

DOI: 10.13382/j.jemi.B2306971

基于 UWB 的加权同心圆聚类室内定位方法^{*}

徐 恒^{1,2} 刘 虎^{1,2} 邵 慧^{1,2} 孙 龙^{1,2} 胡玉霞^{1,2} 孟凡宇^{1,2}
(1. 安徽建筑大学电子与信息工程学院 合肥 230601;
2. 安徽省古建筑智能感知与高维建模国际联合研究中心 合肥 230601)

摘 要: 为了降低基于超宽带(UWB)测距中的非视距(NLoS)误差的影响,引入了一种基于遗传算法-反向传播神经网络(GA-BP)的UWB测距误差识别与优化方法,能够识别NLoS传播链路下的数据,对NLoS传播链路下测距误差和系统偏差进行校正,最后对测距结果使用卡尔曼滤波(KF)优化。在此基础上,针对测距误差导致的多边定位无交点或多交点问题,提出了一种加权同心圆聚类定位(WCCGT)方法,通过加权同心圆生成(WCCG)解决无交点问题,再采用均值漂移聚类定位方法实现定位解算,以提高定位精度。实验结果表明,改进的测距优化方法有效减小了NLoS传播链路下的测距误差,基于UWB的测距精度提升了60%以上;通过静态定位实验和动态实验分析,将WCCGT方法定位结果与最小二乘(LS)方法进行了比较,本文方法能够在NLoS环境下达到10.78 cm的定位精度,定位性能提升了17.32%。

关键词: UWB测距;GA-BP神经网络;卡尔曼滤波;NLoS测距误差;WCCGT定位方法

中图分类号: TN966 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Weighted concentric circle generation clustering indoor positioning method based on UWB

Xu Heng^{1,2} Liu Hu^{1,2} Shao Hui^{1,2} Sun Long^{1,2} Hu Yuxia^{1,2} Meng Fanyu^{1,2}
(1. School of Electronic and Information Engineering, Anhui Jianzhu University, Hefei 230601, China;
2. Anhui International Joint Research Center for Ancient Architecture Intellisencing and Multi-Dimensional Modeling, Hefei 230601, China)

Abstract: To mitigate the influence of non-line of sight (NLoS) errors in ultra-wideband (UWB) ranging, this study presents a method that utilizes a genetic algorithm backpropagation neural network (GA-BP) for error identification and optimization. This method effectively detects and rectifies ranging errors and system deviations occurring in the NLoS propagation link, and subsequently improves the ranging outcomes through the application of Kalman filtering (KF). On this basis, this paper proposes a weighted concentric circle clustering localization (WCCGT) method to address the problem of no intersection or multiple intersection points in multilateral positioning caused by ranging errors. The method solves the problem of no intersection points through weighted concentric circle generation (WCCG). Then, it uses the mean shift clustering localization method to achieve a localization solution and improve localization accuracy. The experimental results show that the improved ranging optimization method effectively reduces the ranging error in the NLoS propagation link, and the ranging accuracy based on UWB is improved by more than 60%. Analyze through static positioning experiments and dynamic experiments, the positioning results of the WCCGT method were compared with the least squares (LS) method. The proposed method can achieve a positioning accuracy of 10.78 cm in NLoS environments, and the positioning performance has been improved by 17.32%.

Keywords: UWB ranging; GA-BP neural network; Kalman filter; NLoS ranging error; WCCGT positioning method

收稿日期:2023-10-17 Received Date: 2023-10-17

^{*} 基金项目:安徽省教育厅自然科研重点项目(KJ2021A0622)、农业生态大数据分析与应用技术国家联合工程研究中心开放课题项目(AE202212)、安徽省住房城乡建设科学技术计划项目(2020-YF22)、安徽省科技厅面上项目(2008085MF182)、安徽省高校协同创新项目(GXXT-2021-028)、国家自然科学基金青年基金项目(62105002)资助

0 引言

商业消费、工业生产、医疗卫生、消防救援等需要高精度的室内定位技术来提供精准的位置信息。超宽带 (ultra-wide band, UWB) 信号具有良好的抗多径干扰能力,可以实现厘米级别的定位精度,具有高数据传输速率、容量高和功耗低等优点,因此 UWB 定位技术是室内定位技术的研究热点^[1]。在室内环境中,信号往往会被墙壁、家具等物体阻挡,在定位过程中引起非视距 (non-line-of-sight, NLoS) 误差以及多径干扰,因此消除或校正 NLoS 误差是室内定位中值得研究的课题。

UWB 室内定位技术中 NLoS 误差抑制的经典方法众多,其中基于卡尔曼滤波^[2] (Kalman filtering, KF)、模糊控制、贝叶斯滤波、最小二乘等方法层出不穷,目前在 UWB 测距中对 NLoS 传播链路识别的主流方式是采用机器学习技术作为分类器^[3],分类准确率与预测精度相当高。其中基于信道冲击响应时频图的多输入学习神经网络模型方法的 NLoS 传播链路识别准确率可以达到 91.74%^[4],利用接收信号的实时特征与机器学习方法相结合^[5],可以进一步提高 NLoS 传播链路识别的准确率并自适应抑制 NLoS 误差。

卡尔曼滤波一直是消除 NLoS 误差方法中的研究热点,在导航定位中受遮挡环境的影响较大,通过改进的自适应卡尔曼滤波组合导航方案,可以降低 24.2% 的定位误差^[6]。文献[7]提出了一种视距 (line-of-sight, LoS) 环境可信度的方法,并将其用于确定 NLoS 环境。将采用该方法补偿后的测量数据和前一时刻状态的最优估计值输入 KF 确定当前时刻的最优估计值。文献[8]采用扩展卡尔曼滤波 (extended Kalman filter, EKF) 滤除噪声,针对严重的 NLoS,提出了一种基于 LoS 重建的 NLoS 缓解算法,以估计 NLoS 误差的平均值,并重建和校正测量值以用于后续定位。文献[9]提出了一种神经网络修正多重滤波器定位算法,该算法首先对 LoS 和 NLoS 环境进行识别区分,再采用 KF 和无迹卡尔曼滤波 (unscented Kalman filter, UKF) 分别处理 LoS 和 NLoS 情况下的数据,对 NLoS 数据进行分组处理后,通过神经网络对多次滤波后的定位结果进行修正,该方法能够适用于 NLoS 误差较大的情况并优化定位结果。文献[10]采用模糊推理算法估计信道脉冲响应 (channel impulse response, CIR) 信号特征的 NLoS 误差并进行初步缓解。再通过自适应抗 NLoS KF 算法,并采用模糊推理算法缓解 NLoS 误差对测距误差进行二次缓解,从而进一步提高距离估计精度。文献[11]采用 EKF 计算定位初值,接着引入图优化 (FGO) 求出整体测距误差最小的基站位置,再将计算出的位置再次代入 EKF 进行二次计算得到更精确的定位

结果。上述方法都是以 KF 为基础进行改进抑制 NLoS 误差,然而算法的复杂度与环境适应性仍然需要多次实验分析进行验证。

近年,部分学者考虑改进定位算法以提高室内定位精度,文献[12]使用蜚螂优化算法代替三边测量法进行定位解算,平均定位误差提升了 55% 以上。惯性测量单元^[13] (inertial measurement unit, IMU) 和行人航迹推算^[14] (pedestrian dead reckoning, PDR) 是室内定位融合方法中常用的技术。文献[15]利用手机将 PDR 数据导出,通过 FGO 和 KF 将手机中的 PDR 数据与全球导航卫星系统数据相融合,提高了定位精度。使用智能手机与定位结合,为室内定位提供了新的思路。文献[16]采用 EKF 融合来自 UWB 和 IMU 的数据,得到移动目标的姿态、速度和位置。然后使用互补滤波将速度和输出与里程计输出融合以提高精度,该方法可以输出更高精确的定位数据。文献[17]通过图优化算法融合里程计和 UWB 测量数据实现全局位姿优化,使定位性能提升了 46%。

文献[1]和[21]均是对 BP 神经网络进行改进,用于定位解算以达到降低定位误差的目的。但在 NLoS 误差问题以及测距误差问题上并未给出优化的解决方案,本文首次采用 GA-BP 方法识别 NLoS 传播链路,结合 KF 算法以优化测距误差,为进一步提升定位精度做准备,文献[18]将加权同心圆生成 (WCCG) 方法应用在 Wi-Fi 定位中,经本文改进应用于 UWB 定位取得较好的定位精度。本文的主要工作包括:1) 采用 GA-BP 神经网络识别 NLoS 传播链路,通过拟合函数和 KF 算法对测量中的 NLoS 数据进行校正,降低 NLoS 数据对定位精度的影响;2) 提出的加权同心圆聚类定位 (WCCGT) 方法解决多边定位无交点或交点过多的问题,提升定位精度。在 3 种不同实验场景中验证算法,均能表现出优秀的定位性能,和传统的 LS 定位方法相比,LoS 环境定位精度提升了 29.25%,NLoS 环境定位精度提升了 17.32% 且具有一定的鲁棒性,满足室内复杂环境下定位需求。

1 UWB 测距原理

在基于 UWB 的测距过程中,基站从发射信号到接收信号所用的时间定义为时间戳,即飞行时间 (time of flight, TOF),将电磁波传输速率与飞行时间的相乘即为标签与基站间的距离。UWB 测距通常采用双边双向测距方法 (asymetric double side two-way ranging, ADS-TWR),原理如图 1 所示。

节点 A、B 建立通信,由原理图可以得到:

$$T_1 = 2 \times TOF + T_2 \quad (1)$$

$$T_3 = 2 \times TOF + T_4 \quad (2)$$

$$T_1 + T_4 = T_2 + T_3 \quad (3)$$




图1 双边双向测距原理

Fig. 1 Schematic diagram of asymmetric double side two-way Ranging

将式(1)和(2)两边相乘整理得到:

$$T_1 \times T_3 - T_2 \times T_4 = 2 \times TOF(T_3 + T_2) \quad (4)$$

联立式(3)和(4)得到:

$$TOF = \frac{T_1 \times T_3 - T_2 \times T_4}{T_1 + T_2 + T_4 + T_3} \quad (5)$$

式中: TOF 表示飞行时间, T_1 表示节点 A 发送信号与节点 A 接收到节点 B 发出响应的的时间差, T_2 表示节点 B 收到 A 的发送的信号与节点 B 发出响应的的时间差, T_3 表示节点 B 发出响应与节点 B 收到节点 A 发出反馈的时间差, T_4 表示节点 A 收到 B 的响应与节点 A 发出反馈的时间差。

将 TOF 和电磁波传输速率 c 相乘得到距离 x :

$$x = c \times TOF \quad (6)$$

分析该方法的测距误差,假设节点 A 的时钟漂移为 γ_A , 节点 B 的时钟漂移为 γ_B ; 实际 T_1, T_2, T_4, T_3 分别表示为 t_1, t_2, t_4, t_3 , 实际 TOF 表示为 tof 。则有:

$$t_1 = (1 + \gamma_A) T_1 \quad (7)$$

$$t_2 = (1 + \gamma_B) T_2 \quad (8)$$

$$t_3 = (1 + \gamma_B) T_3 \quad (9)$$

$$t_4 = (1 + \gamma_A) T_4 \quad (10)$$

将式(7)~(10)代入式(5)中得到:

$$tof = \frac{2(1 + \gamma_A)(1 + \gamma_B)}{(1 + \gamma_A) + (1 + \gamma_B)} TOF \quad (11)$$

实际造成的信号飞行时间误差为:

$$Error = tof - TOF = \frac{\gamma_A + \gamma_B + 2\gamma_A\gamma_B}{2(1 + \gamma_A)(1 + \gamma_B)} tof \quad (12)$$

因为 $\gamma_A \ll 1, \gamma_B \ll 1$, 略去高次项可得:

$$Error \approx \frac{\gamma_A + \gamma_B}{2} tof \quad (13)$$

从式(13)中可以看出此时误差仅与节点 A 或 B 的时钟漂移有关,即使设备的时钟精度很差,单个设备的时钟漂移将被限制在一个单独的时间域内,设备自身的时

间漂移导致的测距误差可以忽略不计。

在 UWB 定位中经常采用 ADS-TWR 测距方法, ADS-TWR 测距方法的误差与时间差更相关,因此在时间差相对较小的情况下,测距精度更高; ADS-TWR 测距算法不需要定位基站的同步,增加了系统的鲁棒性;因此在定位和位置估计方面得到广泛的应用。

2 NLoS 传播链路的识别与误差优化定位方法

NLoS 指的是信号在传输过程中受到的非线性畸变,包括多普勒频移、频率选择性衰落、路径损耗等。在 UWB 定位中, NLoS 会严重影响测量距离的准确性。TWR 方法可以一定程度降低信号在传输过程中 NLoS 的影响,但是仍然会有较大的测距误差。因此本文实验中通过设置障碍物的位置模拟 NLoS 场景,根据 UWB 信号特征识别 NLoS 传播链路,并研究障碍物位置与 NLoS 传播链路下信号接收之间的关系,以进一步提高 UWB 测距的精度。

2.1 NLoS 识别的分类特征

由于室内建筑物材料特性、材料折射率不同等因素,分类问题的复杂性也相对增加,在实际环境中 NLoS 与 LoS 一般同时存在,得到准确的 NLoS 测距误差分布和相关先验信息,能极大提升测距精度。因此众多 NLoS 传播链路的识别算法被提出,文献[19]基于 NLoS 与 LoS 传播链路下的信号强度值构建识别模型,文献[20]等采用 CIR 信号波形特征对 NLoS 传播链路进行分类。传统的 NLoS 传播链路识别方法主要依赖于 UWB 通信中接收信号的统计条件,通过计算估计的接收信号(received signal, RX)强度和第一路径(first path, FP)接收强度之间的差值来实现 NLoS 识别,当阈值功率使用小于 6 dBm 时,测距信号被归类为 LoS,当阈值功率大于 10 dBm 时,被归类为 NLoS。

多径效应和 NLoS 取决于信号传播的介质、测量信号的位置、测量环境中其他物体的位置等,采用传统的统计方法分类需要进行大量的计算,其复杂度较高,容易受到噪声和偏差的影响,导致检测结果不准确。为了克服传统方法的缺陷,可以采用基于机器学习的 NLoS 传播链路识别方法。本文采用 UWB 信号特征识别信号传播链路是否处于 NLoS 传播链路。

使用 UWB 信号特征进行 NLoS 传播链路识别可以被视为一个二元分类问题。基于机器学习的方法在 NLoS 传播链路识别中得到了广泛应用,训练一个分类器自动学习数据中的 NLoS 传播链路特征,从而更准确地识别 NLoS 传播链路。其中 BP 神经网络方法具有较高的处理速度和精度,可以根据需要自行调整网络的结构,更

好地适应数据变化和噪声的影响,但在寻找阈值和权值的过程中容易陷入局部最优^[21]。因此本文采用 GA-BP 神经网络方法用于 NLoS 传播链路的识别。

2.2 基于 GA-BP 神经网络的 NLoS 传播链路识别方法研究

本文采用改进的 GA-BP 神经网络方法进行 NLoS 传播链路识别,解决了 BP 神经网络易陷入局部最优的问题,提高了网络的收敛速度。通过 GA 算法对 BP 神经网络中的参数编码形成的种群进行进化。进化结束后,对种群中最优良的个体进行解码获取最优参数,并用其构建 BP 神经网络鉴别模型。

GA-BP 神经网络流程图如图 2 所示,其左半部分为 BP 神经网络算法流程,右半部分为 GA 流程。




图 2 GA-BP 神经网络流程

Fig. 2 GA-BP neural network flow chart

相关算法步骤如下:

1) 构建 BP 神经网络模型,图 3 为 BP 神经网络的拓扑结构,网络一般由 1 个输入层、1 个输出层、1 个或多个隐含层,输入层 X_i 神经元个数为 m ,激活函数为 f_1 ,输出层 Z_k 神经元个数为 l ,激活函数为 f_2 ,输入层与隐含层 Y_j 的权值为 w_{ij} ,隐含层与输出层的权值为 w_{kj} ,隐含层神经元个数根据经验公式 $n \geq \log_2 m$ 确定,其中 n 为隐含层神经元个数。

2) 对初始种群进行参数初始化,对 BP 神经网络的初始权值和阈值进行编码,编码长度为:

$$S = n \times m + m \times l + m + l \quad (14)$$

3) 对测试数据进行归一化处理并训练网络,计算误差,将误差代入适应度函数计算适应度 f :




图 3 BP 神经网络的拓扑结构

Fig. 3 The topological structure of BP neural networks

$$f = \frac{1}{SE} \quad (15)$$

式中: SE 表示网络的期望输出值与实际输出值之间的误差平方和。

4) 计算种群中个体的适应度函数值,进行选择操作,个体的选择按照选择概率值进行,公式如下:

$$P_i = \frac{f_i}{\sum_{i=1}^I f_i} \quad (16)$$

式中: f_i 为适应度值, i 为该种群的个体。

5) 最优个体不需要进行交叉及下一步的变异操作,将其直接复制到下一代中。本实验采用高概率下的单点交叉,假设需要进行交叉操作的基因为第 i 个染色体的第 k 个基因 g_{ik} 和第 j 个染色体的第 k 个基因 g_{jk} ,其交换过程如下:

$$\begin{cases} g_{ik} = g_{ik}(1 - e) + g_{jk}e \\ g_{jk} = g_{jk}(1 - e) + g_{ik}e \end{cases} \quad (17)$$

式中: e 是一个 $[0, 1]$ 之间的随机数。

6) 将基因设为 2 个方向变异,假设基因的最大值为 $g_{\max}$,最小值为 $g_{\min}$,当向最大值方向变异时,变异幅度不超过 $g_{\max} - g$,当向最小值方向变异时,变异幅度不超过 $g - g_{\min}$,公式如下:

$$g_{ij} = \begin{cases} g_{ij} = e(g_{\max} - g_{ij}) \cdot I \\ g_{ij} = e(g_{ij} - g_{\min}) \cdot I \end{cases} \quad (18)$$

$$I = \left(1 - \frac{I_c}{I_{\max}}\right)^2 \quad (19)$$

式中: I 是加速后期变异的函数, I_c 为当前迭代次数, $I_{\max}$ 最大迭代次数。

7) 判断性能是否满足要求,如不满足重复进行步骤 3)~4),当达到预设目标或者完成设置的迭代次数为止,对适应度最高个体进行解码,得到 BP 神经网络的最优权值和阈值,使用最优参数构建网络模型,进行 NLOS 识别分类。

当 GA-BP 神经网络确定了最优权值和阈值,然后将数据集输入到网络中训练学习,完成对 NLOS 数据的分类检测,对不精确的测距结果进行下一步误差校正。

GA-BP 神经网络算法如算法 1 所示。

算法 1 GA-BP 神经网络算法
输入:输入数据 D , 权值矩阵 V, W , 隐含层阈值矩阵 Y , 输出层阈值矩阵 Z , 染色体基因向量 X_i , 初始种群个数 M
输出:分类结果 O
1: initialize: $X_i = \text{random}$
2: initialize: BP neural network
3: Update the fitness value of X_i by Eq. (14)
4: for $i = 1$ to M do
5: Select operation by Eq. (15)
6: end for
7: for $i = 1$ to $M/2$ do
8: Crossover operation by Eq. (16)
9: end for
10: for $i = 1$ to M do
11: Mutation operation by Eq. (17)
12: end for
13: Decode the chromosome vector X_i into matrices V, W, Y, Z of BP neural network
14: train the BP neural network using D
15: return O

2.3 测距误差校正方法

本实验分别选取了金属板和木板作为障碍物,将发射节点与接收节点间隔开,节点间距分别设置 1.6、3.2、4.8、6.4、8、9.6 m,每个点测量收集 50 组数据,读取接收 UWB 信号的测距结果,金属板和木板对真实距离的影响如图 4 所示。




图4 不同材质遮挡物距离测量值
Fig.4 Distance measurement values for different materials of obstructions

从图 4 中可以看出金属板对测距精度的影响最大,木板对测距精度的影响较小。

根据实验测得在金属板和木板影响下的实际测距误差,如图 5 所示。利用二次多项式对测距误差进行拟合

得到拟合曲线如图 6 所示,利用拟合曲线对金属板和木板引起的测距误差进行补偿。




图5 测距误差分布箱型图
Fig.5 Box plot of distance measurement error distribution




图6 绝对误差拟合曲线
Fig.6 Fitting curve of absolute error in box plot of distance measurement error distribution

金属板的误差拟合曲线为:

$$f(x) = -21.266 + 0.138x - 3.132 \times 10^{-5}x^2 \quad (20)$$

木板的误差拟合曲线为:

$$f(x) = -45.466 + 0.0451x - 2.175 \times 10^{-5}x^2 \quad (21)$$

由于测量设备本身的误差,在 LoS 下也会造成一定的测距误差,所以对无遮挡情况下的误差,本文也对其作了误差拟合。

无遮挡情况下的误差拟合曲线为:

$$f(x) = -56.737 + 0.079x - 5.480 \times 10^{-5}x^2 \quad (22)$$

式中: x 表示实际测距值, $f(\cdot)$ 表示测距误差。

NLoS 传播链路识别与误差校正方法流程如图 7 所示。

- 1) 节点间建立通信关系进行测距;
- 2) 通信过程的特征数据输入到 GA-BP 神经网络模型中,对节点通信的传播链路进行识别;




图 7 NLoS 传播链路识别与误差校正流程

Fig. 7 Flow chart of NLoS propagation link identification and error correction

3) 识别结果为 LoS 或是 NLoS, 根据对应的误差曲线对测得的距离值进行误差补偿, 获得校正后的测距结果。

根据以上方法, 可以设计程序对不同传播链路下的测距误差实现自动补偿, 得到初步校正后的测距结果。

但是在实际测距中, 测距信号在 NLoS 传播链路的影响下, 测得的信号中含有粗差和噪声。采用卡尔曼滤波算法减少粗差、降低噪声, 使数据输出更加平滑, 进一步提高测试数据的稳定性和精度。

卡尔曼滤波算法流程如图 8 和算法 2 所示。用 TOF 测出的距离经误差校正得到补偿后的距离与距离变化率作为系统的状态向量, 建立测距模型:

$$\hat{\mathbf{x}}_k = \mathbf{A} \hat{\mathbf{x}}_{k-1} \quad (23)$$

其中, $\mathbf{x} \in R^m$ 表示待估计状态, k 和 $k-1$ 分别表示当前状态和前一状态。

$$\mathbf{P}_k = \mathbf{A} \mathbf{P}_{k-1} \mathbf{A}^T + \mathbf{Q} \quad (24)$$

其中, $\mathbf{P}$ 为预测协方差矩阵, $\mathbf{Q}$ 为系统噪声协方差矩阵。 $\mathbf{A} \in R^{n \times n}$ 表示连续时间步长的状态之间的传递矩阵, Δt , 可以表示为:

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

卡尔曼滤波增益矩阵为:

$$\mathbf{K}_k = \mathbf{P}_k \mathbf{H}^T (\mathbf{H} \mathbf{P}_k \mathbf{H}^T + \mathbf{R}_k)^{-1} \quad (25)$$

其中, $\mathbf{K}_k$ 表示卡尔曼增益; $\mathbf{R}_k$ 表示观测噪声。

$$\mathbf{x}_k = \hat{\mathbf{x}}_k + \mathbf{K}_k (\mathbf{Z}_k - \mathbf{H} \hat{\mathbf{x}}_k) \quad (26)$$

其中, $\mathbf{Z} \in R^m$ 表示实际测量值, 此式为目标状态更新, 输出当前时刻状态估计。

$$\mathbf{P} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k \quad (27)$$

其中, $\mathbf{I}$ 为单位矩阵, 此式为协方差矩阵更新。 $\mathbf{H} \in R^{m \times n}$ 表示当前状态与实际测量值的转移矩阵, 可以表示为:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$$




图 8 卡尔曼滤波算法流程

Fig. 8 Flow chart of Kalman filter algorithm

算法 2 卡尔曼滤波算法

输入: 状态转移矩阵 $\mathbf{A}$, 输入增益矩阵 $\mathbf{B}$, 过程噪声协方差矩阵 $\mathbf{Q}$, 观测矩阵 $\mathbf{H}$, 预测协方差矩阵 $\mathbf{P}$, 观测噪声协方差矩阵 $\mathbf{R}$

输出: 估计结果 $\mathbf{x}$

- 1: $\hat{\mathbf{x}}_k = \mathbf{A} \hat{\mathbf{x}}_{k-1} + \mathbf{w}$
- 2: $\mathbf{P}_k = \mathbf{A} \mathbf{P}_{k-1} \mathbf{A}^T + \mathbf{Q}$
- 3: $\mathbf{K}_k = \mathbf{P}_k \mathbf{H}^T (\mathbf{H} \mathbf{P}_k \mathbf{H}^T + \mathbf{R}_k)^{-1}$
- 4: $\mathbf{x}_k = \hat{\mathbf{x}}_k + \mathbf{K}_k (\mathbf{Z}_k - \mathbf{H} \hat{\mathbf{x}}_k)$
- 5: $\mathbf{P} = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k$
- 6: return $\mathbf{x}$

2.4 定位方法

本节提出一种基于加权同心圆生成的聚类定位 (WCCGT) 方法。如图 9 所示, 分为 3 个步骤。第 1 步数据收集和预处理, 记录原始数据, 通过本文的优化方法消除测距偏差。第 2 步定位, 采用加权同心圆生成 (weighted concentric circle generation, WCCG) 方法解决多边定位中没有交点或交点不足的问题, 再结合均值漂移聚类定位方法解算定位结果。第 3 步定位优化, 应用卡尔曼滤波改进定位结果。

1) 加权同心圆生成

在理想情况下, 当测距测量稳定且足够准确时, 每对测距圆至少给出一个交点。然而, 由于测距误差, 交点可能在错误的位置, 也可能没有交点。




图9 定位流程

Fig. 9 Positioning flow chart

经本文提出的优化方法校正测距误差后,会出现多边形定位时无交点的情况。此外,由于器件自身偏差也会使测距结果短于真实距离,也会导致定位过程无法找到交点。为了解决这个问题,本文提出了 WCCG 方法来生成一组同心圆,以找到定位交点。

没有系统偏差的测距结果为 r , 测距误差为 λ_i , 则同心圆的半径应为 $r_i = r + \lambda_i$ 。已知 DWM1000 的误差概率分布为 $n_m \sim N(\mu, \sigma^2)$, 可以用于确定测距误差 $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_i]$ 。

图 10 显示了同心圆方法如何解决不相交的问题。其中两个实线圆表示两个基站到待定位节点的测距结果,虚线圆均为与两个实线圆同心的圆。虚线圆由 WCCG 方法生成可以为多边形定位提供交点,从而解决实线圆无交点的问题。




图10 解决无交点问题的加权同心圆生成图示

Fig. 10 Illustration of weighted concentric circle generation to solve the no intersection issue.

因此,需要一个同心圆组 $O = [O_1, O_2, \dots, O_i, \dots, O_k]$ 来为图 10 中的情况创建交点。 O 中的所有圆都具有相同的中心,每个 O_i 对应半径 r_i 。最后使用重要性采样来生成集合。

$$E_p(f) = \frac{1}{m} \sum_{i=1}^m \frac{f(X_i)p(X_i)}{q(X_i)}, X_i \sim q \quad (28)$$

式中: $E_p(\cdot)$ 表示 $X_i \sim q$ 期望值, m 表示在 λ 中的样本数, $f(\cdot)$ 是 X_i 的函数, $p(\cdot)$ 是期望分布的概率密度函数, $q(\cdot)$ 是建议分布的概率密度函数 $n_m \sim N(\mu, \sigma^2)$ 。

这将均匀分布的随机样本分布转换为拟合误差直方图的正态分布。

通过该方法,可以将单个测距结果生成一组同心圆,即在固定位置记录了多个模拟测量值。WCCG 过程之后,将为下一步均值偏移聚类过程计算提供交点位置。

2) 聚类定位

三边测量需要至少 3 个不同圆相对应的范围测量来确定位置。理论上,可以从两对圆计算出 4 个交点,其中两个交点应该出现在或聚集在同一位置。图 11 显示了 3 个同心圆组(每组有 3 个圆)之间的交点,其中 A 组和 B 组有两组交点, B 组和 C 组有两组交点; A 组和 C 组有两组交点。虚线圈出的区域中总共有 27 个交叉点,待定位标签的最佳估计位置在该区域。




图11 同心圆组的交点示意图

Fig. 11 Schematic diagram intersections of concentric circle groups

在位置估计中,待定位标签处于具有最高点密度的区域内。因此,本文提出了一种自动对所有交点进行聚类并找到最高密度聚类区域的方法,作为位置估计的解决方案。

(1) 均值漂移聚类原理

均值偏移聚类算法是一种非参数迭代算法,广泛应用于模式识别、聚类等。聚类的形状和规模都可以基于不同的核、邻域函数和均值偏移聚类带宽来识别。它的一个特别重要的特征是不需要先验地知道集群和集群中心的数量,这和计算交点定位的情况契合,因为不知道交点数量以及所需交点的位置。

在应用均值漂移聚类算法之前,需要预先设置几个参数和函数。首先是核函数 $K(\cdot)$, 它通常被设置为高斯核。

$$K(d) = \frac{1}{\sqrt{2\pi}B} e^{-0.5(d/B)^2} \quad (29)$$

式中: d 是由邻域函数 $N_{nb}(\cdot)$ 确定的距离, B 是均值漂移聚类的带宽,这是用于确定聚类规模的预设参数。其次,样本集 P_i 包括根据测距结果计算的所有交点 p 。使用 $N_{nb}(\cdot)$ 确定样本位置 p 周围的相邻点的邻域函数, $p \in P_i$ 。定义 $N_{nb}(\cdot)$ 为欧几里得距离阈值,以选择附近

的点,因此对于 $p = (x, y)$ 有:

$$N_{nb}(p) = (p - p_i) = \sqrt{(x - x_i)^2 + (y - y_i)^2} \quad (30)$$

对于第 1 次聚类,随机选择一个采样点。然后计算随机选择的交点附近的交点的平均漂移 $m(p)$ 。

$$m(p^l) = \frac{\sum_{p_i^l \in P_i^l} K(p^l - p_i^l) p_i^l}{\sum_{p_i^l \in P_i^l} K(p^l - p_i^l)} = \hat{p} = p^{l+1} \quad (31)$$

迭代 l 时的聚类中心 p^l 移动到新计算的位置 $\hat{p}$, 并用作下一次迭代 $m(p^{l+1})$ 的输入位置。 p 持续更新迭代到 $p = \hat{p}$ 位置不再移动,最终找到聚类中心,第 1 个聚类的迭代结束。

在迭代中排除聚类中的所有点以找到下一个聚类,并且从剩余的点中随机选择新的采样点。这样重复几次,直到所有样本被分类到不同的聚类。

(2) 基于均值漂移聚类的定位

经过聚类,交点密度最高的聚类被确定为聚类中心为 $C_m = (x_m, y_m)$ 的主聚类。然而,由于测距误差,目标交点区域可能会被分割成几个相互靠近的不同聚类。因此,需要继续识别具有簇中心 $C_{sub}^i = (x_{sub}^i, y_{sub}^i)$ 的子簇,其中 i 是子聚类的索引,它是包括所有最优估计点。计算所有集群与主集群之间的距离(中心到中心),如果距离短于阈值 T_s , 则集群将被命名为子集群。

子簇选择需要指定两个参数,这两个参数是平均漂移带宽 B 以及阈值 T_s 。首先,将平均漂移带宽 B 设置为测距结果的误差;其次,子聚类的阈值 T_s 被设置为误差概率分布函数中最大误差的两倍。如果检测到的聚类中心距离比主聚类的测距误差的最大值还高,则这些聚类中的点可忽略。最终解算的位置是主聚类 and 所有子聚类中所有点的平均坐标。

3 实验与分析

3.1 实验安排

本次实验选取本校实验楼平台进行测试环境的搭建,如图 12 所示。在不同遮挡物的条件下获取实验所需的数据,采集过程均在动态情况下进行,连接笔记本端的设备保持静止,另一个设备与静止设备保持在同一高度,由实验人员拿着设备随机走动。分别有金属板、混凝土柱、木板、人体作为障碍物制造 NLoS 传播链路场景阻碍收发器之间的通信。

测试数据集在上述测量环境中得到,接下来的实验保持测量环境不变,完成测距验证分析。在金属板和木板两种障碍物遮挡的场景下,收发器之间的通信有明显的 NLoS 传播链路,对于这两种障碍物遮挡场景分别设置



图 12 收集训练和测试数据的实验场景
Fig. 12 Experimental scenarios for collecting training and testing data

6 组静态实验来验证本文优化方法的测距效果。

在测量过程中,两个收发器中的一个连接到计算机,通过串行端口记录数据,天线高度始终保持在 1.2 m。通过采集不同场景下的 UWB 信号特征用于训练分类器,本实验使用 Decawave 制造的 DWM1000 芯片为核心模块的 D-DWM-PG 设备提取了 11 个 UWB 信号特征,该模块采用 DW1000 芯片通道 2 的信道,中心频率为 3 993.6 MHz,频段为 3 774~4 243.2 MHz,占用的带宽为 499.2 MHz。在实验中提取并保存的特征参数如表 1 所示。以上 11 个特征的提取全部基于 Decawave 公司生产的 DW1000 芯片作为 UWB 收发硬件支持。

表 1 提取到的 UWB 特征参数
Table 1 Extracted UWB feature parameters

序号	特征参数
1	测量距离
2	FP 信号中多重谐波的复合振幅
3	FP 信号中第一谐波的幅值
4	FP 信号中二次谐波的振幅
5	FP 信号中三次谐波的幅值
6	信道脉冲响应(CIR)
7	接收前导码数量
8	FP 强度
9	RX 强度
10	标准噪声
11	最大噪声

为了验证本文所提出算法的性能,选取 3 种室内场景进行了 3 组实验。均采用 4 组基站,1 组测试标签的部署方式。实验 1:如图 13(a)所示,选取 16 m×4.8 m 的室内过道区域,保持基站与移动标签间视距无遮挡,分别进行静态实验以及动态实验以验证定位性能。实验 2:如图 13(b)所示,选取 11.2 m×6.4 m 的室内区域测试定位算法,在遮挡情况下的定位性能,分别进行静态实验以及动态实验以验证定位性能。实验 3:选取 11 m×7.5 m 的车库区域测试定位算法,在严重遮挡环境下的定位性能,分别进行静态实验以及动态实验以验证定位性能,如图

13(c) 所示。



图 13 实验场景图

Fig. 13 Experimental scene diagram

3.2 结果分析

1) 测距数据分析

为了检验 GA-BP 算法对网络训练过程优化的效果, 本文分别对 GA-BP 算法、BP 算法和主成分分析-反向传播神经网络 (PCA-BP) 算法进行了 NLoS 传播链路识别实验对比, 评估指标结果如表 2 所示。

表 2 评估指标				
算法	准确率	精确率	召回率	F1 分数
BP	88.67	94.73	84.24	89.18
PCA-BP	90.21	94.04	87.37	90.58
GA-BP	91.63	96.04	88.27	91.99

首先比较 BP 和 PCA-BP 两种算法的训练效果, 从表 2 可以看出, BP 训练结果的准确率、精确率、召回率和 F1 分数分别为 88.67%、94.73%、84.24% 和 89.18%, 而 PCA-BP 训练结果的准确率、精确率、召回率和 F1 分数

分别为 90.21%、94.04%、87.37% 和 90.58%, 相比于 BP 的结果精确率低 0.69%, 但其他指标均高于 BP。

由此可见 PCA-BP 算法在降低特征维度, 减少存储和计算开销的同时提高了 BP 的分类准确率。从表 2 可以看出, GA-BP 训练结果的准确率, 精确率, 召回率和 F1 分数分别为 91.63%、96.04%、88.27% 和 91.99%, 相比于 PCA-BP 算法, 所有指标均有较大提升, 较好地实现对 NLoS 传播链路的识别分类。GA-BP 算法比 BP 算法的 F1 分数提升了 2.81%, 有效提高了神经网络模型的训练精度。

为验证本文优化方法的有效性, 本文选取金属板遮挡的 NLoS 场景, 分别对基于随机森林 (RF) 回归、基于长短期记忆网络 (LSTM) 回归、基于支持向量机 (SVM) 回归、本文拟合方法、本文拟合方法结合 KF 算法的优化方法 5 种方法进行了对比。

图 14 和 15 分别展示了这 5 种方法的优化测距值和测距值误差对比, 表 3 罗列了 5 种优化测距结果误差的统计数据, 包括距离值的均方根误差值和最大误差值。




图 14 测距值对比

Fig. 14 Comparison of ranging values




图 15 测距误差对比

Fig. 15 Comparison of ranging errors

表 3 5 种算法的测距误差对比

Table 3 Ranging error comparison of five algorithms (cm)

算法	均方根误差	最大误差
RF	43.45	147.60
LSTM	35.44	99.09
SVM	30.84	69.85
拟合方法	14.61	33.49
优化方法	14.11	30.29

首先比较 RF 和 LSTM 两种算法的测距效果,从图 15 和表 3 可以看出,RF 测距最大误差和均方根误差分别为 147.60 和 43.45 cm,LSTM 测距最大误差和均方根误差分别为 99.09 和 35.44 cm,相比于 RF 误差分别下降了 32.87% 和 18.43%。因为 LSTM 具有记忆能力,能够将先前的信息存储在内部状态中。具有强大的预测能力,对 NLoS 误差的抑制效果更好。从表 3 可以看出 SVM 测距最大误差和均方根误差分别为 30.84 和 69.85 cm,相比于 LSTM 误差分别下降了 12.98% 和 29.51%,而本文的拟合方法测距最大误差和均方根误差分别为 14.61 和 33.49 cm,在优化方法中均方根误差降到了 14.11 cm,比 RF 测距精度提升了 67.53%,从图 14 和 15 可以看出优化方法比拟合方法更接近实际值且鲁棒性更好。

本文在图 16 实验环境下对比了金属板和木板两种障碍物遮挡情况下的 6 组测距实验的结果,图 16(a)~(f)是金属板遮挡情况下测距结果的累积分布函数(Common Data Format,CDF)图,图 17(a)~(f)是木板遮挡情况下测距结果的 CDF,其中虚线是原始数据的误差 CDF,实线是采用误差校正以及卡尔曼滤波算法处理后的测距误差 CDF,从图中可以发现区分度非常明显,经过优化方法处理后的数据误差能够快速收敛,误差范围更小。





图 16 金属板遮挡下的测距结果

Fig. 16 Distance measurement results under metal plate shield

如图 16 和 17 所示,本文的方法对金属板和木板两种障碍物遮挡情况下的测距精度都有较大的提升。




图 17 木板遮挡下的测距结果

Fig. 17 Distance measurement results under the wooden boards shield

为验证本文方法的泛化能力,在图 18 地下车库场景下分别进行金属板和木板两种障碍物遮挡情况的测距实验分析。地下车库由于空间狭窄,并且有金属消防管道等复杂设施存在,所以该环境场景会造成更为严重的 NLoS 测距误差。

表 4 是在图 18 场景下分别对 GA-BP 算法、BP 算法和 PCA-BP 算法进行的 NLoS 传播链路识别实验的评估指标结果对比。

从表 4 可以看出,在改变实验场景后,本次 BP 的准



图 18 车库实验场景

Fig. 18 Garage experiment scenarios

确率,精确率,召回率和 F1 分数分别为 96.23%、96.19%、96.23%和 96.21%,而 PCA-BP 的准确率,精确率,召回率和 F1 分数分别为 93.13%、94.82%、91.68%和 93.22%,BP 的各项指标结果明显优于 PCA-BP,由此可见在复杂场景下 PCA-BP 算法降低特征维度会使得分类准确率降低。从表 4 可以看出,GA-BP 的准确率,精确率,召回率和 F1 分数分别为 96.77%、96.88%、96.60%和 96.74%,相比于 BP 算法,所有指标均保持较高数值,GA-BP 算法采用 GA 算法避免了网络在训练时陷入局部最优解,有效提高神经网络模型的训练精度。

表 4 评估指标				
Table 4 Evaluation indicators (%)				
算法	准确率	精确率	召回率	F1 分数
BP	96.23	96.19	96.23	96.21
PCA-BP	93.13	94.82	91.68	93.22
GA-BP	96.77	96.88	96.60	96.74

图 19(a)~(d)是金属板遮挡情况下测距结果的累积分布函数 CDF 图,图 20(a)~(d)是木板遮挡情况下测距结果的 CDF,其中虚线是原始数据的误差 CDF,实线是采用误差校正以及卡尔曼滤波算法处理后的测距误差 CDF。

从图 19 和 20 可以看出,在更换实验场景后,采用本文的方法仍对金属板和木板两种障碍物遮挡情况下的测距精度都有较大的提升,证明了优化方法的有效性。

从测距实验选取 6 个位置,在相同的距离下,本文优化方法对金属板和木板造成的 NLoS 误差抑制效果如表 5 所示。

表 5 测距值对比							
Table 5 Comparison of ranging values (cm)							
主要测距值	339	453	684	755	865	933	平均误差
木板遮挡	305.92	418.61	651.16	728.75	841.46	905.47	29.61
优化方法	339.71	449.12	676.66	753.10	864.61	928.18	3.17
金属板遮挡	400.32	471.26	716.77	799.06	966.53	1010.47	55.90
优化方法	386.58	449.75	667.04	739.35	885.73	923.97	18.87

从表 5 中可以看出,在木板遮挡实验环境下平均测




图 19 金属板遮挡下的测距结果

Fig. 19 Distance measurement results under metal plate shield




图 20 木板遮挡下的测距结果

Fig. 20 Distance measurement results under the wooden boards shield

距误差从 29.61 cm 减少到 3.17 cm,在金属板遮挡实验环境下测距误差从 55.90 cm 减少到 18.87 cm。测距精度分别提升了 89.29%和 66.24%在相同距离下,由于木板和金属板遮挡所产生的 NLoS 传播链路引起的测距误差,在经过本文的优化方法优化后,测距误差明显减小,精度有明显的提高。

从表 5 中可以看出,在木板遮挡实验环境下平均测距误差从 29.61 cm 减少到 3.17 cm,在金属板遮挡实验环境下测距误差从 55.90 cm 减少到 18.87 cm。测距精度分别提升了 89.29%和 66.24%在相同距离下,由于木板和金属板遮挡所产生的 NLoS 传播链路引起的测距误

差,在经过本文的优化方法优化后,测距误差明显减小,精度有明显的提高。

2) 定位数据分析

(1) 静态定位实验分析

不同的估计方法的定位效果不同,如图 21 和表 6 所示,在静态定位实验中对比了最小二乘法 (LS) 定位方法与本文提出的加权同心圆聚类 (WCCGT) 定位方法,在实验 1 的无遮挡场景下,WCCGT 定位结果明显优于 LS,定位误差保持在 35 cm 以内,定位误差降低 29.25%。在实验 2 复杂室内环境下,WCCGT 定位结果仍然优于 LS,定位误差保持在 20 cm 以内,定位误差降低 17.32%。在实验 3 严重遮挡的室内环境下,WCCGT 定位结果在整体上依然优于 LS,定位误差保持在 25 cm 以内,定位误差降低 6.08%。由此可知本文方法可以有效减小实验环境下的 NLoS 误差,有利于提升定位精度。

表 6 不同定位方法的定位误差对比
Table 6 Positioning errors from different localization methods (cm)

	定位方法	平均误差
实验 1	LS	23.22
	WCCGT	16.43
实验 2	LS	13.04
	WCCGT	10.78
实验 3	LS	14.41
	WCCGT	13.53

(2) 动态定位实验分析

在动态实验中,待定位标签由轮式机车人携带按照设定轨迹进行移动。图 22 给出了 3 种室内场景下 LS 方法以及 WCCGT 方法输出的定位轨迹与实际轨迹的对比。在实验 1 的无遮挡场景下,WCCGT 定位轨迹更加接近实际值。在实验 2 复杂室内环境下,WCCGT 定位轨迹在两个转弯处的轨迹明显优于 LS 方法。在实验 3 严重遮挡的室内环境下,WCCGT 定位轨迹在 (200 cm, 200 cm) 至 (900 cm, 200 cm) 段比 LS 差,但从整体的定位轨迹可以观察到 WCCGT 方法优于 LS,由此可知本文方法在视距环境中具有良好的定位性能,在 NLoS 环境下也具有稳定且优秀的定位精度,有效降低由于 NLoS 影响而造成的定位误差。

4 结 论

本文基于 UWB 测距技术设计了静态目标测距实验,验证了本文提出的优化方法能够降低由建筑材料的遮挡等因素而导致的 NLoS 测距误差对室内定位精度的影响。针对 NLoS 误差优化问题,本文采用了 GA-BP 神经网络




图 21 不同定位方法的定位结果对比
Fig. 21 Positioning results from different localization methods

算法对 NLoS 传播链路进行识别,该算法能够更好地提取数据中 NLoS 传播链路的特征,实现网络的快速收敛,最终识别出 NLoS 传播链路。针对 NLoS 传播链路所造成的误差,本文提出了一种基于卡尔曼滤波的优化方法对测距误差进行优化。实验结果表明,GA-BP 神经网络算法能有效识别出 NLoS 传播链路,采用本文的优化方法校正后,可有效地减小 NLoS 测距误差,测距精度相比于原




图 22 不同定位方法轨迹对比

Fig. 22 Trajectories from different localization methods

测距值提升了 60% 以上,结合提出的 WCCGT 定位方法在 NLoS 环境中能够提升 17.32% 的定位精度。可为基于距离的室内定位方法提供有效的技术支持和理论依据。

参考文献

[1] 李勇,柳建. 基于 IA-BP 神经网络的 UWB 室内定位系统[J]. 电子测量技术, 2019, 42(5): 109-112.

LI Y, LIU J. UWB indoor localization system based on

IA-BP neural network [J]. Electronic Measurement Technology, 2019, 42(5): 109-112.

[2] 任昊誉,郭晨霞,杨瑞峰. 卡尔曼滤波提高 UWB 测距精度研究 [J]. 电子测量技术, 2021, 44 (18): 111-115.

REN H Y, GUO CH X, YANG R F. Research on improving UWB ranging accuracy by Kalman filter [J]. Electronic Measurement Technology, 2021, 44 (18): 111-115.

[3] SANG C L, STEINHAGEN B, HOMBURG J D, et al. Identification of NLOS and multi-path conditions in UWB localization using machine learning methods[J]. Applied Sciences, 2020, 10(11): 3980.

[4] WEI J, WANG H, SU S, et al. NLOS identification using parallel deep learning model and time-frequency information in UWB-based positioning system [J]. Measurement, 2022, 195: 111191.

[5] FERREIRA A G, FERNANDES D, BRANCO S, et al. Feature selection for real-time NLOS identification and mitigation for body-mounted UWB transceivers[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.

[6] 王东宇,张慧君,李孝辉,等. 遮挡环境下的基于 AKF 组合导航定位方法研究[J]. 电子测量与仪器学报, 2023,37(5):171-179.

WANG D Y, ZHANG H J, LI X H, et al. Research on positioning in covering environment with an AKF-based integrated navigation system [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (5): 171-179.

[7] LI J, GAO T, WANG X, et al. Study on the UWB location algorithm in the NLOS environment[C]. JPCS, Bristol, UK, 2022, 2400(1): 012043.

[8] CHENG L, HUANG S, XUE M, et al. A robust localization algorithm based on NLOS identification and classification filtering for wireless sensor network [J]. Sensors, 2020, 20(22): 6634.

[9] BIAN Z, CHENG L, WANG Y. A multifilter location optimization algorithm based on neural network in LOS/ NLOS mixed environment[J]. Journal of Sensors, 2021, 2021: 1-15.

[10] WU J, ZHANG Z, ZHANG S, et al. UWB positioning algorithm based on fuzzy inference and adaptive anti-NLOS Kalman filtering[J]. Applied Sciences, 2022, 12(12): 6183.

[11] 易颂轩,高伟强,刘建群,等. 基于图优化和 EKF 的

- UWB 组合定位算法 [J]. 电子测量技术, 2022, 45(23): 1-6.
- YI S X, GAO W Q, LIU J Q, et al. UWB combined location algorithm based on graph optimization and EKF [J]. Electronic Measurement Technology, 2022, 45(23): 1-6.
- [12] 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.
- [13] 王鹏, 侯忠生. UWB 与 IMU 融合的室内动态定位算法 [J]. 电子测量技术, 2023, 46(10): 76-83.
- WANG P, HOU ZH SH. Indoor dynamic positioning algorithm fused with UWB and IMU [J]. Electric Measurement Technology, 2023, 46(10): 76-83.
- [14] LONG K, NSALO KONG D F, ZHANG K, et al. A CSI-based indoor positioning system using single UWB ranging correction [J]. Sensors, 2021, 21(19): 6447.
- [15] JIANG C, CHEN Y, CHEN C, et al. Implementation and performance analysis of the PDR/GNSS integration on a smartphone [J]. GPS Solutions, 2022, 26(3): 81.
- [16] LI J, GAO T, WANG X, et al. The IMU/UWB/odometer fusion positioning algorithm based on EKF [C]. JPCS, Bristol, UK, 2022, 2369(1): 012092.
- [17] 蓝发籍, 刘冉, 郭林, 等. 融合超宽带方位和距离的移动机器人定位 [J]. 电子测量与仪器学报, 2023, 37(8): 155-163.
- LAN F J, LIU R, GUO L, et al. Mobile robot localization based on ultra-wideband bearing and ranging [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 155-163.
- [18] CHENGQI M A, WU B, POSLAD S, et al. Wi-Fi RTT ranging performance characterization and positioning system design [J]. IEEE Transactions on Mobile Computing, 2022, 21(2): 740-756.
- [19] DONG Y, ARSLAN T, YANG Y. Real-time nlos/los identification for smartphone-based indoor positioning systems using wifi rtt and rss [J]. IEEE Sensors Journal, 2021, 22(6): 5199-5209.
- [20] JIANG C, CHEN S, CHEN Y, et al. An UWB channel impulse response de-noising method for NLOS/LOS classification boosting [J]. IEEE Communications Letters, 2020, 24(11): 2513-2517.
- [21] WANG W, ZHU Q, WANG Z, et al. Research on

indoor positioning algorithm based on SAGA-BP neural network [J]. IEEE Sensors Journal, 2021, 22(4): 3736-3744.


作者简介



徐恒 (通信作者), 2009 年于安徽工业大学获得学士学位, 2013 年于合肥工业大学获得硕士学位, 2019 年于合肥工业大学获得博士学位, 现为安徽建筑大学讲师, 主要研究方向为室内定位、无线通信。

E-mail: hengxu@ahjzu.edu.cn

Xu Heng (Corresponding author) received B. Sc. degree from Anhui University of Technology in 2009, M. Sc. degree from Hefei University of Technology in 2013, and Ph. D. degree from Hefei University of Technology in 2019. He is currently a lecturer at Anhui Jianzhu University. His main research interests include indoor positioning and wireless communication.



刘虎, 2021 年于安徽建筑大学获得学士学位, 现为安徽建筑大学硕士研究生, 主要研究方向为室内定位、计算机视觉。

E-mail: liuhu7698@std.ahjzu.edu.cn

Liu Hu received B. Sc. degree from Anhui Jianzhu University in 2021. He is currently a M. Sc. candidate at Anhui Jianzhu University. His main research interests include indoor positioning and computer vision.



邵慧, 2014 年于中国科学院大学获得光学博士学位。安徽建筑大学电子与信息工程学院教授, 芬兰地理空间研究院访问学者, 主要研究领域为激光雷达、图像处理和高光谱遥感。

E-mail: ahjzshaohui@163.com

Shao Hui received the Ph. D. degree in optics from University of Chinese Academy of Sciences in 2014. She is currently a professor with the School of Electronic and Information Engineering, Anhui Jianzhu University, and a visiting scholar with Finnish Geospatial Research Institute Finland. Her main research interests include the fields of LiDAR, image processing and hyperspectral remote sensing.



孙龙, 2015 年于哈尔滨工程大学获得博士学位, 现为安徽建筑大学电子与信息工程学院讲师, 主要研究方向为雷达与电子对抗技术、毫米波雷达成像技术。

E-mail: sunlong126@126.com

Sun Long received his Ph. D. degree from Harbin Engineering University in 2015. He is a currently lecturer at the School of Electronic and Information Engineering, Anhui Jianzhu University. His main research interests include

radar and electronic countermeasures technology, as well as millimeter wave radar imaging technology.




胡玉霞, 2008 年于合肥学院获得学士学位, 2012 年于天津理工大学获得硕士学位, 2018 年于中国科学技术大学获得博士学位, 现为安徽建筑大学讲师, 主要研究方向为光电信息处理、水体微生物光谱分析方法研究。

E-mail: yxhuhf@163.com

Hu Yuxia received B. Sc. degree from Hefei University in 2008, M. Sc. degree from Tianjin University of Technology in 2012, and Ph. D. degree from the University of Science and

Technology of China in 2018. She is currently a lecturer at Anhui Jianzhu University. Her main research interests include optoelectronic information processing and research on water microbial spectral analysis methods.



孟凡宇, 2022 年于青岛城市学院获得学士学位, 现为安徽建筑大学硕士研究生, 主要研究方向为室内定位。

E-mail: dzxxmengfanyu@163.com

Meng Fanyu received B. Sc. degree from Qingdao City University in 2022. He is currently a M. Sc. candidate at Anhui Jianzhu University. His main research interest includes indoor positioning.