

DOI: 10.13382/j.jemi.B2407956

基于多维缩放和自适应加权迭代的 WSN 定位算法*

江美娟 刘锡祥 盛广润

(东南大学仪器科学与工程学院 南京 210096)

摘要:针对基于测距的接收信号强度(RSSI)的定位方法存在的误差较大,以及针对基于复杂函数缩放(SAMCOF)的迭代方法的加权策略单一,无法适应距离量测值的不稳定性,影响定位精度的问题,提出了一种基于扩展卡尔曼滤波(EKF)和多维尺度(MDS)的自适应加权迭代算法。首先,利用EKF算法融合由RSSI得到的距离量测值和加速度信息,以获得优化后的距离状态量;然后,基于协方差矩阵中距离状态量的置信度动态调整不同通信节点对之间的权重,并采用优化的距离构建距离矩阵,进行多维标度定位(MDS-MAP),得到初始位置;最后,采用基于SMACOF的迭代优化方法对初始位置进行迭代,以消除不完全链路观测对定位精度的影响,从而获得更精确的位置估计。仿真实验表明无论在何种网络分布、通信半径、节点数量以及噪声水平下,所提出的定位算法相比MDS-MAP、vMDS、wMDS均表现出了更好的效果,提高了变化的网络中的定位技术精确性和鲁棒性。同时,基于ZigBee CC2530的定位系统的半物理实验结果验证了所提出算法在室内和室外场景上定位效果,克服了传统方法在复杂环境中的局限性。

关键词:接收信号强度;SMACOF;扩展卡尔曼滤波;MDS-MAP;自适应加权

中图分类号: TP393; TN929.5 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Localization algorithm for wireless sensor networks based on multidimensional scaling and adaptive weighting iteration

Jiang Meijuan Liu Xixiang Sheng Guangrun

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: To address the issues of the large errors in received signal strength indicator (RSSI)-based ranging methods and the limited adaptability of the iterative method based on the scaling by majorizing a complicated function (SAMCOF), which cannot adapt to the instability of distance measurements and degrading localization precision, this paper proposes an adaptive weighting algorithm based on the extended Kalman filter (EKF) and multidimensional scaling (MDS). The algorithm first fuses the distance measurements obtained from RSSI and acceleration information using EKF to obtain optimized distance states. Then, the weights for different communication node pairs are dynamically adjusted based on the confidence of the distance states in the covariance matrix, and an optimized distance matrix is constructed for MDS-MAP positioning to obtain the initial positions. Finally, the SMACOF-based iterative optimization method is employed to refine the initial positions, reduce the negative impact of incomplete link observations and enhance positioning accuracy. Simulation experiments show that the proposed localization algorithm outperforms MDS-MAP, vMDS, and wMDS in various network distributions, communication radii, node numbers, and noise levels, improving positioning precision and robustness in dynamic networks. Additionally, the semi-physical experiment results of the positioning system based on ZigBee CC2530 validate the effectiveness of the algorithm's effectiveness in both indoor and outdoor scenarios, overcoming the limitations of traditional methods in complex environments.

Keywords: received signal strength indication; SMACOF; extended Kalman filter; MDS-MAP; adaptive weighting

0 引言

无线传感网络(wireless sensor network, WSN)融合了通信技术、传感器技术以及嵌入式技术等多种技术^[1],并在军事、医疗、智能家居、工业自动化等领域得到了广泛应用。网络中配备了数以百计甚至上千的传感器节点,这些节点具备通信、计算和感知能力并通过无线通信将采集的数据传输给监控中心。在实际应用中,节点的位置信息对于无线传感网络至关重要。然而,由于成本、体积与功耗的限制^[2],不可能为每个节点都配备高精度全球定位系统(global positioning system, GPS)设备^[3],一是因为在成百上千的节点中都部署 GPS 导致成本过高,二是因为定位系统会导致能耗过大,和传感器的基本性质相悖,三是因为 WSN 通常被部署在恶劣环境中,如深林、地下、灾害现场等障碍物较多或信号较弱的场景中,对 GPS 的定位性能产生影响^[4]。因此 GPS 无法大规模应用于 WSN 中,然而在大多数场景中,只有确定了位置信息,所监测的信息才具有意义。综上所述,为了确定网络中每个节点的位置信息,研究通过其他测量信息来间接获得未知节点的定位算法成为了 WSN 领域中重要的研究方向。

WSN 中将定位技术分为基于测距和非测距定位,基于测距的定位技术主要依赖于节点之间的距离信息,主要有质心算法(centroid)、近似三角形内点测量(approximate point-in-triangulation, APIT)、距离向量跳(distance vector hop, DV-hop)算法和 multidimensional scaling map, MDS-MAP 等算法^[5-8]。

相比于其他算法, MDS-MAP 在大规模网络和已知信息较少的场景中具有更高的优势,因为它能够利用较少的锚节点以及部分节点间的相对关系得到其他未知节点的位置信息。而基于接收信号强度(received signal strength indication, RSSI)测距技术其不需要额外硬件且成本较低而被广泛采用,相较于其他需要额外硬件设备的到达时间定位法(time of arrival, TOA)、到达时间差定位法(time difference of arrival, TDOA)和到达角度定位法(angle of arrival, AOA)测距技术^[9-12],而 RSSI 可以直接从无线收发器得到,再经过传播模型得到测距信息,但由于障碍物、多径传播和非视距传播等因素,距离信息往往不够准确,还需要进一步提高精度^[13]。

经典 MDS-MAP 算法在当节点分布不均匀的情况下,定位性能会急剧下降,文献[14]提出基于复杂函数缩放(scaling by majorizing a complicated function, SMACOF)迭代算法,通过不断的迭代调整节点的位置,直至达到预定的收敛条件,来提高定位精度。近年来,

有许多研究人员针对基于 SMACOF 的 MDS 定位算法提出改进。针对 SMACOF 对初始值敏感,容易陷入局部最小值,文献[15]提出了 AI-SMACOF 算法(锚定惯性 SMACOF)。该方法通过锚定一个数据点消除平移冗余性,并结合惯性项加速收敛,最后证明了该算法的全局收敛性。相较于传统 SMACOF 算法, AI-SMACOF 在运行效率和收敛速度上更具优势,但其性能依然依赖于初值的准确度。文献[16]提出一种迭代 I-MDS 算法,该算法分为将网络分为单跳网络和多跳网络。对于单跳网络,先使用经典 MDS 获得初始估计,再用 SMACOF 优化。而对于多跳网络,通过使用 Bron-Kerbosch 算法,分阶段合并团,逐步整合局部定位结果,形成全局解。这种方法避免了传统 SMACOF 陷入局部最优,但复杂度较高,且未考虑移动场景下的定位需求。针对动态节点的定位,文献[17]提出了一种名为 DC-MDS 的快速集群定位方法。该方法采用了核心融图算法提高初始化节点位置的准确性,避免 SMACOF 算法陷入局部最小值,但是这种逐渐合并的方法会消耗更多的计算资源和时间。文献[18]提出了一种分布式 MDS 算法,该算法通过每个代理与其邻居节点通信并通过计算当前坐标在邻居空间上的投影来更新坐标,以最小化应力函数,该算法在处理大规模数据上具有显著优势。文献[19-20]则将节点的相对速度引入到目标函数中,并采用基于三边定位和 MDS 结合的定位算法,在上述改进的算法中,节点速度被作为目标函数的一部分,进一步提高了定位精度,且没有引入增加更多的计算复杂度。但是,上述算法在使用 SMACOF 对初始位置进行迭代时在权重选择上仅考虑了两种情况,即节点无法通信时,权重为 0,否则为 1,这种加权方式比较简单,但当可通信对节点之间的距离测量存在较大的误差,这种方式会影响迭代的准确性。因此,在现有算法的基础上,本文提出了一种自适应加权策略,充分考虑了距离测量值的不稳定性,来提高定位精度。并与将速度测量引入到应力函数中的 vMDS 算法进行对比,验证算法的准确性和鲁棒性。

综上所述,为了适应动态环境又不增加算法的时间复杂度,本文提出了一种结合扩展卡尔曼滤波(extended Kalman filter, EKF)和自适应加权多维缩放(weighted multidimensional scaling, wMDS)的定位算法,该算法不仅考虑了距离测量的精度,还适用于动态环境。本文算法流程如下:首先,利用 EKF 融合加速度计信息来对测距信息进行优化。接着,利用优化的距离值及其对应的置信度来调整权重。最后,使用 MDS-MAP 算法获取初始位置信息,将其作为 SMACOF 的输入进行迭代求精,以得到最终的位置信息。

1 系统模型

1.1 MDS-MAP

MDS-MAP 是一种基于多维标度技术发展而来的方法,用于在降维过程中保持数据点之间的距离关系,主要思想是通过构造多个实体之间的多维空间的坐标图,以可视化或表征实体之间的相似性或差异性,可以分为以下 3 个步骤。

1) 构建距离矩阵

由 k 维($k=2$ 或 3 分别表示二维和三维空间)空间的全局关系图内的 n 个节点构建 $n \times n$ 的距离矩阵 \mathbf{D} , 在实际中,当两个节点在通信范围内,可以通过量测值构建矩阵,在可通信范围外的,则需要利用最短路径算法补全,距离矩阵如式(1)所示。

$$\mathbf{D} = \begin{bmatrix} 0 & d_{12} & d_{13} & \cdots & d_{1n} \\ d_{21} & 0 & d_{23} & \cdots & d_{2n} \\ d_{31} & d_{32} & 0 & \cdots & d_{3n} \\ \vdots & \vdots & \vdots & \cdots & \vdots \\ d_{n1} & d_{n2} & d_{n3} & \cdots & 0 \end{bmatrix} \quad (1)$$

2) 降维

可以运用 MDS 技术来对距离矩阵 \mathbf{D} 进行降维处理。在此之前,还需要对距离矩阵 \mathbf{D} 进行双重中心化操作。首先,在距离矩阵 \mathbf{D} 的平方项两端乘以一个中心矩阵 \mathbf{J} 。然后,乘以系数 $-1/2$,以获得双重中心化矩阵 \mathbf{B} ,如式(2)所示。这个过程实质上是为了调整数据,使得在降维处理中更好地保留数据的原始结构和特征。

$$\mathbf{B} = -\frac{1}{2}\mathbf{J}\mathbf{D}^2\mathbf{J} \quad (2)$$

其中:

$$\mathbf{J} = \mathbf{I} - n^{-1}\mathbf{e}\mathbf{e}^T =$$

$$\begin{bmatrix} 1 - \frac{1}{n} & -\frac{1}{n} & -\frac{1}{n} & \cdots & -\frac{1}{n} \\ -\frac{1}{n} & 1 - \frac{1}{n} & -\frac{1}{n} & \cdots & -\frac{1}{n} \\ -\frac{1}{n} & -\frac{1}{n} & 1 - \frac{1}{n} & \cdots & -\frac{1}{n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -\frac{1}{n} & -\frac{1}{n} & -\frac{1}{n} & \cdots & 1 - \frac{1}{n} \end{bmatrix} \quad (3)$$

再对矩阵 \mathbf{B} 进行奇异值(singular value decomposition, SVD)分解,求得最大的 k 维特征值 $\lambda_1, \lambda_2, \dots, \lambda_k$ 组成的 k 维对角矩阵 \mathbf{A} , 和得到对应的 k 个特征向量 $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_k$ 组成的 $n \times k$ 维矩阵 \mathbf{V} , 得到 n 个节点之间的相对坐标 $\mathbf{X} = \mathbf{V}\mathbf{A}^{1/2}$ 。

3) 将相对位置转为绝对位置

根据已知的锚节点位置信息可以将上述得到的相对位置绝对化。通过对相对坐标 \mathbf{x} 进行平移 \mathbf{t} 、旋转 \mathbf{R} 以及缩放 s 操作进行坐标转换,从而得到绝对位置 \mathbf{x}' 。当坐标为 2 维,则至少需要 3 个锚节点,当坐标为 3 维,则至少需要 4 个锚节点^[21]。

$$\mathbf{x}' = s\mathbf{R}\mathbf{x} + \mathbf{t} \quad (4)$$

从理论上来看,仅通过距离信息与少数锚节点的位置信息,就可以对大多数未知节点进行定位。然而,在实际应用中,由于无法获取完整的距离矩阵、网络链路中存在的不稳定性、测量的距离信息的不精确性以及使用最短路径算法补全的距离矩阵与实际距离严重不符等问题的存在,使得获取精确位置信息变得十分困难。因此,本文主要通过优化距离测量来改进定位精度。方法分为两部分:(1)对距离测量值进行优化;(2)对获得的初始位置进行迭代调整,利用距离信息的置信度来校正位置。

1.2 基于 EKF 的 RSSI 优化方法

1) RSSI 模型

RSSI 通过接受到的信号强度来估计发送端和接收端之间的距离信息,信号强度和设备之间的距离存在一定的关系,可通过一种基于统计学模型的 Shadowing 信号模型来估算距离,一般定义为^[22]:

$$P_r(d_{mn}) = P_0(d_0) - 10n_p \log_{10}\left(\frac{d_{mn}}{d_0}\right) + X_\delta \quad (5)$$

式中: $P_r(d_{mn})$ 为距离发射点 d_{mn} 处接收到的信号强度值; $P_0(d_0)$ 为距离发射点 d_0 处接收到的信号强度值; n_p 为路径损耗值,表示信号随传输距离的增加其发射功率的衰减速度,一般取 $2 \sim 4$, 值越大,表明干扰越大; X_δ 为均值为 0、标准差为 σ 的高斯分布噪声。

一般情况下,随着距离的增加, RSSI 值呈现非线性减小的趋势,相距越远,距离的变化对 RSSI 值的影响越小;反之,距离的变化对 RSSI 值影响更加敏感,因此距离越近, RSSI 就越准确,受到的干扰比远距离更少,这时候可以赋予更近节点对之间更大的权重,以提高定位算法的准确性和稳定性。

2) EKF

而在 WSN 中,节点的运动往往是非线性的,因此考虑使用 EKF 对距离值进行优化^[23]。EKF 是一种基于递归贝叶斯滤波的技术,其主要目的是通过动态更新模型和观测数据,对系统进行连续的预测和更新。相对于传统的 KF, EKF 更加适用于处理非线性的系统模型,因为它通过线性化非线性函数来近似非线性系,实现对系统状态的有效估计和预测,从而提高位置估计的准确性和稳定性。同时节点内部集成了微电子机械系统传感器(micro-electro-mechanical systems, MEMS),如加速度传感器,用于监测节点的运动信息,它能实时测量节点的加

速度,从而提供关于节点位置变化的重要数据^[24]。再根据节点的运动模型,来建立状态更新方程和量测方程来推算出节点的其他信息。

设在无线传感网络节点接收到的数据包包括 RSSI、节点的加速度信息, k 时刻的状态量为:

$$\mathbf{X}_k = [d_{ij} \quad \mathbf{p}_i \quad \mathbf{v}_i \quad \mathbf{a}_i \quad \mathbf{p}_j \quad \mathbf{v}_j \quad \mathbf{a}_j]^T \quad (6)$$

量测量为:

$$\mathbf{Z}_k = [d_{ij} \quad \mathbf{a}_i \quad \mathbf{a}_j]^T \quad (7)$$

式中: d_{ij} 是节点 i 到节点 j 的距离; $\mathbf{p}_i, \mathbf{p}_j$ 是节点 i, j 的位置信息,其中 $\mathbf{p} = [x \quad y]$; $\mathbf{v}_i, \mathbf{v}_j$ 则是两个节点的速度,其中 $\mathbf{v} = [v_x \quad v_y]$; $\mathbf{a}_i, \mathbf{a}_j$ 则是两个节点的加速度,其中 $\mathbf{a} = [a_x \quad a_y]$, EKF 的状态预测方程和状态观测方程分别为:

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}, \mathbf{u}_k) + \mathbf{w}_{k-1} \quad (8)$$

$$\mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{v}_k \quad (9)$$

式中: \mathbf{u}_k 为控制向量; $\mathbf{w}_k \sim N(0, Q)$ 为服从零均值正态分布的过程激励噪声; $\mathbf{v}_k \sim N(0, R)$ 为观测噪声,与 \mathbf{w}_k 相互独立,服从零均值正态分布。假设节点在进行匀加速直线运动,因此距离的更新方程为:

$$d_{ij}^k = \frac{\sqrt{(x_i^{k-1} + v_{xi}^{k-1} - x_j^{k-1} - v_{xj}^{k-1})^2 + (y_i^{k-1} + v_{yi}^{k-1} - y_j^{k-1} - v_{yj}^{k-1})^2}}{1} \quad (10)$$

由于这个更新方程是非线性的,因此需要对函数 $f(\cdot), h(\cdot)$ 线性化,即进行一阶泰勒级数展开,因此式(6)、(7)线性化方程可分别表示为:

$$\mathbf{X}_k = \mathbf{F}\mathbf{X}_{k-1} + \mathbf{W}\mathbf{w}_k + \phi(k) \quad (11)$$

$$\mathbf{Z}_k = \mathbf{H}\mathbf{X}_k + \mathbf{V}\mathbf{v}_k + \gamma(k) \quad (12)$$

式中: \mathbf{W} 和 \mathbf{V} 分别是过程噪声协方差矩阵和观测噪声协方差矩阵; \mathbf{F} 为系统状态雅各比矩阵; \mathbf{H} 为系统观测矩阵的雅各比矩阵定义如式(13)和(14)所示。

$$\mathbf{F} = \frac{\partial f}{\partial \mathbf{X}} = \begin{bmatrix} 0 & \frac{\partial d_{ij}}{\partial \mathbf{p}_i} & \frac{\partial d_{ij}}{\partial \mathbf{v}_i} & 0 & \frac{\partial d_{ij}}{\partial \mathbf{p}_j} & \frac{\partial d_{ij}}{\partial \mathbf{v}_j} & 0 \\ 0 & 1 & dt & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & dt & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & dt & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & dt \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (13)$$

$$\mathbf{H} = \frac{\partial h}{\partial \mathbf{X}} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (14)$$

而 $\phi(k), \gamma(k)$ 为方程线性化后的偏置项,即无法完全线性化的非线性化部分,通常为常量。这样就退化到线性滤波过程,再使用 KF 进行处理。KF 算法部分本文不再做详细的介绍。

最后, EKF 不仅对距离值进行了优化,同时还提供了一个协方差矩阵 \mathbf{P} , 由矩阵 \mathbf{P} 可以得到测量信息的置信度,从上文可以得知矩阵 \mathbf{P} 的第一个元素表示对估计距离的置信度,即 $\sigma_{ij} = \mathbf{P}[1, 1]$ 。值越小说明估计的越准,反之则越不准。

1.3 基于 SMACOF 的迭代优化算法

SMACOF 算法在精度提高方面具有显著效果^[25]。该算法的核心思想是通过不断迭代,调整数据点在低维空间中的位置,使得它们在低维空间中的距离尽可能地接近它们在高维空间中的距离。这一过程通过最小化应力函数来实现,定义为:

$$\hat{\mathbf{X}}(t) = \underset{\mathbf{X}^{(t)} \in \mathbf{R}^{N \times 3}}{\operatorname{argmin}} \sum_{i < j} \omega_{ij}^{(t)} (\delta_{ij}^{(t)} - d_{ij}(\mathbf{X}^{(t)}))^2 \quad (15)$$

此函数是所有节点对之间距离误差的加权平方和,通过选择适当的权值并迭代优化位置信息,使函数值最小化。在式(15)中, $\mathbf{X}^{(t)}$ 是 t 时刻跟据 MDS-MAP 算法得到的相对位置, $d_{ij}(\mathbf{X}^{(t)})$ 是跟据相对位置计算得到的节点 i 和节点 j 之间的距离信息, $\delta_{ij}^{(t)}$ 表示在 t 时刻下节点 i 与节点 j 之间的观测距离,通常情况下,权值 ω_{ij} 的定义如式(16)所示。

$$\omega_{ij} = \begin{cases} 0, & \delta_{ij} \text{ 缺失或不精确} \\ 1, & \text{其他} \end{cases} \quad (16)$$

然而,这样定义无法准确描述距离值的准确性。因此,本文引入一种新的权值定义方法,旨在更好地反映距离的准确性。定义如式(17)所示。

$$\omega_{ij} = e^{-\frac{d_{ij}^2(\mathbf{X}^{(t)})}{2\sigma_{ij}^2}} \quad (17)$$

式(17)是一个自适应权值,其中 σ_{ij} 是用 EKF 估计距离状态量的协方差, $\sigma_{ij} = \mathbf{P}_{ij}[1, 1]$, 协方差越大说明估计的越不准,越小则说明估计的越准确。式(17)的曲线图如图 1 所示,当分母越小,则函数越陡,距离越近,权值就越大。从图 1 可以看出,更小的协方差可以减弱距离较远节点对的影响,使得网络对于噪声和干扰更加稳健。由于距离较远节点的权重较小,它们对于整体结构的影响也会相应降低,从而使得网络对于局部噪声的影响更小。通过这种新的权值定义方法,算法可以更精确地评估距离的准确性,从而提高定位算法的精度和可靠性。

在优化过程中, SMACOF 算法采用一种称为 MM (majorization-minimization) 的算法,通过对式(15)进行迭代优化来逐步改善目标函数的值。函数被重新表述为:

$$\sigma \mathbf{X}^{(t)} = \sum_{i < j} \omega_{ij}^{(t)} (\delta_{ij}^{(t)} - d_{ij}(\mathbf{X}^{(t)}))^2 = \sum_{i < j} \omega_{ij}^{(t)} (\delta_{ij}^{(t)})^2 + \sum_{i < j} (\omega_{ij}^{(t)})^2 d_{ij}^2(\mathbf{X}^{(t)}) - 2 \sum_{i < j} \omega_{ij}^{(t)} \delta_{ij}^{(t)} d_{ij}(\mathbf{X}^{(t)}) = C + \eta(\mathbf{X}^{(t)}) - 2\rho(\mathbf{X}^{(t)}) \quad (18)$$

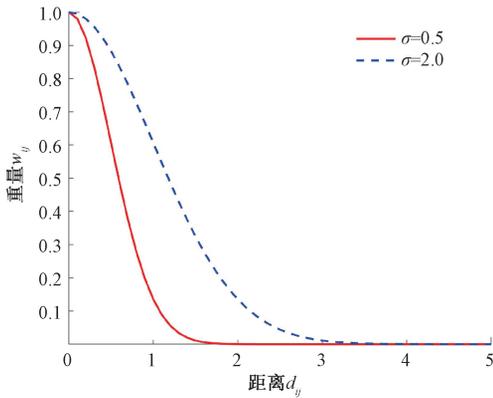


图1 权重分布

Fig. 1 Weight distribution

改写后的函数可以分解为3个部分。如式(18)所示,由于权值和距离量测信息已知,因此第1项C是与 $\mathbf{X}^{(t)}$ 无关的常数项。第2项是关于 $\mathbf{X}^{(t)}$ 的凸函数。第3项中的 $d_{ij}(\mathbf{X}^{(t)})$ 是估计坐标的节点*i*与节点*j*的距离,需要开平方,因此是关于 $\mathbf{X}^{(t)}$ 的非凸函数。因此,整体而言,这构成了一个非凸函数优化问题。直接解决这种非凸函数比较困难。通过MM算法,寻找一个更易于求解的函数 $g(x, z)$ 代替式(18),其中*z*是常数,可以将 $g(x, z)$ 视为 $\sigma(\mathbf{X}^{(t)})$ 的上界,将 $\sigma(\mathbf{X}^{(t)})$ 简写为 $\sigma(x)$ 。 $g(x, z)$ 满足以下关系:

- 1) $g(x, z)$ 是比 $\sigma(x)$ 更容易求解的函数;
 - 2) $\forall x, \sigma(x) \leq g(x, z)$, 当且仅当 $x = z$, 等号成立。
- 求解 $\text{ming}(x, z)$ 得到 $x = x_1$, 此时有:

$$\sigma(x_1) \leq g(x_1, z) \leq g(z, z) = \sigma(z) \quad (19)$$

再而求解 $\text{ming}(x, x_1)$ 得到 $x = x_2$, 此时有:

$$\sigma(x_2) \leq g(x_2, x_1) \leq g(x_1, x_1) = \sigma(x_1) \quad (20)$$

不断迭代,可以得到一个单调不增的 $\sigma(x_k)$ 。

首先对第2部分凸函数部分进行求解,化简 $(\omega_{ij}^{(t)})^2 d_{ij}^2(\mathbf{X}^{(t)})$ 可得:

$$\omega_{ij}^{(t)} d_{ij}^2(\mathbf{X}^{(t)}) = \text{tr}((\mathbf{X}^{(t)})^T (\omega_{ij}^{(t)} \mathbf{A}_{ij}) \mathbf{X}^{(t)}) \quad (21)$$

式中: \mathbf{A}_{ij} 是指 $a_{ii} = a_{jj} = 1, a_{ij} = a_{ji} = -1$;其他元素则为0; tr 表示求矩阵的迹。因此第2项 $\eta(\mathbf{X}^{(t)})$ 可化简为:

$$\eta(\mathbf{X}^{(t)}) = \sum_{i < j} \omega_{ij}^{(t)} d_{ij}^2(\mathbf{X}^{(t)}) = \sum_{i < j} \text{tr}((\mathbf{X}^{(t)})^T (\omega_{ij}^{(t)} \mathbf{A}_{ij}) \mathbf{X}^{(t)}) = \text{tr}((\mathbf{X}^{(t)})^T (\sum_{i < j} \omega_{ij}^{(t)} \mathbf{A}_{ij}) \mathbf{X}^{(t)}) = \text{tr}(\mathbf{X}^{(t)})^T \mathbf{V}^{(t)} \mathbf{X}^{(t)} \quad (22)$$

式中: $\mathbf{V}^{(t)} = \sum_{i < j} \omega_{ij}^{(t)} \mathbf{A}_{ij}$, 当 $i \neq j$ 时, $v_{ij}^{(t)} = -\omega_{ij}^{(t)}$; 当 $i = j$ 时, $v_{jj}^{(t)} = \sum_{j=1, j \neq i}^N \omega_{ij}^{(t)}$ 。

针对第3部分的非凸函数,可以用柯西-施瓦格不等式推导出主要因子 $d_{ij}(\mathbf{X}^{(t)})$:

$$-d_{ij}(\mathbf{X}^{(t)}) \leq -\frac{(x_i^{(t)} - x_j^{(t)})^T (z_i - z_j)}{d_{ij}(\mathbf{Z})} =$$

$$-\frac{\text{tr}((\mathbf{X}^{(t)})^T \mathbf{A}_{ij} \mathbf{Z})}{d_{ij}(\mathbf{Z})} \quad (23)$$

可得:

$$-\rho(\mathbf{X}^{(t)}) \leq -\sum_{i < j} \omega_{ij}^{(t)} \delta_{ij}^{(t)} \frac{\text{tr}((\mathbf{X}^{(t)})^T \mathbf{A}_{ij} \mathbf{Z})}{d_{ij}(\mathbf{Z})} = -\text{tr}(\mathbf{X}^{(t)})^T \mathbf{B}(\mathbf{Z}) \mathbf{Z} \quad (24)$$

其中 $\mathbf{B}(\mathbf{Z})$ 的取值与 $\mathbf{V}^{(t)}$ 的取值类似:

$$b_{ij} = \begin{cases} -\frac{\omega_{ij}^{(t)} \delta_{ij}^{(t)}}{d_{ij}(\mathbf{Z})}, & i \neq j \text{ and } d_{ij}(\mathbf{Z}) \neq 0 \\ 0, & i \neq j \text{ and } d_{ij}(\mathbf{Z}) = 0 \end{cases} \quad (25)$$

$$b_{ii} = -\sum_{j=1, j \neq i}^N b_{ij} \quad (26)$$

由此,优化复杂函数式(15)就是对凸函数 $g(\mathbf{X}^{(t)}, \mathbf{Z})$ 求解,

$$\sigma(\mathbf{X}^{(t)}) \leq C + \text{tr}(\mathbf{X}^{(t)})^T \mathbf{V}^{(t)} \mathbf{X}^{(t)} - 2\text{tr}(\mathbf{X}^{(t)})^T \mathbf{B}(\mathbf{Z}) \mathbf{Z} = g(\mathbf{X}^{(t)}, \mathbf{Z}) \quad (27)$$

要求 $\min g(\mathbf{X}^{(t)}, \mathbf{Z})$, 可以对其求导, 并让 $g'(\mathbf{X}^{(t)}, \mathbf{Z}) = 0$

$$g'(\mathbf{X}^{(t)}, \mathbf{Z}) = 2\mathbf{V}^{(t)} \mathbf{X}^{(t)} - 2\mathbf{B}(\mathbf{Z}) \mathbf{Z} = 0 \quad (28)$$

由式(28)可得 $\mathbf{V}^{(t)} \mathbf{X}^{(t)} = \mathbf{B}(\mathbf{Z}) \mathbf{Z}$, 由于 $\mathbf{V}^{(t)}$ 不是满秩矩阵, 无法求逆, 因此用 $\mathbf{V}^{(t)}$ 的广义逆矩阵 $(\mathbf{V}^{(t)})^\dagger$, 由此可以得到 $\{\mathbf{X}^{(t)}\}$ 的更新公式:

$$\mathbf{X}^{k+1} = (\mathbf{V}^{(t)})^\dagger \mathbf{B}(\mathbf{X}^k) \mathbf{X}^k \quad (29)$$

虽然通过SMACOF迭代算法可以很好的提高定位精度, 但为了防止算法在迭代过程中发散, 需要合理设置初值, 因此本文选用MDS-MAP的定位结果作为SMACOF算法的初始值; 同时也要注意权值的选取, 若权值过大, 则这些点对误差整体目标函数的影响被放大, 导致算法过于敏感某些距离, 使得更新不稳定, 因此需要对权值做归一化处理。

1.4 算法的时间复杂度分析

设网络中总节点数为*n*, 有*m*个锚节点, 在MDS-MAP算法中, 涉及到需要对矩阵进行逆计算以及使用Floyd算法求不连通节点对之间的距离, 因此时间复杂度为 $O(n^3)$; 相对坐标转绝对坐标的时间复杂度为 $O(m^3 + n)$, 因此MDS-MAP算法的时间复杂度为 $O(n^3 + m^3 + n)$ 。对于SMACOF算法, 每一次迭代过程中都涉及到对 $n \times n$ 矩阵进行运算, 因此其总的时间复杂度为 $O(k \cdot n^3)$, 其中*k*为最大迭代次数。基于EKF的RSSI优化算法时间复杂度为 $O(w^3)$, 其中*w*为状态变量的个数。因此本文算法的总时间复杂度为 $O(n^3 + m^3 + n + k \cdot n^3 + w^3)$, 可以化简为 $O(k \cdot n^3)$ 。

2 仿真及结果分析

本文是针对典型的无线传感网络应用场景进行模拟

的,即假设网络中的数据流以周期性方式进行传输,数据流大小和具体内容在这里不做具体考虑,而是将重点放在算法在不同场景下的定位效果上,以便更直观地评估其性能。

2.1 仿真环境设置

本文使用 MATLAB R2020a 仿真工具对改进的扩展卡尔曼滤波加权多维标度(EKF-wMDS)算法进行仿真实验。在仿真环境中,50 个节点随机分布在 100 m×100 m 的区域内,其中有 10 个锚节点,节点通信半径为 $R = 30\text{ m}$,并假设加速度计和 RSSI 的测量误差服从均值为 0 的高斯分布,即 $\mathbf{a} \sim N(0, 0.1^2)$ (m/s^2) 和 $P_r(d) \sim N(0, 4.43^2)$ 。具体仿真参数如表 1 所示。

表 1 仿真参数

Table 1 Simulation parameters

参数	初始化
网络大小	100×100
通信半径	30
节点总数	50
锚节点数目	10
$\sigma(a)$	0.01
$\sigma(P_r(d))$	1.43

此外,本文假设数据流在网络中定时发送。在 WSN 的动态环境中,外界条件的变化是不可避免的,例如由于外界环境或能量消耗导致的节点失效,从而引起网络发送变化。针对这些动态变化,本节对所提出的算法进行了详细验证,以确保其在不同情况下都能保持鲁棒性。并与 MDS-MAP、vMDS 以及 wMDS 算法进行比较,其中 vMDS 是将速度引入到复杂函数中,并使用 SMACOF 算法对其进行迭代。这些对比算法关键参数设置与表 1 一致。为了评估各算法的定位性能,本文使用均方根误差(root mean square error, RMSE) 和平均定位误差(error) 作为评价指标,定义如式(30)和(31)所示。

$$RMSE = \sqrt{\sum_{i=m+1}^n \left((x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right)} / (n - m) \quad (30)$$

$$error = \frac{\sum_{i=m+1}^n \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2}}{n - m} \quad (31)$$

式中: (x, y) 为真实位置信息; (\hat{x}, \hat{y}) 为估计位置; N 为节点总数; m 为锚节点个数。

2.2 基于 EKF 的 RSSI 数据优化仿真

验证了带有误差的 RSSI 数据在通过 EKF 算法处理后的有效性。RSSI 测量值常受到多径效应、障碍物、非视距传播等多种不确定因素的影响,导致距离误差较大。因此,通过引入 EKF 算法对 RSSI 数据进行滤波与校正,仿真结果如图 2 所示,可以观察到,未经 EKF 处理的

RSSI 数据,即蓝色虚线,波动较大,经过 EKF 算法的处理后, RSSI 误差降低且波动幅度更小。

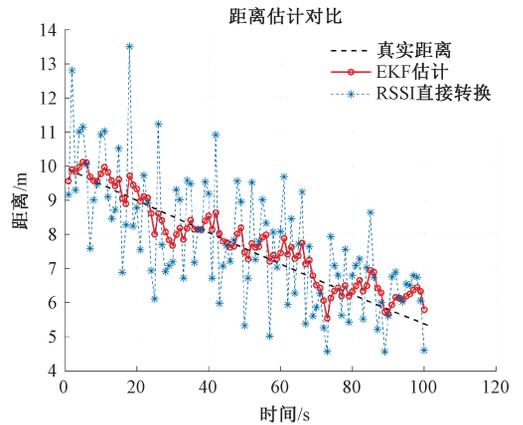


图 2 距离估计对比

Fig. 2 Comparison of distance estimation

还验证了经 EKF 处理和未经 EKF 处理后直接使用的定位情况,结果如表 2 所示。仿真结果表明,经 EKF 处理后会 对定位精度产生影响,分别提高了 4.02%、8.52%、1.79% 和 1.2%。

表 2 距离精度对平均定位误差的影响

Table 2 The influence of distance accuracy on localization algorithms (m)

处理方式	MDS-MAP	vMDS	wMDS	EKF-wMDS
未经 EKF 处理	4.018 5	3.541 8	1.244 2	1.085 6
经 EKF 处理	3.863 3	3.263 6	1.222 3	1.084 3

2.3 不同节点分布定位精度的影响

验证了节点在不同分布下对定位精度的影响,在其他条件与初始设置一样的情况下,具体分析了随机分布、均匀分布以及 O 型分布的情况。不同分布条件下的平均误差如表 3 所示。从表 3 可以看出,均匀分布下的误差值较低,表明节点均匀分布时,算法的定位效果更好;O 型分布下,定位效果最差,这时节点中心密度低,边缘节点较多,导致定位误差增大;而在随机分布的条件下,节点位置不确定性较大,有可能节点分布相对均匀,但有时也会出现极端情况,导致节点分布不均,因此,在此条件下,算法定位误差也相对较大。

表 3 节点分布对定位算法的影响

Table 3 The influence of distribution of nodes on localization algorithms (m)

算法	随机分布	均匀分布	O 型分布
MDS-MAP	2.648 4	0.817 5	4.635 8
vMDS	1.747 0	0.566 7	4.200 4
wMDS	0.772 6	0.033 0	1.045 5
EKF-wMDS	0.674 6	0.003 8	0.896 8

2.4 不同测距噪声对定位精度的影响

验证了各评估算法在不同测距噪声强度下的平均位置估计误差。在仿真中,其他条件一定的情况下,节点的误差从 $1\%R$ 增加到了 $4\%R$,步长为 $0.5\%R$,此时 $R=30$,仿真结果如图 3 所示。当 RSSI 噪声越大,各算法的位置误差呈上升的趋势,但本文算法的定位误差仍小于其他 3 个算法,平均定位精度分别提升了 78.12%、67.38% 和 12.84%。

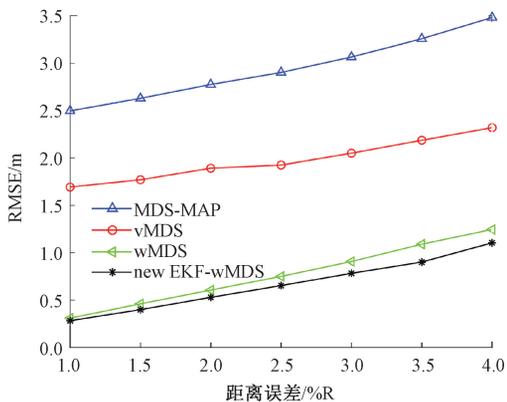


图 3 不同测距误差对算法均方根误差的影响

Fig. 3 The influence of distance noise on RMSE of algorithms

同时为了模拟节点之间存在障碍物的情况,其他条件不变,增大了 35% 的节点对之间的测距误差,增大的误差是原始误差 $3\%R$ 的 5 倍, $R=30$,同时其他条件与初始设置一样。此条件下不同算法的 RMSE 和平均误差如表 4 所示,从表 4 可以看出,在有障碍物的情况下,各算法的定位误差明显增大,但 EKF-wMDS 算法仍具有更好的定位精度,优于另外 3 个算法,证明了其在复杂环境中的具有较好的鲁棒性。

表 4 障碍物干扰环境下对定位算法的影响

Table 4 The influence of obstacle interference

environments on localization algorithms (m)

	MDS-MAP	vMDS	wMDS	EKF-wMDS
RMSE	8.098	7.271	3.232 8	3.161 3
error	6.929	5.846	2.714	2.677 1

2.5 不同通信半径对定位精度的影响

在 WSN 定位中,应该首先设置合适的通信半径。本节主要验证不同通信半径对算法定位误差的影响。在仿真环境中,通信半径从 25 增加到 50,步长为 5。如图 4 所示,随着通信半径的增加,误差呈现下降最后逐渐平缓的趋势。这是因为随着通信半径的增大,节点邻居节点的数量也相应增加。一般情况下,网络连通性越高,算法的误差越小,但当通信半径达到一定阈值时,网络的连接

度变化不大,因此精度也提高不明显。此外,本文提出的算法表现出更好的定位效果,与 MDS-MAP、vMDS、wMDS 相比,定位精度分别提升了 70.37%、54.73%、9.31%。

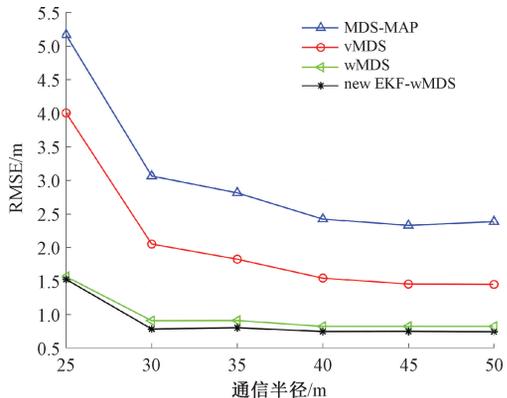


图 4 不同通信半径对算法均方根误差的影响

Fig. 4 The influence of communication radius on RMSE of algorithms

2.6 不同节点数目对定位精度的影响

分为两部分进行验证,首先是验证锚节点数一定的条件下节点总数对定位精度的影响,其次是相同节点总数情况下不同锚节点数对定位精度的影响。

1) 不同锚节点数

各算法在其他条件如初始设置一样,而锚节点数量不同的情况下得到的平均位置估计误差如图 5 所示。由图 5 可知,锚节点的数量从 4 逐渐增加到 10,随着锚节点数量增加,节点定位误差出现逐渐下降并趋于平缓的趋势,与 MDS-MAP、vMDS、wMDS 相比,平均定位精度分别提升了 57.43%、45.26%、14.53%。由于更多的锚节点提供了更精确的坐标转换数据,因此算法定位精度提升了。当锚节点数量达到一定水平,数据已经相对充分,进一步增加锚节点对结果的影响也不大,且增加锚节点数量会增加系统的成本和复杂度,因此在实际中可以跟据需要选择合适的锚节点数,既能使定位效果更好也能降低成本。

2) 不同节点总数

各评估算法在锚节点一定,节点总数不同的情况下的误差情况如图 6 所示。仿真中,节点的数目从 40 增加到 100,步长为 10,在其他条件固定的情况下,节点数量增加会提高定位精度,因为节点数量增加导致网络连通度提高,分别为 7.75、10.12、12.6、15.2、17.725、19.3、21.12,可通信节点对就越多。与 MDS-MAP、vMDS、wMDS 相比,平均定位精度分别提升了 72.6%、61.01%、12.46%。然而,随着节点数量的增加,定位系统的运行时间也随之增加。

通过以上实验和比较,就可以得出不同算法在不同

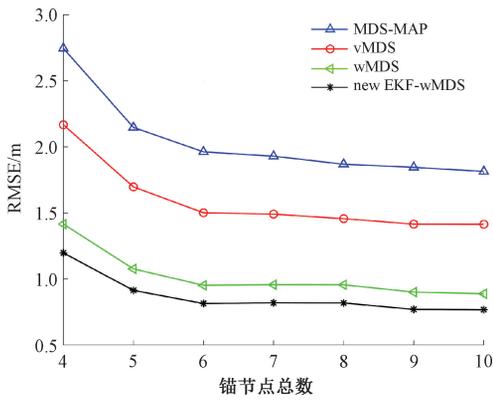


图 5 锚节点数量对算法均方根误差的影响
Fig. 5 The influence of number of anchor nodes on RMSE of algorithms

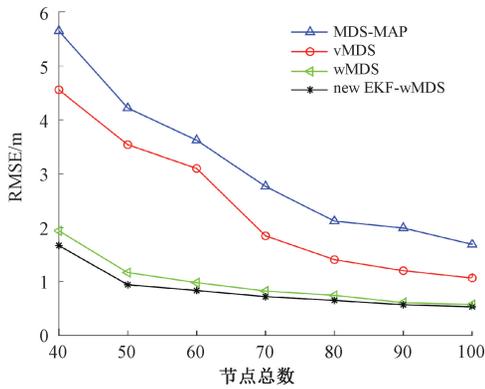


图 6 节点总数对算法均方根误差的影响
Fig. 6 The influence of total number of nodes on RMSE of algorithms

条件下的定位精度差异,验证了改进的 EKF-wMDS 算法在变化环境下的定位能力以及鲁棒性。

3 半物理仿真验证

为了进一步验证算法的有效性,搭建基于 ZigBee 的定位系统,定位系统结构如图 7 所示,结构分为两个部分,第 1 部分是无线定位模块,主要有协调器(未知节点)和终端节点(参考节点);第 2 部分是监控模块,主要是负责系统管理和实时监测,这两部分是由协调器通过串口与计算机连接起来,从而组成整个定位系统。

节点选用以 CC2530 芯片为核心的 ZigBee 模块,采用了增强型 C8051,工作频段为 2.4 GHz,支持基于 IEEE802.15.4 的 ZigBee 通信协议,工作频率为 10 Hz,使用电池供电,输出功率为 4.5 dBm,实物如图 8 所示。

3.1 RSSI 数据采集实验和分析

实验取了两种不同的环境进行验证,一处是在实验

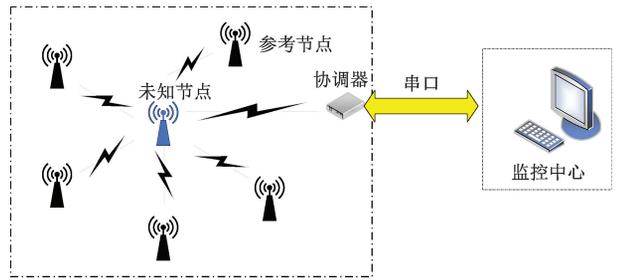


图 7 系统总体结构
Fig. 7 Overall system structure

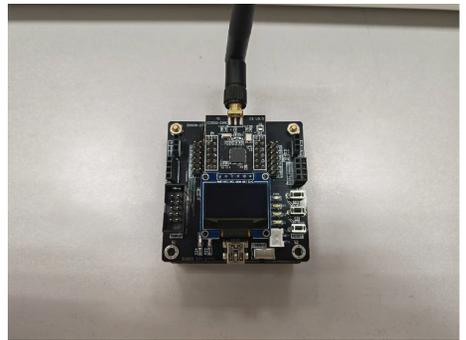


图 8 节点实物
Fig. 8 Node physical

室(障碍物较多)里,另一处是在实验楼天台(空旷)上,如图 9(a)和(b)所示。在其中放置发射器和接收器,并保证它们在同一高度以及天线垂直于地面。

为了保证数据的有效性,在同一距离选取多组数据,剔除最大值和最小值,再取平均,之后不断移动节点,记录不同距离下的 RSSI 值,最后拟合曲线如图 10 所示。



(a) 实验室环境 (a) Laboratory
(b) 天台环境 (b) Roof

图 9 实验环境

Fig. 9 Experimental environment

其中拟合曲线 1 即实验室内环境下拟合函数为:

$$RSSI = -37.3779 - 21.8502 \lg(d) \tag{32}$$

拟合曲线 2 即天台环境下拟合函数为:

$$RSSI = -39.2148 - 18.5801 \lg(d) \tag{33}$$

可以看出,在实验室环境下的路径损耗因子明显大

于天台下的值,在实验室环境中,由于存在墙壁、设备等障碍物的干扰,RSSI 值随距离的增加而下降的速度较快。反之,在空旷的天台上,RSSI 值随距离的增加而下降的速度相对较慢。通过收集大量数据,拟合出两个环境下的曲线,可以更准确地推算出距离。

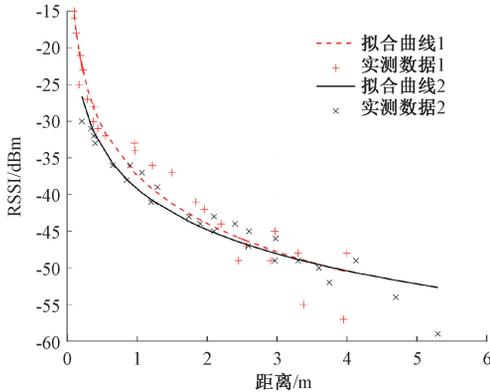


图 10 拟合曲线
Fig. 10 Fit curve

3.2 半物理定位实验

实验中,放置 5 个节点,其中 1 个是待定位节点,其他节点是锚节点,锚节点位置固定后不再移动,每个节点额外配备了可以相互通信的 UWB,还可以跟据它们的距离标定出相对位置,其关键数据如表 5 所示。

表 5 UWB 技术指标

Table 5 UWB technical specifications

技术指标	参数
工作频段	[3 744,4 243]
最远通信距离	120 m
测距精度	10 cm
采集频率	100 Hz

当布置好节点后,将待定位节点和 UWB 与计算机相连,设备上电后,使用 UWB 标定好相对位置。之后再采集数据,待定位节点会收到其他 ZigBee 节点发来的 RSSI 值,与计算机相连的 UWB 接受到其他 UWB 的距离信息,当收集到一定量数据后,移动待定位节点,并重新标定,如此循环,在实验室和天台环境中各采集 5 组数据,最后进行半物理仿真,结果如表 6、7 所示。在两种场景下,锚节点的相对坐标都为 (0,0)、(0,3)、(3,0)、(3,3),未知节点随机放置在其内部或外部。

从表 6 和 7 可知,在不同场景下,各种算法的定位误差有所不同。MDS-MAP 算法的定位误差相对较大,相比之下,EKF-wMDS 的整体表现最佳,但是偶尔会出现波动,这是因为在实际环境中,RSSI 信号会受到多种因素的干扰,尽管如此,EKF-wMDS 算法定位效果仍比其他算

法表现要好,具有更好的鲁棒性。结合表 6 和 7 可知,实验室场景下的定位误差更大,主要是因为室内环境复杂,存在多径效应,导致 RSSI 误差增大,从而影响定位精度,而室外场景较开阔,RSSI 信号在传播过程中受到的干扰较少。

表 6 天台场景下算法的平均定位误差

Table 6 Positioning errors of the algorithms in the rooftop scenario (m)

实际坐标	MDS-MAP	vMDS	wMDS	EKF-wMDS
(0.9,0.5)	0.25	0.240 1	0.245	0.240 1
(0.9,1.8)	0.838 6	0.687 4	0.498 2	0.418 5
(1.0,0.7)	0.689 6	0.665 8	0.659 8	0.646 7
(2.0,2.2)	0.351 9	0.313 8	0.264 5	0.158 7
(3.7,2.0)	0.693	0.605 2	0.419 4	0.423 2

表 7 实验室场景下算法的平均定位误差

Table 7 Positioning errors of the algorithms in the laboratory scenario (m)

实际坐标	MDS-MAP	vMDS	wMDS	EKF-wMDS
(0.7,1.3)	1.069 7	0.900 3	0.825 1	0.721 9
(1.6,2.4)	0.591 2	0.591 3	0.529 5	0.451
(1.9,1.5)	0.666	0.680 4	0.728 8	0.636 9
(2.0,0.9)	0.986 2	0.674 7	0.501 2	0.664 6
(2.0,2.4)	0.902 4	0.927	0.917 6	0.899 7

这些实验结果进一步验证了 EKF-wMDS 算法的有效性和鲁棒性。

4 结 论

为了进一步提高基于 RSSI 距离量测的多维标度技术定位精度,本文提出了一种基于扩展卡尔曼滤波的自适应迭代的多维标度算法。该方法使用 EKF 对距离量测进行优化,并根据优化的距离状态量的置信度,动态调整多维标度算法中初始坐标迭代过程的权重。权重公式综合考虑了节点距离的远近以及量测的精确度,赋予了置信度高且距离较近的节点更高的权重,减少了误差较大的距离量测对定位结果的影响。最后,通过仿真和半物理仿真实验,验证了本文所提出的算法在变化场景下的有效性和鲁棒性。仿真结果表明,与 MDS-MAP、vMDS 和 wMDS 算法相比,本文算法在不同节点分布、测距噪声、通信半径和节点数目下均展现了更好的定位效果。半物理实验也证实了算法在室内多障碍物和室外开阔环境下的鲁棒性。未来研究将进一步探索和验证算法在高速移动的三维空间和复杂室外环境中的适用性。

参考文献

[1] MANI R, MESSOUS S, CAMPOBELLO G, et al.

- Improved distance vector based Kalman filter localization algorithm for wireless sensor network [C]. 2023 International Conference on Control, Automation and Diagnosis (ICCAD). IEEE, 2023: 1-6.
- [2] MESSOUS S, LIOUANE H, LIOUANE N. Improvement of DV-Hop localization algorithm for randomly deployed wireless sensor networks[J]. *Telecommunication Systems* 2020, 73(1): 75-86.
- [3] LIOUANE H, MESSOUS S, CHEIKHROUHOU O, et al. Regularized least square multi-hops localization algorithm for wireless sensor networks[J]. *IEEE Access*, 2021, 9: 136406-136418.
- [4] ZHAO Y, WANG T H, LI W J, et al. Structural design of high-precision positioning system in weak signal environment based on UWB and IMU fusion [J]. *Instrumentation*, 2023, 10(2):30-39.
- [5] SANKARANARAYANAN S, VIJAYAKUMAR R, SWAMINATHAN S, et al. Node localization method in wireless sensor networks using combined crow search and the weighted centroid method [J]. *Sensors*, 2024, 24(15): 4791.
- [6] SHEN X Y, XU B Y, SHEN H M. Indoor localization system based on RSSI-APIT algorithm [J]. *Sensors*, 2023, 23(24): 9620.
- [7] 刘瑞兴, 段中兴, 李博. 改进 DV-Hop 定位算法在钢结构建筑健康监测中的应用[J]. *仪器仪表学报* 2022, 43(4): 38-49.
- LIU R X, DUAN ZH X, LI B. Application of improved DV-Hop positioning algorithm in steel structure health monitoring[J]. *Chinese Journal of Science Instrument*, 2022, 43(4): 38-49.
- [8] FANG X M, JIANG Z H, NAN L, et al. Noise-aware localization algorithms for wireless sensor networks based on multidimensional scaling and adaptive Kalman filtering[J]. *Computer Communications*, 2017, 101: 57-68.
- [9] XIONG W X, SCHINDELHAUER C, SO H C, et al. Maximum correntropy criterion for robust TOA-based localization in NLOS environments [J]. *Circuits, Systems, and Signal Processing*, 2021, 40 (12): 6325-6339.
- [10] WANG Y W, HO K C, WANG Z. Robust localization under NLOS environment in the presence of isolated outliers by full-Set TDOA measurements [J]. *Signal Processing*, 2023, 212: 109159.
- [11] ZHENG Y, SHENG M, LIU J Y, et al. Exploiting AoA estimation accuracy for indoor localization: A weighted AoA-based approach [J]. *IEEE Wireless Communications Letters*, 2018, 8(1): 65-68.
- [12] ABBA A M, SANUSI J, OSHIGA O, et al. A review of localization techniques in wireless sensor networks[C]. 2023 2nd International Conference on Multidisciplinary Engineering and Applied Science (ICMEAS). IEEE, 2023: 1-5.
- [13] 邹琰妮, 蒋伟, 杨俊杰, 等. 一种加权圆模型的 AOA 与 RSSI 融合定位算法 [J]. *导航定位学报*, 2023, 11(5): 12-20.
- ZHOU Y N, JIANG W, YANG J J, et al. An AOA and RSSI fusion location algorithm based on weighted circle model[J]. *Journal of Navigation and Positioning*, 2023, 11(5): 12-20.
- [14] DI FRANCO C, BINI E, MARINONI M, et al. Multidimensional scaling localization with anchors [C]. 2017 IEEE International Conference on Autonomous Robot Systems and Competitions (ICARSC). IEEE, 2017: 49-54.
- [15] RAM N, SABACH S. A globally convergent inertial first-order optimization method for multidimensional scaling[J]. *Journal of Optimization Theory and Applications*, 2024, 202(2): 949-974.
- [16] GAMGAM E O, NUMANOGLU T. Localization without GNSS for TDMA-based multi-hop networks [C]. 2024 6th International Conference on Communications, Signal Processing, and Their Applications (ICCSA). IEEE, 2024: 1-6.
- [17] ZOU Y Y, HU E W, DENG Z L, et al. Multidimensional scaling algorithm for mobile swarming uavs localization [J]. *IEEE Transactions on Intelligent Vehicles*, 2023, DOI:10.1109/TIV.2023.3325806.
- [18] GACHKOOBAN Z, ALIZADEH R, SHAKERI F. Enhancing multidimensional scaling through a distributed algorithm [J]. *The Journal of Supercomputing*, 2024, 80(15): 22049-22068.
- [19] WU H, WU P F, SHI Z S, et al. An aerial ammunition ad hoc network collaborative localization algorithm based on relative ranging and velocity measurement in a highly-dynamic topographic structure[J]. *Defence Technology*, 2023, 25: 231-248.
- [20] KUMAR S, KUMAR R, RAJAWAT K. Cooperative localization of mobile networks via velocity-assisted multidimensional scaling [J]. *IEEE Transactions on Signal Processing*, 2015, 64(7): 1744-1758.
- [21] WANG J, QIU X, TU Y. An improved MDS-MAP localization algorithm based on weighted clustering and heuristic merging for anisotropic wireless networks with

energy holes [J]. Computers, Materials & Continua, 2019, 60(1).

- [22] SHILPI, GAUTAM P R, KUMAR S, et al. An optimized sensor node localization approach for wireless sensor networks using RSSI [J]. The Journal of Supercomputing, 2023, 79(7): 7692-7716.
- [23] 高凤强, 王若宇, 曹光求, 等. 基于扩展卡尔曼滤波的疏散行人密度预测算法研究[J]. 仪器仪表学报, 2024, 45(5): 281-290.
- GAO F Q, WANG R Y, CAO G Q, et al. Research on the evacuation pedestrian density prediction algorithm based on extended Kalman filter[J]. Chinese Journal of Science Instrument, 2024, 45(5): 281-290.
- [24] 关存贺, 许高斌, 王焕章, 等. 复杂应力条件下 MEMS 加速度传感器可靠性分析[J]. 电子测量与仪器学报, 2023, 37(7): 17-25.
- GUAN C H, XU G B, WANG H ZH, et al. Reliability analysis of MEMS acceleration sensors under complex stress conditions[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 17-25.
- [25] FAN Y S, MENG F, LI G J, et al. A survey and evaluation of iterative optimization algorithms for cooperative localization [J]. Physical Communication, 2023, 60: 102165.

作者简介



江美娟, 2018 年于南昌航空大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为无线传感网络。

E-mail: 220223342@seu.edu.cn

Jiang Meijuan received her B. Sc. degree from Nanchang Hangkong University in 2018. Now she is a M. Sc. candidate at Southeast University. Her main research interest includes wireless sensor networks.



刘锡祥(通信作者), 1999 年于南京林业大学获得学士学位, 2004 年于东南大学获得硕士学位, 2007 年于东南大学获得博士学位。现为东南大学仪器科学与工程学院教授, 主要研究方向为惯性导航、感知定位、组合导航与信息融合技术研究。

E-mail: scliuseu@163.com

Liu Xixiang (Corresponding author) received his B. Sc. degree from Nanjing Forestry University in 1999, the M. Sc. degree from Southeast University in 2004, and the Ph. D. degree from Southeast University in 2007, respectively. Now he is a professor at the School of Instrument Science and Engineering at Southeast University. His main research interests include inertial navigation, perceptual positioning, combined navigation, and information fusion technology research.