IEEE Wireless Communications Letters, 2020, 9(10): 1611-1615.

[4] MEI X, HAN D, SAEED N, et al. Localization in underwater acoustic IoT networks: Dealing with perturbed anchors and stratification[J]. IEEE Internet of Things Journal, 2024, 11(10): 17757-17769.

[5] PLACED J A, STRADER J, CARRILLO H, et al. A survey on active simultaneous localization and mapping: State of the art and new frontiers[J]. IEEE Transactions on Robotics, 2023, 39(3): 1686-1705.

[6] MEI X, WU H, XIAN J, et al. RSS-based byzantine fault-tolerant localization algorithm under NLOS

- environment[J]. IEEE Communications Letters, 2021, 25(2): 474-478.
- [7] 李天松, 李奕霖, 卢相志. 基于改进灰狼优化算法的射频识别室内定位算法[J]. 电子测量技术, 2023, 46(18): 85-91.
- LI T S, LI Y L, LU X ZH. RFID indoor positioning algorithm based on improved grey wolf optimization algorithm [J]. Electronic Measurement Technology, 2023, 46(18): 85-91.
- [8] 卢秀丽, 胡天濡, 冀松, 等. 基于改进蝙蝠优化算法的无线传感器网络定位研究[J]. 国外电子测量技术, 2023, 42(6): 103-109.
- LU X L, HU T R, JI S, et al. Research on wireless sensor network location based on improved bat optimization algorithm [J]. Foreign Electronic Measurement Technology, 2023, 42(6): 103-109.
- [9] 郑安琪, 秦宁宇. 空间指纹测量特征双精简下的室内定位算法[J]. 仪器仪表学报, 2023, 44(10): 80-89.
- ZHENG AN Q, QING N N. Indoor localization algorithm with dual refinement of spatial fingerprint measurement features[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 80-89.
- [10] 潘志远, 卜凡亮. 基于蜣螂算法优化的 DV-Hop 定位算法 [J]. 电子测量与仪器学报, 2023, 37(7): 33-41.
- PAN ZH Y, BU F L. DV-Hop localization algorithm optimized based on dung beetle optimizer[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 33-41.
- [11] WANG Q, DUAN Z, LI F. Semidefinite programming for wireless cooperative localization using biased RSS measurements[J]. IEEE Communications Letters, 2022, 26(6): 1278-1282.
- [12] DU J, YUAN C, YUE M, et al. A novel localization algorithm based on RSSI and multilateration for indoor environments[J]. Electronics, 2022, 11(2): 289.
- [13] 张大龙, 孙顶, 张立志, 等. 基于模拟退火和樽海鞘群优化的 DV-Hop 定位算法[J]. 传感器与微系统, 2024, 43(3): 125-129.
- ZHANG D L, SUN D, ZHANG L ZH, et al. DV-Hop localization algorithm based on simulated annealing and optimization of salp swarm [J]. Transducer and Microsystem Technologies, 2024, 43(3): 125-129.
- [14] ZAFARI F, GKELIAS A, LEUNG K K. A survey of indoor localization systems and technologies[J]. IEEE Communications Surveys & Tutorials, 2019, 21(3): 2568-2599.
- [15] JIN D, YIN F, FRITSCH C, et al. Bayesian cooperative localization using received signal strength with unknown path loss exponent: Message passing approaches [J]. IEEE Transactions on Signal Processing, 2020, 68: 1120-1135.
- [16] RAYAR V, NAIK U, MANAGE P S. A RSS-based path loss model approaches multi-dimensional scaling to localize 2D sensor nodes in WSN [J]. Peer-to-Peer Networking and Applications, 2023, 16(4): 1609-1623.
- [17] YADAV P, SHARMA S C. A systematic review of localization in WSN: Machine learning and optimization-based approaches [J]. International Journal of Communication Systems, 2023, 36(4): 5397.
- [18] ZHANG Y, WU H, MEI X, et al. Unknown transmit power RSSD based localization in a gaussian mixture channel[J]. IEEE Sensors Journal, 2022, 22(9): 9114-9123.
- [19] YAN Q, LUO Z, WANG H M. Joint noise model learning and source localization with unknown transmit power [J]. IEEE Communications Letters, 2023, 27(5): 1317-1321.
- [20] MEI X, CHEN Y, XU X, et al. RSS localization using multistep linearization in the presence of unknown path loss exponent[J]. IEEE Sensors Letters, 2022, 6(8): 1-4.
- [21] SARI R, ZAYYANI H. RSS localization using unknown statistical path loss exponent model [J]. IEEE Communications Letters, 2018, 22(9): 1830-1833.
- [22] NAJARRO L A C, SONG I, TOMIC S, et al. Fast localization with unknown transmit power and path-loss exponent in WSNs based on RSS measurements [J]. IEEE Communications Letters, 2020, 24(12): 2756-2760.
- [23] ZHANG L, YANG B, YOU X. Received signal strength indicator-based recursive set-membership localization with unknown transmit power and path loss exponent [J]. IEEE Sensors Journal, 2021, 21(22): 26175-26185.
- [24] ZOU Y, LIU H. RSS-based target localization with unknown model parameters and sensor position errors [J]. IEEE Transactions on Vehicular Technology, 2021, 70(7): 6969-6982.
- [25] KANG S, KIM T, CHUNG W. Target localization with unknown transmit power and path-loss exponent using a Kalman filter in WSNs[J]. Sensors, 2020, 20(22): 6582.
- [26] MOLLER T, MACHIRAJU R, MUELLER K, et al. Evaluation and design of filters using a Taylor series expansion[J]. IEEE Transactions on Visualization and Computer Graphics, 1997, 3(2): 184-199.
- [27] ABDOLLAHZADEH B, KHODADADI N,

- BARSHANDEH S, et al. Puma optimizer (PO): A novel metaheuristic optimization algorithm and its application in machine learning[J]. Cluster Computing, 2024, 27(4): 5235-5283.
- [28] MORE J J. Generalizations of the trust region problem[J]. Optimization Methods & Software, 1993, 2(3-4): 21.
- [29] SENGIPTA S K. Fundamentals of statistical signal processing: Estimation theory[J]. Technometrics, 1993, 37(4): 465-466.
- [30] HU Y, LEUS G. Self-estimation of path-loss exponent in wireless networks and applications [J]. IEEE Transactions on Vehicular Technology, 2015, 64(11): 5091-5102.
- [31] PRASAD K N R S V, BHARGAVA V K. RSS localization under gaussian distributed path loss exponent model [J]. IEEE Wireless Communications Letters, 2021, 10(1): 111-115.
- [32] WANG J, WANG W CH, HU X X, et al. Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems [J]. Artificial Intelligence Review, 2024, 57(4): 98.
- [33] JIA H, RAO H, WEN C, et al. Crayfish optimization algorithm [J]. Artificial Intelligence Review, 2023, 56(2): 1919-1979.
- [34] HAMAD R K, RASHID T A. GOOSE algorithm: A powerful optimization tool for real-world engineering challenges and beyond [J]. Evolving Systems, 2024, 15(4): 1249-1274.
- [35] AMIRI M H, MEHRABI HASHJIN N, MONTAZERI M, et al. Hippopotamus optimization algorithm: A novel nature-inspired optimization algorithm [J]. Scientific Reports, 2024, 14(1): 5032.
- [36] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [37] NADIMI-SHAHRAKI M H, TAGHIAN S, MIRJALILI S, et al. MTDE: An effective multi-trial vector-based differential evolution algorithm and its applications for engineering design problems [J]. Applied Soft Computing, 2020, 97: 106761.
- [38] WOJCICKI P, ZIENTARSKI T, CHARYTANOWICZ M, et al. Estimation of the path-loss exponent by bayesian filtering method[J]. Sensors, 2021, 21(6): 1934.
- [39] LIN L, SO H C, CHAN Y T. Accurate and simple source localization using differential received signal strength[J]. Digital Signal Processing, 2013, 23(3): 736-743.
- [40] XU Y, ZHOU J, ZHANG P. RSS-based source localization when path-loss model parameters are unknown[J]. IEEE Communications Letters, 2014, 18(6): 1055-1058.
- [41] MIAO K, WANG R, SUN J, et al. Application of remote network technology in engine room communication of the ship [J]. 2022, DOI:10.1007/978-981-16-8558-3_19.
- [42] PANWAR K, FATIMA G, BABU P. Optimal sensor placement for hybrid source localization using fused TOA-RSS-AOA measurements [J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 59(2): 1643-1657.

作者简介



梅晓峻, 2016 年于上海海事大学获得学士学位, 2021 年于上海海事大学获得博士学位, 现为上海海事大学副教授, 硕士生导师, 主要研究方向为无线传感器网络/水下载感器网络定位技术。

E-mail: xjmei@shmtu.edu.cn

Mei Xiaojun received his B. Sc. degree from Shanghai Maritime University in 2016 and Ph. D. degree from Shanghai Maritime University in 2021, respectively. Now he is an associate professor and M. Sc. supervisor in Shanghai Maritime University. His main research interests include localization technology in wireless sensor networks and underwater wireless sensor networks.



吴华锋 (通信作者), 1997 年于集美大学获得学士学位, 2004 年于大连海事大学获得硕士学位, 2008 年于复旦大学获得博士学位, 现为上海海事大学教授, 博士生导师, 主要研究方向为交通信息工程及控制、物联网技术、无线传感器网络。

E-mail: hfwu@shmtu.edu.cn

Wu Huafeng (Corresponding author) received his B. Sc. degree from Jimei University in 1997, M. Sc. degree from Dalian Maritime University in 2004, and Ph. D. degree from Fudan University in 2008, respectively. Now he is a professor and Ph. D. supervisor in Shanghai Maritime University. His main research interests include traffic information engineering and control, Internet of things, and wireless sensor networks.