

doi:10.12068/j.issn.1005-3026.2024.09.003

基于误差因子的改进WLS超宽带定位算法

刘林¹, 宋雨昊^{2,1}

(1. 西南交通大学 信息编码与传输省重点实验室, 四川 成都 611756;

2. 轨道交通工程信息化国家重点实验室(中铁一院), 陕西 西安 710043)

摘要: 为提高非视距场景下超宽带(ultra-wideband, UWB)定位精度, 本文提出一种基于误差因子的改进加权最小二乘(weighted least square, WLS)算法. 该算法利用测距值和实时信道冲激响应特征训练1维卷积神经网络, 实现误差因子的准确预测; 基于预测得到的误差因子设计改进WLS算法的加权矩阵, 赋予不同基站合理的权重, 以改善非视距场景下UWB定位性能. 通过实测采集静态和动态定位数据对改进WLS算法进行性能验证. 实验结果表明: 视距场景下, 改进WLS算法与最小二乘(least square, LS)算法、WLS算法定位性能相近; 非视距场景下, 改进WLS算法明显优于LS算法、WLS算法, 能够有效抑制非视距误差.

关键词: 超宽带; 到达时间; 非视距; 1维卷积神经网络; 改进加权最小二乘算法

中图分类号: TN 92 文献标志码: A 文章编号: 1005-3026(2024)09-1235-10

Improved WLS Ultra-wideband Positioning Algorithm Based on Error Factor

LIU Lin¹, SONG Yu-hao^{2,1}

(1. Key Laboratory of Information Coding and Transmission, Southwest Jiaotong University, Chengdu 611756, China;
2. State Key Laboratory of Rail Transit Engineering Informatization (China Railway First Survey and Design Institute Group Co., Ltd.), Xi'an 710043, China. Corresponding author: SONG Yu-hao, E-mail: 544552319@qq.com)

Abstract: In order to improve the positioning accuracy of ultra-wideband (UWB) in non-line of sight (NLOS) scenarios, an improved weighted least square (WLS) algorithm based on error factor was proposed in this paper. A one dimensional convolutional neural network (1DCNN) is trained by using ranging values and real-time channel impulse response (CIR) features to achieve accurate prediction of error factor. Based on the predicted error factor, the weighting matrix of improved WLS algorithm is designed, and different base stations are given reasonable weights to improve the UWB positioning performance in NLOS scenarios. Static and dynamic measured data are collected from the real environment to verify the performance of the improved WLS algorithm. The experimental results show that the improved WLS algorithm has similar positioning performance to the least square (LS) algorithm and WLS algorithm in the line of sight (LOS) scenarios. In the NLOS scenarios, the improved WLS algorithm is obviously better than the LS algorithm and WLS algorithm, and can effectively restrain the NLOS error.

Key words: ultra-wideband; time of arrival; non-line of sight (NLOS); one dimensional convolution neural network (1DCNN); improved weighted least square (WLS) algorithm

随着时代的发展,人们对基于位置服务的需求与日俱增,获取位置信息变得极为重要.目前,室外定位问题依靠全球导航卫星系统(global navigation satellite system, GNSS)已经能够很好地解决.但对于环境多变的室内场所、复杂地下

空间、隧道等特殊应用场景,GNSS却无能为力^[1-2].对于这些特殊应用场景,人员的自由行走以及室内不同障碍物的存在,限制了各种定位技术的定位精度.相比于蓝牙^[3]、WiFi^[4]、可见光^[5]等其他定位技术,UWB定位技术在视距条件下,

收稿日期: 2023-04-28

基金项目: 轨道交通工程信息化国家重点实验室(中铁一院)开放课题(SKLKZ19-03).

作者简介: 刘林(1974-),女,四川资中人,西南交通大学副教授.

定位精度能够达到厘米级;且其功耗低、抗多径干扰和穿透能力强、时间分辨率高^[6],因而在室内定位中得到了广泛应用.

然而,在 NLOS 场景下,UWB 定位精度急剧下降.目前处理 NLOS 影响的主流策略包括多传感器融合^[7]、NLOS 识别^[8-9]以及 NLOS 抑制^[10].多传感器融合利用 UWB 与其他传感器之间的互补性质,通过复杂的融合算法可有效抑制 NLOS 误差,但多传感器融合方式会导致设备成本增加.NLOS 识别技术基于基站和标签间的信道传播特性差异,判断 UWB 设备工作于 LOS 还是 NLOS 场景,依据识别结果对相应的测距值进行处理,以提高定位精度.如何准确识别 NLOS 及识别后的相应处理算法有待深入研究.至于 NLOS 抑制,一般是直接估计出测距误差后将误差从测距值中消除^[11].

在进行 NLOS 识别和抑制时,一般需要获取 CIR(channel impulse response)特征.若采用原始的 CIR 信息^[12],数据量随着基站数量的增加急剧增加;若采用从原始 CIR 信息中统计得到的信息,例如 RMS(root mean square)延迟扩展等可能会增加 4~5 s 的定位延迟,并且需要占用大量的内存资源^[13].近年来,研究者开始探索利用 UWB 诊断寄存器中提取的实时 CIR 特征^[14-16]进行 NLOS 识别和抑制,实践证明,该特征能够识别 NLOS,但相关文献并没有对如何利用这些特征提高 NLOS 条件下的 UWB 定位精度进行研究.

本文从定位成本、定位实时性以及 NLOS 场景下 UWB 定位精度等角度出发,引入深度学习算法,运用 1 维卷积神经网络(1DCNN)模型强大的数据处理能力,对测距值及 UWB 诊断寄存器中提取的实时 CIR 特征进行学习,预测得到误差因子.并依据所得到的误差因子设计改进 WLS 算法的加权矩阵,实现对各个基站测距值进行加权修正,从而提高 NLOS 场景下 UWB 定位精度.

1 UWB 定位方案

本文设计的 UWB 定位方案如图 1 所示.该方案主要包括三个部分:第一部分为数据采集及预处理,该部分完成测距值的获取以及 UWB 诊断寄存器中实时 CIR 特征的提取;第二部分搭建 1 维卷积神经网络模型实现误差因子的准确预测;第三部分则是利用预测得到的误差因子设计

改进 WLS 算法的加权矩阵,对测距值赋予合理的权重并输出定位结果.




图 1 UWB 定位方案

Fig. 1 UWB positioning scheme

1.1 数据采集及预处理

本文采集实时 CIR 特征和测距值的设备为 2 个 DW1000 802.15.4a UWB 传感器模块以及 1 台便携式计算机,其中 UWB 传感器模块设置为通道 2(中心频率为 3 993.6 MHz,带宽为 499.2 MHz),脉冲重复频率 64 MHz,数据速率 6.8 Mb/s. UWB 基站和标签之间的测距值由双边双向测距算法(AltDS-TWR)计算而来^[17],其测距原理如图 2 所示.

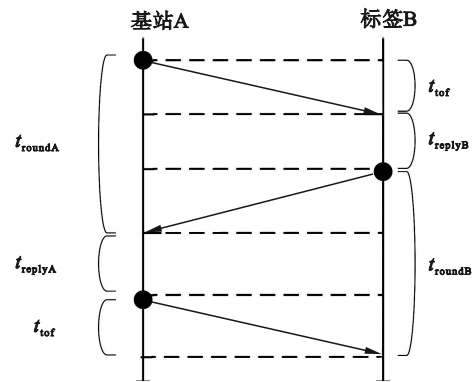


图 2 AltDS-TWR 测距原理图

Fig. 2 Schematic diagram of AltDS-TWR ranging

由图 2 可知,往返时间 t_{roundA} 和 t_{roundB} 为

$$\left. \begin{aligned} t_{\text{roundA}} &= 2 \times t_{\text{tof}} + t_{\text{replyB}} \\ t_{\text{roundB}} &= 2 \times t_{\text{tof}} + t_{\text{replyA}} \end{aligned} \right\} \quad (1)$$

式中: t_{tof} 为 UWB 信号在基站和标签间的无线传输时间; t_{replyA} 为基站在响应接收到的标签信息前的处理时间; t_{replyB} 为标签在响应接收到的基站信息前的处理时间.

将式(1)中的 2 个式子相乘,可得

$$t_{\text{roundA}} \times t_{\text{roundB}} = (2t_{\text{tof}} + t_{\text{replyB}}) \times (2t_{\text{tof}} + t_{\text{replyA}}). \quad (2)$$

化简整理可得 t_{tof} 如式(3)所示:

$$t_{\text{tof}} = \frac{t_{\text{roundA}} \times t_{\text{roundB}} - t_{\text{replyA}} \times t_{\text{replyB}}}{t_{\text{roundA}} + t_{\text{roundB}} + t_{\text{replyA}} + t_{\text{replyB}}}. \quad (3)$$

传输时间 t_{tof} 乘以光速即可得到两者之间的传输距离,如式(4)所示,其中光速 c 大小为 2.9979×10^8 m/s. 根据式(4)可知,UWB 传感器

1ns 的传输时间误差将会导致测距误差增加约 30 cm.

$$d_r = c \times t_{\text{tof}} \quad (4)$$

式中, d_r 表示基站和标签间的距离.

进行距离测量的同时,还可以从设备中获取如表 1 所示的有关 CIR 特征信息,这些实时 CIR 特征均可以反映出基站和标签之间接收信号的质量,有助于误差因子的预测.前 8 个 CIR 特征信息是从 DW1000 UWB 传感器的内置通道诊断寄存器中提取的,后面 3 个 CIR 特征信息是通过组合前 8 个 CIR 特征信息得到的.其中,第一路径信号功率 P_{FPL} 计算如式(5)所示:

$$P_{\text{FPL}} = 10 \times \lg \left(\frac{F_1^2 + F_2^2 + F_3^2}{N_p^2} \right) - A. \quad (5)$$

其中: N_p 为接收到的前导码累积计数长度; A 为常量,大小等于 121.74 dBm.

接收信号功率 P_{RPL} 计算如式(6)所示.

$$P_{\text{RPL}} = 10 \times \lg \left(\frac{C_1 \times 2^{17}}{N_p^2} \right) - A. \quad (6)$$

其中, C_1 是 UWB 诊断寄存器中报告的 CIR 功率值.

第一路径信号功率和接收信号功率之间的比值计(R_p)算如式(7)所示:

$$R_p = P_{\text{FPL}}/P_{\text{RPL}}. \quad (7)$$

表 1 采集的实时特征

Table 1 Real-time features of acquisition

名称	说明
d_r	测距值
F_1	第一路径(point 1)的幅值
F_2	第一路径(point 2)的幅值
F_3	第一路径(point 3)的幅值
N_p	前导码累积计数长度
N_{MaxNoise}	DW1000 寄存器中报告的最大噪声
σ_{StdNoise}	DW1000 寄存器中报告的标准噪声
C_1	DW1000 寄存器中报告的 CIR 功率值
$I_{\text{FirstPath}}$	第一路径索引值
P_{FPL}	第一路径信号功率
P_{RPL}	接收信号功率
R_p	第一路径信号功率和接收信号功率之间的比值

根据文献[18], CIR 的幅值与前导码累积计数长度有关.如果前导码累积计数长度加倍,则 CIR 的幅度加倍, CIR 功率值与前导码累积计数长度 N_p 的平方成正比.因此,为了消除前导码累积计数长度带来的影响,从诊断寄存器中提取到的原始 F_1, F_2, F_3 的幅值均需除以前导码累积计数

长度 N_p ; DW1000 芯片寄存器中报告的 CIR 功率值需除以前导码累积计数长度 N_p 的平方.前导码累积计数长度以及第一路径索引值在 LOS 和 NLOS 数据集上并没有显著区别,经人工筛选后剔除该特征.

在数据采集过程中,上述基站和标签间测距值及其对应的 CIR 实时特征信息均会被记录在便携式计算机中,以供后续实验使用. LOS 和 NLOS 数据集样本数量均为 19 600 个,共计 39 200 个.其中,训练集和验证集占总数据集的 80%,测试集占 20%.对数据集输入特征进行归一化处理有助于提升深度学习算法模型训练的稳定性及收敛速度.同时,也可以避免某些特征值过大或过小的情况对模型产生负面影响,归一化处理方式如式(8)所示.数据集输出信息为误差因子,采用测距误差来构建该误差因子,构建方式如式(9)所示.

$$\hat{X}_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}, \quad (8)$$

$$\hat{Y}_i = \frac{|Y_{\text{测距误差}}|_i}{\left(\sum_j^N |Y_{\text{测距误差}}|_j \right) / N}. \quad (9)$$

式中: X_i 为输入数据中第 i 个数据; X_{\min} 为输入数据中的最小值; X_{\max} 为输入数据中的最大值; \hat{X}_i 为 X_i 归一化结果; $|Y_{\text{测距误差}}|_i$ 为第 i 个测距误差; \hat{Y}_i 为对应输出误差因子.

根据式(9)可知,当基站和标签之间处于 LOS 场景时,测距误差较小,据此计算得到的误差因子取值较小;当基站和标签之间处于 NLOS 场景时,测距误差较大,故而误差因子取值较大.

1.2 基于 1DCNN 模型预测误差因子

本文引入 1DCNN 模型预测误差因子.1DCNN 具有出色的数据学习能力,是一种具有卷积计算且含有深层网络架构的前馈神经网络.其模型结构如图 3 所示.




图 3 1 维卷积神经网络模型结构图

Fig. 3 Structure diagram of 1DCNN model

该模型结构中,输入层的输入信息为表 1 中提取到的特征信息,输出层的输出信息为误差因

子,其定义如式(9)所示.为了补偿1DCNN模型过拟合问题,在网络模型结构中添加了批归一化层(batch normalization, BN)和Dropout层,并且在模型训练过程中引入了早停法.为了评估1DCNN算法模型性能,本文将从学习率、优化器、丢弃率等方面对该模型进行综合分析.

图4对比了不同学习率(L_i)下模型的损失值.从图4中可以看出,学习率较大时,模型无法训练,无法得到稳定可靠模型;学习率非常低时,虽然模型损失值较低,但在训练步数达到100时也没有趋于稳定,而是略有波动.图中圆点曲线对应学习率衰减模式,当起始学习率为0.001时,该模式下模型能够快速收敛,并逐渐趋于稳定.因此,本文设计的1DCNN模型采用学习率衰减模式,而不是固定学习率.

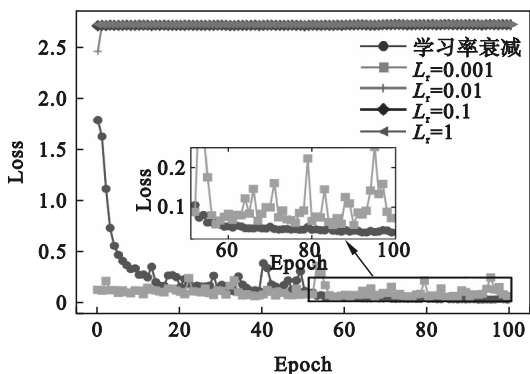


图4 不同学习率的模型性能

Fig. 4 Model performance of different learning rates

除了学习率的选择,优化器的选择对模型的训练也至关重要.图5对比分析了常见的Adam优化器、Nadam优化器和RMSprop优化器的性能.




图5 不同优化器的模型性能

Fig. 5 Model performance of different optimizers

从图5中可以看出,Nadam优化器与Adam优化器均提供了较低的损失值.同时,Nadam优化器收敛速度较快.因此从优化器原理和收敛速

度出发,选择Nadam优化器作为该1DCNN模型的优化器.

图6显示了Dropout层的不同丢弃率对1DCNN模型性能的影响.




图6 不同丢弃率的模型性能

Fig. 6 Model performance of different dropout rates

从图6中可以看出,丢弃率会影响回归效果,过大或过小都会导致模型损失值升高.当丢弃率取0.5时,曲线收敛速度较其余曲线快且更稳定,因此,本文丢弃率取0.5.

经过上述实验,最终确定的1DCNN模型超参数及取值如表2所示.

表2 1DCNN模型超参数
Table 2 Hyperparameter of 1DCNN model

1DCNN超参数名称	取值/类型
学习率	初始值 $L_i=0.001$,自适应衰减
优化器	Nadam
激活函数	ReLU
丢弃率	0.5
批量训练数据大小	64
损失函数	均方误差函数

按表2参数设计的一维卷积神经网络模型在训练集和验证集上的训练情况如图7和图8所示.图7为训练集和验证集的均方误差(mean square error, MSE)曲线,图8为训练集和验证集的平均绝对误差(mean absolute error, MAE)曲线.根据曲线趋势来看,随着训练步数的增加,误差逐渐减小,并趋于稳定.训练结束后在测试集上检验该模型,测试集均方误差为0.05,平均绝对误差为0.08,误差较小,因此模型有效.

图9为测试得到的误差因子频率分布直方图,从图9可以很明显地看到,LOS场景下的误差因子相比于NLOS场景下的误差因子取值相对较小,实验结果与理论相符合,且LOS场景下的误差因子约90%的概率小于0.6.

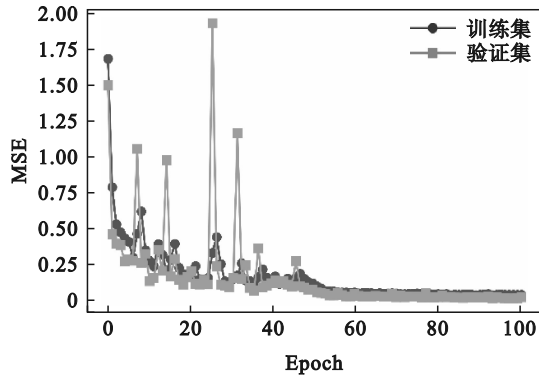


图 7 训练集和验证集 MSE 对比情况

Fig. 7 Comparison of MSE between training set and validation set




图 8 训练集和验证集 MAE 对比情况

Fig. 8 Comparison of MAE between training set and validation set

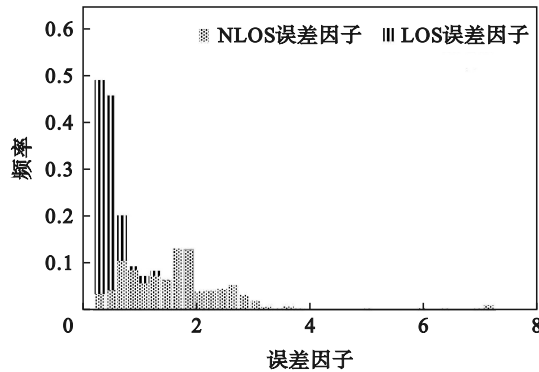


图 9 误差因子频率分布直方图

Fig. 9 Error factor frequency distribution histogram

2 基于误差因子的改进 WLS 定位算法

WLS 算法、Chan 算法、Taylor 迭代算法等传统定位算法是 UWB 室内定位中常见且使用广泛的算法。在 LOS 场景中几种算法均能够实现良好的定位效果,定位精度可以达到厘米级。然而在 NLOS 场景中,几种算法定位性能下降,不能够达

到厘米级定位精度。这主要是由于 NLOS 误差的存在限制了传统定位算法的定位性能。

WLS 算法实现简单且对 NLOS 有一定的处理能力,但在 NLOS 场景下定位精度需要进一步提高。因此,本文选择 WLS 算法进行研究,利用 1.2 节 1DCNN 模型预测得到的误差因子来构建 WLS 算法的加权矩阵,实现对不同基站和标签之间的测距值进行加权修正,从而提高 WLS 算法的定位精度。

2.1 WLS 算法基本原理

假设 N 个基站的位置坐标分别为 $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$; 标签的位置坐标为 (x, y) ; 基站到标签间的测距值分别为 d_1, d_2, \dots, d_N ; 根据测距信息可以建立如下方程组,如式(10)所示:

$$\left. \begin{aligned} (x_1 - x)^2 + (y_1 - y)^2 &= d_1^2, \\ (x_2 - x)^2 + (y_2 - y)^2 &= d_2^2, \\ &\vdots \\ (x_N - x)^2 + (y_N - y)^2 &= d_N^2. \end{aligned} \right\} \quad (10)$$

该二元二次方程组中的方程式通过移项处理,可以得到式(11)所示方程组:

$$\left. \begin{aligned} -2x_1x - 2y_1y + r &= d_1^2 - r_1, \\ -2x_2x - 2y_2y + r &= d_2^2 - r_2, \\ &\vdots \\ -2x_Nx - 2y_Ny + r &= d_N^2 - r_N. \end{aligned} \right\} \quad (11)$$

其中: $r_i = x_i^2 + y_i^2; r = x^2 + y^2$ 。

该方程组可以转化为矩阵形式,如式(12)所示:

$$A\theta = b. \quad (12)$$

其中,矩阵 A 和 b 如式(13)所示:

$$A = \begin{bmatrix} -2x_1 & -2y_1 & 1 \\ -2x_2 & -2y_2 & 1 \\ \vdots & \vdots & \vdots \\ -2x_N & -2y_N & 1 \end{bmatrix}; \quad b = \begin{bmatrix} d_1^2 - r_1 \\ d_2^2 - r_2 \\ \vdots \\ d_N^2 - r_N \end{bmatrix}. \quad (13)$$

矩阵 θ 如式(14)所示:

$$\theta = \begin{bmatrix} x \\ y \\ r \end{bmatrix}. \quad (14)$$

在基站位置坐标信息和基站与标签间测距信息已知的条件下,运用式(15)就可以得到标签的位置坐标。

$$\theta = (A^T A)^{-1} A^T b. \quad (15)$$

在实际环境中,基站与标签之间的测距值总是存在误差,其中,影响最大的是 NLOS 误差。为了解决 NLOS 误差带来的问题,可以采用加权最小二乘算法。采用加权最小二乘算法时式(12)可

以变换成式(16):

$$WA\theta = Wb. \quad (16)$$

标签的位置坐标可通过式(17)获得,

$$\theta = (A^TWA)^{-1}A^TWb. \quad (17)$$

其中, W 为 $[]_{N \times N}$ 对角矩阵,如式(18)所示,其构建一般依赖于先验信息-噪声方差;或者测距结果-测距值越小,赋予的权值相对越大,如式(19)所示:

$$W = \begin{bmatrix} W_{11} & \cdots & 0 \\ \vdots & & \vdots \\ 0 & \cdots & W_{NN} \end{bmatrix}, \quad (18)$$

$$W_{ii} = \frac{1}{\sigma_i^2} \text{ 或 } W_{ii} = 1 - \frac{d_i}{\sum_{j=1}^N d_j}. \quad (19)$$

在现实情况下,由于标签位置的未知性及不确定性,采用先验信息构建的加权矩阵会导致权重比例失衡,无法计算出标签的精确位置^[19-20].文献[19]中通过实验证明了利用测距信息进行加权能够取得较方差加权更高的定位精度.因此,本文后面对比实验中提到的WLS算法为采用测距信息构建的加权矩阵.

2.2 改进WLS算法基本原理

现有的WLS算法加权矩阵若采用噪声方差进行构造,则会由于先验统计的噪声方差的局限性而不能随时适应定位场景的变化;若依赖于测距值的大小进行构造,则在非视距场景下无法很好地反映各基站信号质量.因此,本文提出利用1.2节的1DCNN模型预测得到各基站误差因子,依据误差因子设计新的加权矩阵,实现改进的WLS算法.

假定 N 个基站与标签间的误差因子分别为 $\eta_1, \eta_2, \eta_3, \dots, \eta_N$,则加权矩阵 W 的构建方式如式(20)所示:

$$W_{ii} = 1 - \frac{\eta_i^2}{\sum_{j=1}^N \eta_j^2}. \quad (20)$$

该方式可以实现在基站和标签之间存在障碍物时赋予较小的权重,基站和标签之间无障碍物时赋予较大的权重,从而提高定位精度.

3 实验结果与分析

本文在实验场地采集静态和动态数据,验证基于误差因子的改进WLS算法的定位性能.

3.1 实验环境

本文采用4个基站与1个标签进行实测数据采集,4个基站放置在定位场地的4个顶角处.

在采集静态定位数据时,每个定位采集点采集1 000组定位数据.

实测场地:九号教学楼一楼开阔平地.基站坐标信息如下:基站A(0,0)、基站B(600 cm,0)、基站C(600 cm,600 cm)、基站D(0,600 cm).在该场地设置3个静态定位采集点,坐标分别为(180 cm,60 cm),(240 cm,180 cm),(300 cm,300 cm).

3.2 LOS静态定位性能分析

实验1 LOS场景静态定位

在该场景下,LS、WLS和改进WLS算法定位误差情况如表3所示.从定位误差均值、标准差以及均方根误差(root mean square error, RMSE)大小来看,LOS静态定位时,3种算法性能接近,定位误差小于3 cm,定位精度达到厘米级.

表3 实验1的定位误差
Table 3 Positioning errors of experiment 1 cm

算法	误差		
	均值	标准差	RMSE
LS	2.66	0.98	2.83
WLS	2.66	0.98	2.83
改进WLS	2.64	0.97	2.83

LOS静态定位时,不同基站和标签之间的测距误差均较小,采用LS算法和WLS算法即可取得较高的定位精度.对于改进WLS算法,LOS场景下基站和标签间测距误差小,不同基站误差因子取值较小且接近,故而改进WLS算法定位性能接近其余2种算法.

3.3 NLOS静态定位性能分析

采集NLOS静态定位数据时,采用2种方式构建NLOS场景:第1种是在定位区域内有行人行走从而形成NLOS场景(标记为A);第2种是利用人体长时间遮挡部分基站(标记为B).实验2的NLOS场景对应于第1种;实验3的NLOS场景对应于第2种.

实验2 NLOS场景静态定位(A)

在该场景下,LS、WLS和改进WLS 3种算法的定位误差如表4所示.由表4可知,改进WLS算法误差均值接近其余2种定位算法误差均值的1/2,精度提高约1倍;而且,改进WLS算法误差标准差和均方根误差均小于其余2种定位算法,定位结果相对更稳定.因此,改进WLS算法定位性能优于传统定位算法.

实验2的3种定位算法的定位误差累积分布函数(cumulative distribution function, CDF)曲线如图10所示.当累积概率为60%,75%和90%时,

对应的定位误差如表 5 所示.结合图 10 和表 5 中的数据来看,累积概率达到 90% 时,改进 WLS 算法误差值约为其余 2 种定位算法误差的 1/4,定位性能大大改善.

表 4 实验 2 的定位误差

算法	误差		
	均值	标准差	RMSE
LS	22.73	45.95	51.26
WLS	21.47	42.04	47.20
改进 WLS	11.84	25.51	28.12




图 10 实验 2 的 CDF 曲线

Fig. 10 CDF curves of experiment 2

表 5 实验 2 的 CDF 分析表

算法	定位误差		
	60%	75%	90%
LS	9.16	12.39	73.99
WLS	8.91	12.24	69.73
改进 WLS	7.88	9.67	16.41

实验 3 NLOS 场景静态定位(B)

在该场景下,3 种算法的定位误差如表 6 所示.从表 6 的结果可知,改进 WLS 算法误差均值接近其余 2 种定位算法误差均值的 1/2,精度提高约 1 倍.此外,改进 WLS 算法定位误差标准差和均方根误差均小于其余 2 种定位算法,说明改进 WLS 算法对 NLOS 误差具有一定抑制效果,能够提高 NLOS 场景下的定位精度.但是,该场景下改进 WLS 算法的标准差和均方根误差分别为 52.96 cm 和 64.47 cm,仍然较大,有待进一步改进.

实验 3 不同定位算法的定位误差累积分布函数如图 11 所示.从图 11 中可以发现,LS 算法和 WLS 算法对应曲线波动明显且在某些情况下出现误差上升趋势较快的问题.产生这种现象的原因是在 NLOS 场景构建过程中,人体近距离遮挡

基站会导致基站和标签间产生极大的 NLOS 误差^[14],此时可能出现 1 个或多个基站被长时间近距离遮挡,导致基站和标签间测距值急剧增大,进而造成定位误差的急剧增加.同时,LS 算法和 WLS 算法在此种场景下定位结果变差,无法很好地处理由于人体近距离且长时间遮挡造成的 NLOS 误差,故可见 LS 算法和 WLS 算法对应的误差曲线波动明显.

表 6 实验 3 的定位误差

算法	误差		
	均值	标准差	RMSE
LS	72.72	78.34	106.88
WLS	69.69	72.53	100.58
改进 WLS	36.78	52.96	64.47




图 11 实验 3 的 CDF 曲线

Fig. 11 CDF curves of experiment 3

实验 3 的 CDF 累积概率为 60%,75% 和 90% 时对应的定位误差如表 7 所示.

表 7 实验 3 的 CDF 分析表

算法	定位误差		
	60%	75%	90%
LS	110.16	121.85	189.80
WLS	111.57	122.01	165.56
改进 WLS	16.37	54.35	104.65

结合图 11 和表 7 的数据可知,累积概率达到 90% 时,相较其余 2 种算法,改进 WLS 算法定位精度提高约 60~80 cm.当累积概率为 60% 时,改进 WLS 算法能够达到 16.37 cm,相比其余 2 种定位算法精度提高约 100 cm.

为了准确描述改进 WLS 算法性能优越的原因,本文随机选择实验中的某一次定位时 2 种算

法的加权矩阵进行分析,如表 8 所示.对于此次定位,4 个基站和标签间的真实距离分别为 300, 402.49, 553.17, 483.74 cm;而测试距离分别为 535.7, 398.3, 555.9, 483.7 cm.根据测试距离以及真实距离之差可知,基站 A 的测距误差是最大的,其余基站的测距误差很小;理论上基站 A 对应的权重宜偏小,其余基站对应的权重宜偏大且接近.

表 8 实验 3 的加权矩阵设置

Table 8 Weighting matrix setting of experiment 3

定位算法	W_{11}	W_{22}	W_{33}	W_{44}
WLS	0.729	0.723	0.466	0.004
改进 WLS	0.515	0.835	0.874	0.852

由表 8 可知,WLS 算法中基站 A 对应的权值 W_{11} 为 0.729,相比于其余基站对应的权值,基站 A 的权值反而偏大,因此基于测距信息的 WLS 算法权值设置不合理,导致定位结果变差.对于基于

误差因子的改进 WLS 算法,基站 A 对应的权值 W_{11} 为 0.515,其余基站对应的权值均比基站 A 对应的权值大,且数值大小接近.因此,基于误差因子的改进 WLS 算法在定位性能方面优于 WLS 算法.同时亦说明,基于误差因子的改进 WLS 算法优于其余 2 种算法的重要原因在于加权矩阵设置合理,改进 WLS 算法的加权矩阵准确反映了测距质量.

综合对比实验 2 和实验 3 可知,相比于其他 2 种定位算法,改进 WLS 算法的定位精度明显更高,说明改进 WLS 算法能够有效抑制 NLOS 误差,提升 NLOS 场景下的 UWB 定位精度.但在强 NLOS 场景下,改进 WLS 算法的标准差和均方根误差仍然较大,有待进一步改进.

3.4 LOS 动态定位性能分析

实测场地 LOS 场景下的动态定位结果如图 12 所示.由图 12 可知,LOS 场景下,3 种算法的实时定位轨迹均贴合真实轨迹.




图 12 LOS 动态定位轨迹
Fig. 12 LOS dynamic positioning trajectory

3.5 NLOS 动态定位性能分析

实测场地 NLOS 场景下的动态定位结果如图 13 所示.由图 13 可以发现,在 NLOS 场景下,LS 算法和 WLS 算法定位能力下降,大量标签定

位结果严重偏离真实轨迹;而改进 WLS 算法有效抑制了 NLOS 误差,相比于 LS 算法和 WLS 算法,其散落在轨迹外的点较少,能更好地贴合真实轨迹.

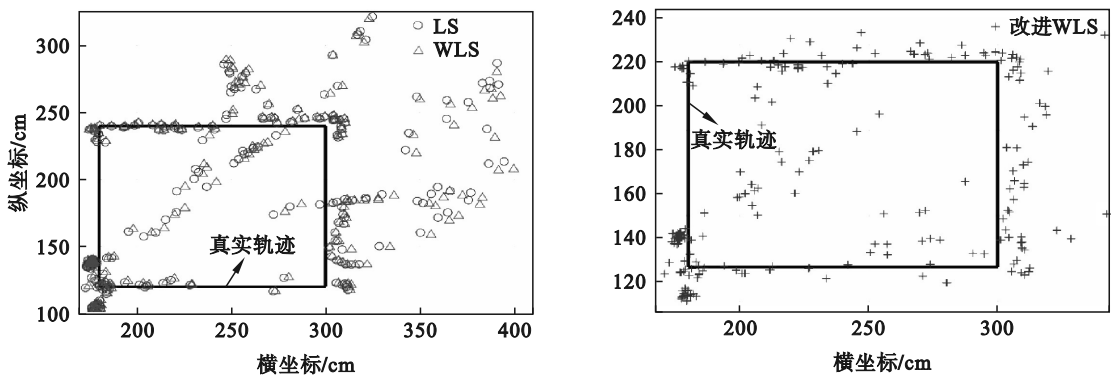


图 13 NLOS 动态定位轨迹
Fig. 13 NLOS dynamic positioning trajectory

NLOS动态定位时,LS算法、WLS算法和改进WLS算法的定位误差均值分别为53.82, 48.71, 30.84 cm.相较于LS算法、WLS算法,改进WLS算法在定位精度上分别提升了42.70%, 36.68%.同时,3种算法的定位误差标准差分别为59.99, 54.56, 44.91 cm,由此可知改进WLS算法定位误差标准差小于LS算法以及WLS算法的定位误差标准差,呈现相对稳定的变化趋势.因此,改进WLS算法可以有效抑制NLOS误差,定位性能优于LS算法和WLS算法.

3.6 算法复杂度分析

为了区分LS算法、WLS算法、改进WLS算法之间的复杂度,本文记录了不同定位算法完成同一定位实验时所消耗的时间.消耗的时间越长,说明该算法的复杂度越高^[20].

实验过程中记录了3.3节实验2中各种定位算法定位1000次的运行时间,如表9所示.

表9 不同算法的消耗时间

Table 9 Time consumption of different algorithms

算法	时间
LS	4.120
WLS	4.129
改进WLS	4.532

由表9可知,基于误差因子的改进WLS算法消耗时间比LS算法和WLS算法消耗的时间稍长.其原因是运用该算法定位时,需要采用1DCNN模型预测各基站对应的误差因子,预测误差因子需要进行451580次FLOPS(每秒浮点运算次数),增加了算法复杂度,故而消耗的时间最长.然而改进WLS算法消耗时间依然能够满足室内定位实时性的要求.

综上,相较于LS算法以及WLS算法,改进WLS算法虽复杂度稍高,但能够显著提升NLOS场景下UWB定位精度.

4 结 语

为提高NLOS场景下UWB的定位精度,本文提出一种基于误差因子的改进WLS定位算法.该算法利用测距值和UWB诊断寄存器中提取的实时CIR特征完成1DCNN算法模型训练,实现了误差因子的准确预测.基于误差因子的改进WLS算法在LOS场景下,性能与LS算法、WLS算法定位性能相近.在NLOS场景下,定位性能优于LS算法、WLS算法,能够有效抑制NLOS误

差.此外,在某些强NLOS场景下,改进WLS算法的误差标准差和均方根误差仍然较大,有待进一步改进.

参考文献:

- [1] Batistić L, Tomic M. Overview of indoor positioning system technologies [C]//2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics. Opatija, 2018:473-478.
- [2] 宋雨昊,刘林,王平.WKNN在UWB定位中的应用研究[J].现代计算机,2021,27(35):34-40,69. (Song Yu-hao, Liu Lin, Wang Ping. Research on the application of WKNN in UWB positioning [J]. *Modern Computer*, 2021, 27(35):34-40, 69.)
- [3] Hu S C, He K, Yang X, et al. Bluetooth fingerprint based indoor localization using Bi-LSTM [C]//2022 31st Wireless and Optical Communications Conference (WOCC). Shenzhen, 2022:161-165.
- [4] Tan S, Ren Y L, Yang J, et al. Commodity WiFi sensing in ten years: status, challenges, and opportunities [J]. *IEEE Internet of Things Journal*, 2022, 9(18):17832-17843.
- [5] Zhang S, Liu K H, Zhang Y L, et al. A coarse fingerprint-assisted multiple target indoor device-free localization with visible light sensing [J]. *IEEE Sensors Journal*, 2022, 22(2):1461-1473.
- [6] Elsanhoury M, Mäkelä P, Koljonen J, et al. Precision positioning for smart logistics using ultra-wideband technology-based indoor navigation: a review [J]. *IEEE Access*, 2022, 10:44413-44445.
- [7] Kim D H, Pyun J Y. NLOS identification based UWB and PDR hybrid positioning system [J]. *IEEE Access*, 2021, 9:102917-102929.
- [8] Dong M Y. A low-cost NLOS identification and mitigation method for UWB ranging in static and dynamic environments [J]. *IEEE Communications Letters*, 2021, 25(7):2420-2424.
- [9] Chen C X, Huang Z, Wang J Y, et al. Channel - quality - evaluation - based anchor node selection for UWB indoor positioning [J]. *Electronics*, 2022, 11(3):436-450.
- [10] Wang T Y, Hu K K, Li Z H, et al. A semi-supervised learning approach for UWB ranging error mitigation [J]. *IEEE Wireless Communications Letters*, 2021, 10(3):688-691.
- [11] Bregar K, Mohorčič M. Improving indoor localization using convolutional neural networks on computationally restricted devices [J]. *IEEE Access*, 2018, 6:17429-17441.
- [12] Angarano S, Mazzia V, Salvetti F, et al. Robust ultra-wideband range error mitigation with deep learning at the edge [J]. *Engineering Applications of Artificial Intelligence*, 2021, 102:104278-104286.
- [13] Yu K G, Wen K, Li Y B, et al. A novel NLOS mitigation algorithm for UWB localization in harsh indoor environments [J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(1):686-699.
- [14] 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, 70:5502310.
- [15] 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):3980-4004.

(下转第1316页)