

DOI:10.3979/j.issn.1673-825X.202501180025

## 基于测距修正的 BLE 和 PDR 融合定位方法研究

刘 辉,何航川

(重庆邮电大学 通信与信息工程学院,重庆 400065)

**摘要:**为解决室内非视距(non line of sight, NLOS)环境以及低信标部署密度下传统定位算法精度急剧下降的问题,提出一种基于测距修正的低功耗蓝牙(blueetooth low energy, BLE)和行人航位推算(pedestrian dead reckoning, PDR)融合定位方法。通过 SketchUp 室内 3D 建模软件联合射线追踪算法实现 BLE 的接收信号强度(received signal strength, RSS)快速构建,避免人工繁琐的 RSS 实地采集。设计一种基于卷积神经网络的变分自编码器(variational autoencoder based on convolution neural network, VAE-CNN)模型对 BLE 测距误差进行预测和修正,提升 BLE 定位精度。采用扩展卡尔曼滤波(extended Kalman filter, EKF)融合 BLE 和 PDR 的定位结果。实验结果表明,采用测距修正后的 BLE 测距定位以及 EKF 融合定位在 NLOS 以及信标部署密度低的环境下具有较好的定位性能。

**关键词:**低功耗蓝牙;行人航位推算;射线追踪;变分自编码器;扩展卡尔曼滤波

中图分类号:TN98;TP391.9

文献标志码:A

文章编号:1673-825X(2025)05-0627-11

## Research on BLE and PDR fusion localization method based on ranging correction

LIU Hui, HE Hangchuan

(School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, P. R. China)

**Abstract:** To address the significant decline in positioning accuracy of traditional algorithms under indoor non line of sight (NLOS) conditions and low beacon deployment density, this paper proposes a fused positioning method based on ranging correction, combining bluetooth low energy (BLE) and pedestrian dead reckoning (PDR). Firstly, the received signal strength (RSS) of BLE is rapidly constructed using SketchUp indoor 3D modeling software integrated with a ray-tracing algorithm, eliminating the need for tedious manual RSS field collection. Subsequently, a variational autoencoder based on convolutional neural network (VAE-CNN) is designed to predict and correct BLE ranging errors, thereby improving BLE positioning accuracy. Finally, an extended Kalman filter (EKF) is employed to fuse the positioning results from BLE and PDR. Experimental results demonstrate that the proposed ranging-corrected BLE positioning and EKF-based fusion positioning achieve superior performance in environments with NLOS interference and low beacon deployment density.

**Keywords:** bluetooth low energy; pedestrian dead reckoning; ray tracing; variational autoencoder; extended Kalman filter

## 0 引言

近年来,商场大楼、图书馆、博物馆等对室内定位系统的需求越来越大。同时,智能手机集成了许多传感器,其功能越来越完善,利用智能手机进行室内定位成为一种趋势。目前的定位技术主要有全球导航卫星系统(global navigation satellite system, GNSS)<sup>[1]</sup>、超宽带(ultra wideband, UWB)<sup>[2]</sup>、无线保真(wireless fidelity, WiFi)<sup>[3]</sup>、低功耗蓝牙(bluetooth low energy, BLE)<sup>[4]</sup>、惯性测量单元(inertial measurement unit, IMU)<sup>[5]</sup>等。

然而,受建筑结构或天气因素的影响,GNSS 通常难以在室内接收到有效的定位信号,无法实现准确的室内定位<sup>[6]</sup>。UWB 在视距环境下具有很高的定位精度,而在非视距环境下,由于障碍物的阻挡和信号的反射使得定位精度较低。此外,UWB 定位必须使用昂贵的专用设备<sup>[7]</sup>。Wi-Fi 指纹定位通常基于接收信号强度(receive signal strength, RSS)来实现,定位精度高,但对接入点(access point, AP)的部署密度要求高。文献[8]在 75 m×25 m 的实验场景中部署了 100 多个 AP,而文献[9]在 5.5 m×9.5 m 的实验场景中部署了 7 个 AP,并且前期需要建立 Wi-Fi 指纹数据库,需要大量的资源和高昂的成本<sup>[10]</sup>。此外,安卓(Android)系统限制了智能手机扫描 Wi-Fi 的频率,导致 Wi-Fi 定位的刷新频率不高。BLE 易于使用且不需要专用设备,这使得基于 BLE 的定位方法得到了广泛应用,但 BLE 的定位精度高度依赖于部署密度,从而增加了成本。常用的基于智能手机 IMU 的定位方法是行人航位推算(pedestrian dead reckoning, PDR)<sup>[11]</sup>。然而,智能手机中的 IMU 因成本限制存在精度缺陷,导致 PDR 定位误差随时间累积显著增加。

PDR 算法不依赖于任何外部信息,仅依靠 IMU 信息即可实现自主定位导航,在短时间内具有良好的定位精度。而 BLE 可以很容易地扩展场景,并且 BLE 测距观测值具有较好的物理意义,为此相关研究人员尝试将这 2 种技术进行融合,发挥各自的技术优势,提升室内定位精度。基于 BLE 的 RSS 定位方法包括三角法、最小二乘(least squares, LS)法、指纹法和最大似然估计法,这些算法的定位精度与所处环境以及 BLE 的部署密度密切相关。一方面,室内(non line of sight, NLOS)环境会导致这些算法定位精度恶化;另一方面,当 BLE 信标的部署密度高

时,定位精度高,但成本也会增加;当 BLE 信标的部署密度降低时,这些算法可能无法有效工作,定位精度将大大降低<sup>[12]</sup>。在以往的研究中,已经提出了多种基于扩展卡尔曼滤波(extended Kalman filter, EKF)的 PDR 和无线信号测距融合算法<sup>[13-14]</sup>。这些算法主要将测距值作为观测量,与 PDR 进行松耦合,未能充分考虑测距值的误差大小,使其在 NLOS 和 BLE 信标部署密度较低的场景中定位精度低、鲁棒性差。

为解决上述问题,本文提出了一种基于测距误差修正的 BLE 和 PDR 融合定位方法。该方法的核心在于利用深度学习模型对 BLE 测距误差进行预测和修正,以提升融合定位性能。首先,在离线阶段通过 SketchUp 室内 3D 建模联合射线追踪方法实现 RSS 相关特征数据集的快速构建。然后,设计一种基于卷积神经网络的变分自编码器(variational autoencoder based on convolution neural network, VAE-CNN)模型对 BLE 测距误差进行预测和修正,提升 BLE 定位精度。最后,采用 EKF 算法融合 BLE 和 PDR 的定位结果。与现有 EKF 融合定位算法不同,本文方法充分考虑了测距误差的大小,并对此进行修正,极大地提升了定位性能。

## 1 算法框架

基于测距误差修正的 BLE 和 PDR 融合室内定位算法主要分为 3 个部分:PDR、BLE 和 EKF 融合,如图 1 所示。

在 PDR 定位中,首先对 IMU 输出的加速度和角速度数据进行低通滤波,使得加速度和角速度数据更加稳定,然后利用滤波后的加速度数据进行步态检测和步长估计,其次通过四元数法进行航向估计,最后利用得到的步长和航向角进行位置推算<sup>[11]</sup>,输出 PDR 定位结果,以便采用 EKF 算法融合。

BLE 定位过程主要分为离线阶段和在线阶段。离线阶段中,通过地图信息进行 SketchUp 室内 3D 建模,并联合射线追踪(ray tracing, RT)传播模型得到 RSS 值,以此构建特征数据集(包括信标位置、发射信号强度、RSS 值、测距值),然后采用 VAE-CNN 网络模型对数据集进行训练。在线阶段中,首先将采集到的 RSS 值进行高斯-中值滤波预处理,通过路径损耗函数获得距离信息,然后利用训练好的网络模型对测距误差进行预测,以实现测距值的修正,最后通过 LS 法获得 BLE 定位信息。

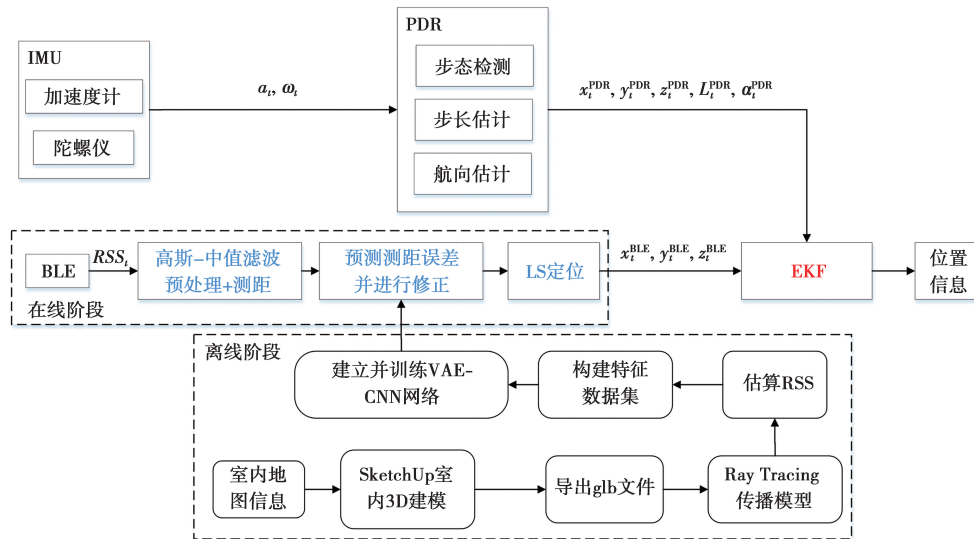


图 1 基于测距误差修正的 BLE 和 PDR 融合定位算法框架

Fig.1 Framework of BLE and PDR fusion localization algorithm based on ranging error correction

在 EKF 融合定位中,将 PDR 定位结果和 BLE 定位结果进行松耦合,获得最终的位置估计。

## 2 SketchUp 室内 3D 建模与 RT 传播模型

为构建特征数据与测距误差之间的相互关系,需要大量的数据集作为支撑。本文采用 SketchUp 室内 3D 建模联合 RT 传播模型的方法获得 RSS 特征数据,以避免 RSS 采集工作费时费力的问题。下面将简要介绍 SketchUp 在室内建模方面的应用以及 RT 传播模型。

### 2.1 SketchUp 简介

SketchUp 是一款由 Trimble 公司开发的易于使用的 3D 建模软件<sup>[15]</sup>。它支持多种文件格式(如 stl、glb、dwg 等)的导入导出操作,方便与其他软件进行数据交互。本节采用该软件实现室内 3D 场景的可视化,如图 2 所示。




图 2 SketchUp 室内 3D 模型

Fig.2 SketchUp interior 3D model

### 2.2 RT 传播模型

RT 传播模型是一种用于预测无线信号传播路径和损耗的高精度模型<sup>[16]</sup>。它通过模拟电磁波的传播路径,包括直射、反射、绕射和透射等现象,来准确预测信号在复杂环境中的传播特性。RT 模型中的路径损耗表式为

$$L = L_{FS} + L_{ref} + L_{diff} \quad (1)$$

式(1)中: $L_{FS}$ 为自由空间损耗; $L_{ref}$ 为反射损耗; $L_{diff}$ 为绕射损耗。各项损耗的计算公式为

$$\begin{cases} L_{FS} = 20\lg\left(\frac{4\pi df}{c}\right) \\ L_{ref} = 10\lg\left(\frac{1}{R}\right) \\ L_{diff} = 20\lg\left[\frac{4\pi h(d_1 + d_2)}{\lambda d_1 d_2}\right] \end{cases} \quad (2)$$

式(2)中: $d$ 为发射源和接收点之间的距离; $f$ 为信号频率; $c$ 为光速; $R$ 为反射系数,取决于反射面的材料和信号入射角; $h$ 为障碍物的高度; $\lambda$ 是信号波长; $d_1$ 和  $d_2$ 分别是发射源和接收点到障碍物的距离。

在实际 RT 建模过程中,为简化对测试环境的分析,将信标建模为配备了全向半波偶极子的天线,同时假设接收端也使用全向天线。此外,为了实现较为确切的 RT 仿真,还必须为墙壁和其他结构元件添加电磁参数,包括相对介电常数和电导率,这些元件材料参数根据国际电联发布文件中的推荐值给出<sup>[17]</sup>,如表 1 所示。

表 1 元件材料的电磁参数

Tab.1 Electromagnetic parameters of component materials

材料	相对介电常数 $\epsilon_r$	电导率 $\sigma/(S/m)$
混凝土	6	0.01
石膏板墙	4	0.02
木制品	2.1	0.05
玻璃	3	$1 \times 10^{-9}$
金属制品	1	$1 \times 10^7$
塑料制品	2	$1 \times 10^{-7}$

通过设置 RT 的仿真参数,如表 2 所示,模拟模拟 BLE 信号的路径,其结果如图 3 所示。

表 2 基于 BLE 信号的 RT 仿真参数

Tab.2 RT simulation parameters based on BLE signals

参数	值
载波频率 $f_c/\text{GHz}$	2.4
带宽 $B/\text{MHz}$	2
发射/接收端天线辐射模式	全向
最大反射次数	3
最大绕射次数	2
BLE 数据包格式	LE1M
符号率/MHz	1
采样率/MHz	8
BLE 数据包长度	256
BLE 信标输出功率/dBm	0
载波频率 $f_c/\text{GHz}$	2.4




图 3 射线追踪仿真结果

Fig.3 Results of ray tracing simulation

### 3 基于 VAE-CNN 测距误差预测的 BLE 定位

为实现测距量的修正,准确地获得测距误差大小至关重要。本节提出了一种测距误差预测的方

法。通过建立 VAE-CNN 深度学习模型,对 RT 信号传播模型得到的数据集进行特征提取和分析,建立了室内 BLE 信号与测距误差之间的映射关系,实现测距误差的预测。

#### 3.1 变分自编码器

变分自编码器 (variational autoencoders, VAE)<sup>[18]</sup>是一种基于高斯混合模型的无监督生成模型。简单地说,任何分布都可以分解成几个高斯分布的叠加,而 VAE 是从概率的角度来描述隐藏变量的。通过提取数据在不同位置的分布特征,实现隐藏空间下数据的特征聚类。

VAE 结构框图如图 4 所示,主要分为编码和解码 2 个过程,首先通过构建 2 个神经网络来将原始数据  $X$  借助其均值和方差使用重参数化方法生成隐变量  $z$ ,然后通过解码器生成重构数据  $X'$ 。

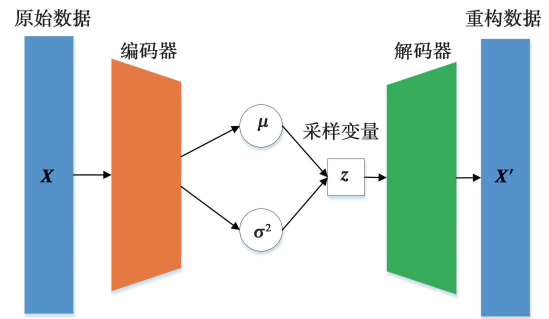


图 4 VAE 模块结构图

Fig.4 VAE module structure diagram

算法的具体流程为以高斯混合模型为理论基础,假设数据服从高斯分布,将  $X$  输入编码器网络,分别计算出  $X$  中每个元素对应的均值和方差,为简化训练过程以及提升优化效率,使数据经过一个均值为 0,方差为 1 的正态分布池,即学习到的概率  $p(z)$  服从正态分布  $N(0,1)$ 。构建出来的编码器神经网络  $p(X)$  为

$$p(X) = \int p(z)p(X|z) dz \quad (3)$$

式(3)中: $X|z \sim N(\mu(z), \sigma^2(z))$ 。

为使得输出的数据尽可能接近原始样本,引入 KL 散度。其核心思想是利用相对好计算的后验概率  $q(z|X)$  来接近先验概率  $p(X|z)$ ,从而只要最小化它们之间的 KL 散度即可近似估算出特征的潜在表示。因此,定义目标函数为

$$\lg p(X) = L(\theta, \varphi, X) + \sum_i^k KL(q_i(z|X) \| p(z)) \quad (4)$$

式(4)中:左边为样本数据  $\mathbf{X}$  的似然函数;右边第一项为变分下界,  $\theta$  为编码器参数,  $\varphi$  为解码器参数, 第二项为 KL 散度。在左边概率函数不变的情况下, 想要通过最小化 KL 散度来缩小差距, 更便利的方法是提高变分下界, 从而减小 KL 散度和重构损失之和。通过对先前得出的方差和交叉熵, 可以推导出重构损失为

$$L_{\mu, \sigma^2} = \frac{1}{2} \sum_i^k (\mu_{(i)}^2 + \sigma_{(i)}^2 - \lg \sigma_{(i)}^2 - 1) \quad (5)$$

最终的目标函数可以表示为

$$L(\theta, \varphi, \mathbf{X}) = L_{\mu, \sigma^2} - \sum_i^k KL(q_i(z | \mathbf{X}) \parallel p(z)) \quad (6)$$

### 3.2 卷积神经网络

卷积神经网络 (convolutional neural network, CNN) 是一种前馈神经网络, 能够从具有卷积结构的数据中提取特征<sup>[19]</sup>。本文将信标坐标、测量距离、发射信号强度以及 RSS 值作为数据集构成形式, 即输入到 VAE 网络的数据实际上是一个类似于二维图像的数据。因此, 本文选择使用 CNN 来处理特征提取。基于多层卷积运算, 可以学习不同数据类型之间的相关性, 从而提高模型的泛化能力。将 CNN 与其他方法相结合, 有助于网络在空间关系方面表现更优。同时, 卷积层是深度神经网络的重要组成部分, 与 VAE 强大的生成模型相结合, 有助于通过深度特征识别以及高保真编码来重建其输出。

具体来说, 在编码过程中使用 CNN 进行特征提取。假设  $w$  为输入矩阵的尺度,  $K$  为卷积核的尺度,  $s$  为滑动步长,  $p$  为零填充大小, 则卷积计算得到的

特征图尺度为

$$w' = \frac{w + 2p - K}{s} + 1 \quad (7)$$

卷积操作完成后, 通常通过池化来减少特征量, 也即数据压缩, 一般有最大池化和平均池化两种。在本节中, 获得数据映射  $\mathbf{V}$  后, 通过卷积网络  $c(K, \mathbf{V}, s)$  得到中间变量  $\mathbf{Z}$ , 并将其共享给整个网络进而计算损失函数  $\mathbf{J}(\mathbf{V}, \mathbf{K})$ 。此时, 经过反向传播可得到满足式(8)的张量  $\mathbf{G}$ 。

$$G_{i,j,k} = \frac{\partial}{\partial K_{i,j,k,l}} \mathbf{J}(\mathbf{V}, \mathbf{K}) = \sum_{m,n} G_{i,m,n} V_{j,(m-1) \times s + k, (n-1) \times s + l} \quad (8)$$

若该层不是网络的最后一层, 则需要根据式(9)求  $\mathbf{V}$  的梯度, 使误差进一步反向传播。

$$h(K, G, s)_{i,j,k} = \frac{\partial}{\partial V_{i,j,k}} \mathbf{J}(\mathbf{V}, \mathbf{K}) = \sum_{l,m} \sum_{n,p} \sum_q K_{q,i,m,p} G_{q,l,n} \quad (9)$$

$$\text{s.t. } (l-1) \times s + m = j(n-1) \times s + p = k$$

式(9)中:  $i$  表示第  $i$  个输出通道, 输出的行和列分别对应  $j$  和  $k$ ;  $l$  表示第  $l$  个输入通道, 输入行偏移量和列偏移量分别对应  $m$  和  $n$ 。一般来说, 从输入到输出的变换过程中, 非线性运算是通过加入偏移项来实现的。

### 3.3 VAE-CNN 测距误差预测模型

VAE-CNN 测距误差预测模型的整体结构如图 5 所示, 其中,  $(x_n, y_n, z_n)$  表示信标坐标;  $d_n$  表示测量距离;  $P_m$  表示接收信号强度;  $P_n$  表示发射信号强度。

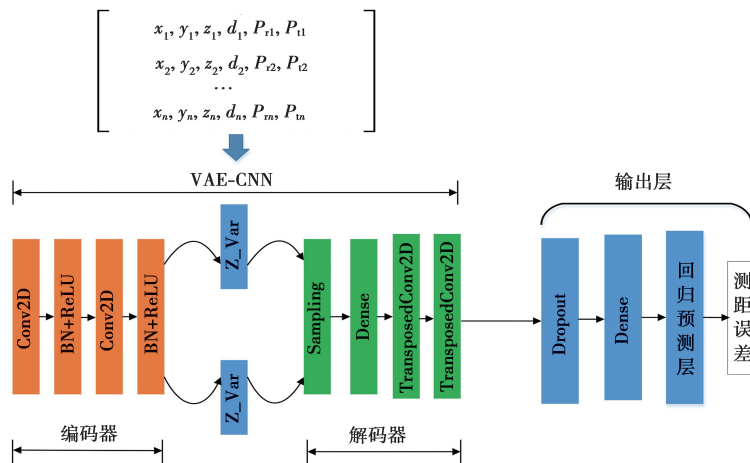


图 5 基于 VAE-CNN 的测距误差预测模型

Fig.5 Ranging error prediction model based on VAE-CNN

在构建 VAE-CNN 预测模型的基础上,需要先训练一个二维的 CNN 辅助 VAE 来获得特征提取模型,再训练一个全连接网络来获得预测模型。具体来说,VAE 的编码器采用 CNN 对数据信息进行特征提取,并通过最大池化方法获得最具代表性的特征。在解码器中,还使用反卷积对采样后的潜在特征向量进行恢复,得到重构数据,通过优化重构损失和 KL 散度对网络进行训练,直到模型收敛。在输出端,通过 Dropout 层防止网络的过拟合,最终通过回归预测输出预测误差。

在线阶段,通过 VAE-CNN 网络预测得到的测距误差对实际测得距离值进行修正,表达式为

$$d' = d - E \quad (10)$$

进一步地,采用 LS 算法获得 BLE 定位结果。

#### 4 EKF 融合定位

卡尔曼滤波是一种经典的最优线性系统估计算法,由于 PDR 定位方程为非线性,不能直接采用卡尔曼滤波,需要对非线性方程线性化。本文采用 EKF 方法<sup>[20]</sup>,对非线性方程作一阶泰勒级数展开,将其转换成近似线性化系统,从而获得 PDR 与 BLE 的融合定位结果。其系统的状态转移方程和观测方程表达式分别为

$$\mathbf{x}_t = \begin{bmatrix} x_t \\ y_t \\ z_t \\ L_t \\ \alpha_t \end{bmatrix} = \begin{bmatrix} x_{t-1} + L_{t-1} \cos\theta_{t-1} \sin\alpha_{t-1} \\ y_{t-1} + L_{t-1} \cos\theta_{t-1} \cos\alpha_{t-1} \\ z_{t-1} + L_{t-1} \sin\theta_{t-1} \\ L_{t-1} \\ \alpha_{t-1} \end{bmatrix} + \mathbf{w} \quad (11)$$

$$z_t = [x_t^{\text{BLE}} \quad y_t^{\text{BLE}} \quad z_t^{\text{BLE}}]^T + \mathbf{v} \quad (12)$$

式(11)–(12)中: $\mathbf{w}$ 为状态转移方程的过程噪声向量, $\mathbf{w} \sim N(0, \mathbf{Q})$ ;  $\mathbf{v}$ 为观测方程的测量噪声向量, $\mathbf{v} \sim N(0, \mathbf{R})$ ;  $w$ 与  $v$ 相互独立,  $(x_t, y_t, z_t)$ 表示预测的第  $t$  步位置;  $L_t$ 为预测的步长;  $\theta_t$ 为预测的俯仰角;  $\alpha_t$ 为预测的航向角;  $(x_t^{\text{BLE}}, y_t^{\text{BLE}}, z_t^{\text{BLE}})$ 表示第  $t$  步的 BLE 定位结果。

EKF 线性化与状态初始化后,系统的先验估计为

$$\mathbf{x}'_t = \mathbf{A}\mathbf{x}_{t-1} \quad (13)$$

$$\mathbf{P}'_t = \mathbf{A}\mathbf{P}_{t-1}\mathbf{A}^T + \mathbf{Q}$$

卡尔曼增益矩阵可以表示为

$$\mathbf{K}_t = \mathbf{P}'_t \mathbf{H}^T (\mathbf{H} \mathbf{P}'_t \mathbf{H}^T + \mathbf{R})^{-1} \quad (14)$$

更新系统状态与协方差矩阵,可得到系统的后验估计为

$$\mathbf{x}_t = \mathbf{x}'_t + \mathbf{K}_t(z_t - \mathbf{H}\mathbf{x}'_t) \quad (15)$$

$$\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}) \mathbf{P}'_t$$

式(15)中,状态转移矩阵  $\mathbf{A}$  为

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & \cos\theta_{t-1} \sin\alpha_{t-1} & L_{t-1} \cos\theta_{t-1} \cos\alpha_{t-1} \\ 0 & 1 & 0 & \cos\theta_{t-1} \cos\alpha_{t-1} & -L_{t-1} \cos\theta_{t-1} \sin\alpha_{t-1} \\ 0 & 0 & 1 & \sin\theta_{t-1} & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (16)$$

观测矩阵为

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix} \quad (17)$$

由 BLE 定位给出融合定位系统的初始位置  $(x_1, y_1, z_1)^T$ , 初始协方差矩阵为  $\mathbf{P}_1$ , 系统的过程噪声协方差矩阵  $\mathbf{Q}$  由 PDR 定位的位置、步长和航向角估计的平均误差构成, 观测噪声协方差矩阵  $\mathbf{R}$  由 BLE 定位的平均误差构成。融合定位系统状态初始值的表达式为

$$\mathbf{P}_1 = \mathbf{I}_{5 \times 5} \quad (18)$$

$$\mathbf{Q} = \text{diag} \{ \delta_{x^{\text{PDR}}}^2, \delta_{y^{\text{PDR}}}^2, \delta_{z^{\text{PDR}}}^2, \delta_L^2, \delta_\alpha^2 \} \quad (19)$$

$$\mathbf{R} = \text{diag} \{ \delta_{x^{\text{BLE}}}^2, \delta_{y^{\text{BLE}}}^2, \delta_{z^{\text{BLE}}}^2 \} \quad (20)$$

式(18)–(20)中:  $\delta_{x^{\text{PDR}}}$ 、 $\delta_{y^{\text{PDR}}}$ 、 $\delta_{z^{\text{PDR}}}$ 、 $\delta_L$ 、 $\delta_\alpha$  分别表示 PDR 定位 X 轴、Y 轴、Z 轴、步长估计和航向角估计的平均误差, 各指标通过 Allan 方差进行标定<sup>[21]</sup>。  $\delta_{x^{\text{BLE}}}$ 、 $\delta_{y^{\text{BLE}}}$ 、 $\delta_{z^{\text{BLE}}}$  分别表示 BLE 定位 X 轴、Y 轴、Z 轴的平均误差。由于在估计  $\mathbf{R}$  矩阵前对 BLE 测距量进行了修正, 使测距精度得到了有效提升, 定位误差随之减小。为此, 将  $\mathbf{R}$  矩阵中各指标采用 VAE-CNN 模型预测得到的相对测距误差进行标定。

### 5 实验设置及结果分析

#### 5.1 实验设置

实验环境与场景平面图如图 6 所示。房间长 7.7 m、宽 6.8 m、高 3 m, 中间有一处挡风玻璃, 长 4.6 m、宽 0.1 m、高 2.2 m, 作为 NLOS 障碍物。行进路线外围的 6 个信标部署在距地面 1 m 高的位置, 中间的 2 个信标部署在距地面 2.2 m 高的位置。实验采用 iBeacon-AK51 型号的 BLE 信标作为信号发射器, 信标发射功率设置为 0 dBm, WT9011DCL-

BT50 作为惯导器件与智能手机连接,通过智能手机进行数据采集,采样频率设置为 50 Hz。行人以

1.2 m 高度水平手持手机从起点出发,匀速行走一圈。

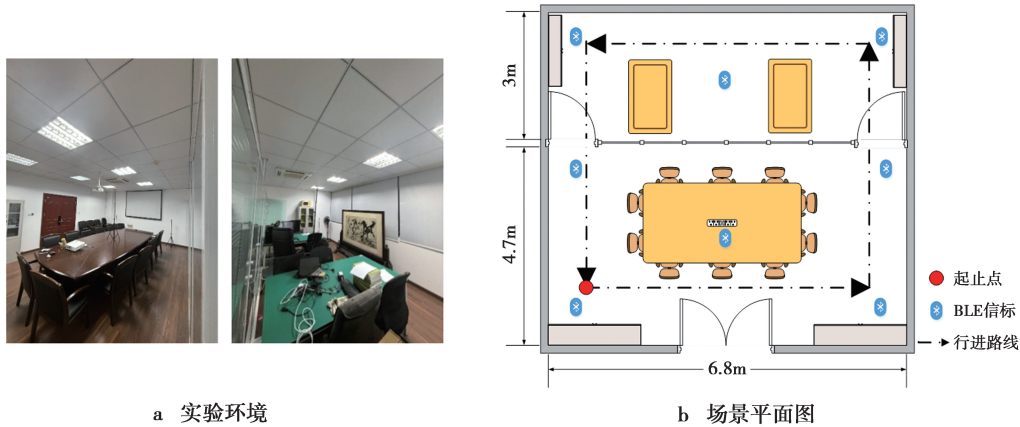


图 6 实验环境与场景平面图

Fig.6 Experimental environment and floor plan

### 5.2 网络训练设置及结果分析

在 VAE-CNN 模型参数中设置训练的优化算法、迭代次数、学习率等参数初始值,损失函数为均方差损失函数,然后将 RT 算法生成的数据作为训练集,室内环境中实际得到的数据作为测试集,模型优化的对象为测距误差值。根据当前样本的数据分布,选择合适的卷积核,通过不断的迭代操作,最终预测出当前状态的测距误差值。

训练模型的目的是获得一组参数,使模型的预测精度满足后续的定位要求。为了使所提出的模型尽可能轻量化,对具有不同层数的几种体系结构进行了比较。为了使其在预测速度和准确性方面更有效,最终模型结构的超参数设置如表 3 所示。

表 3 VAE-CNN 模型超参数

Tab.3 Hyperparameters of the VAE-CNN

超参数	参数值
输入尺寸	1×6×1
卷积层	1×2 卷积核,步长为 1
维度	64
激活函数	ReLU
卷积层数量	2
优化器	Adam
学习率	0.001
Dropout 比率	0.5
批量大小	100
训练周期	500

在 VAE-CNN 网络的构建中,设计了由卷积网络组成的输入层、编码层和解码层。其中,特征提取通过两层的卷积运算实现,首先将数据转换为 1×6×1 格式的输入数据,然后用 2 个 1×2 卷积核对数据进行卷积,并采用注意力机制增强对有用特征的提取。在解码器中,将编码器的结果作为输入,输出重构数据。在测距误差预测中,采用 ReLU 激活函数,使神经元具有稀疏性。为了防止过度拟合,没有使用复杂的模型结构,全连接层前的 dropout 值为 0.5,学习率为 0.001,批量大小为 100,训练周期为 500 轮。

用实际环境中测得的 RSS 等数据进行测试,可以得到 8 个信标下行人每一步的实际测距误差与预测测距误差的对比结果如图 7 所示。此外,本文将实际的测距误差值与 CNN、LSTM<sup>[22]</sup>、CNN-LSTM<sup>[23]</sup>、Transformer<sup>[24]</sup>、VAE-CNN 网络预测出的测距误差值作差并取绝对值,得到相对测距误差,对比以显示出所提 VAE-CNN 网络在测距误差预测中的优异性能,其相对测距误差值的分布结果对比如图 8 所示。

从上述结果中不难发现,采用 VAE-CNN 模型预测的测距误差与实际的测距误差较为接近能够很好地捕捉到测距误差的变化规律。与 CNN、LSTM、CNN-LSTM、Transformer 模型相比,其相对测距误差较小,均在 1.2 m 范围内,且 70%的相对测距误差均在 0.5 m 范围内,具有较好的测距误差预测性能。

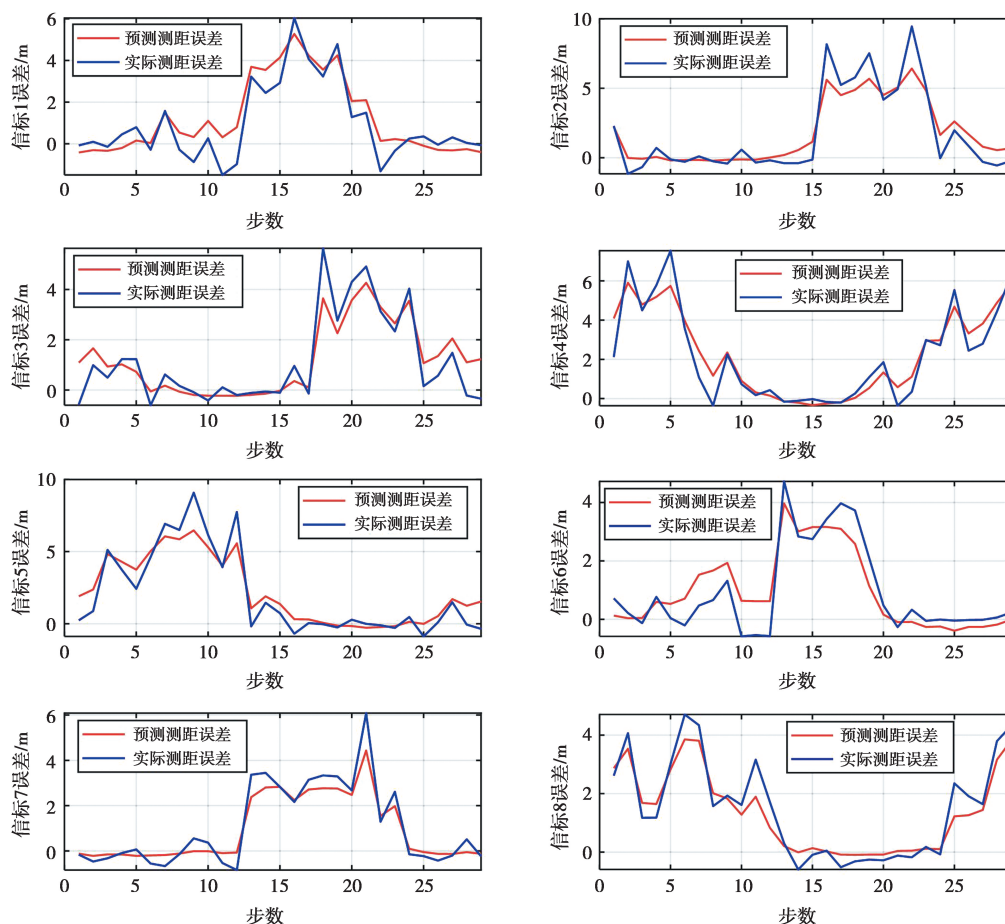


图 7 测距误差结果

Fig.7 Ranging measurement error results




图 8 相对测距误差对比结果

Fig.8 Comparison results of relative ranging errors

### 5.3 NLOS 影响程度的量化分析

为评估 VAE-CNN 模型在不同 NLOS 遮挡类型下的测距误差预测性能,本文分析了多种遮挡物对 BLE 测距误差的影响及该模型的预测效果。

实验设置如图 9 所示,手机与 BLE 信标分别放置在高为 1.5 m 的支架上,两者相距 4 m,确保初始

条件下视距测距基准。信标发射功率设置为 0 dBm,手机端通过安卓应用实时采集 RSS 值,并通过路径损耗模型转换为距离值。随后添加不同的遮挡物测试对测距误差的影响,遮挡物包括:纸制品、玻璃、木制品、金属物和人体,每组遮挡物实验进行 30 次以评估其测距误差。




图 9 遮挡物测距实验设置

Fig.9 Obstruction ranging experimental setup

实验结果如图 10 所示,不同遮挡物对测距结果影响显著。金属物遮挡导致的测距误差最大,实际最大误差可达到 6 m,反映出金属物电磁特性对信

号传播的强烈干扰。而在人体、木制品、玻璃或纸质品的遮挡条件下,实际的测距误差和预测的测距误差基本保持一致,论证了 VAE-CNN 网络模型在不同遮挡物情况下良好的测距误差预测性能。




图 10 不同遮挡物的 BLE 测距误差

Fig.10 BLE ranging errors with different obstructions

### 5.4 定位结果及分析

在线阶段,按图 6 设置进行实验,根据 VAE-CNN 网络预测出来的测距误差对 BLE 测距定位进行修正,从而提高 BLE 测距定位精度,进而提升

$$\begin{cases} S_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 + (z_i - \hat{z}_i)^2]} \\ S_{\text{STD}} = \sqrt{\frac{1}{n} \sum_{i=1}^n [(\hat{x}_i - \bar{x}_i)^2 + (\hat{y}_i - \bar{y}_i)^2 + (\hat{z}_i - \bar{z}_i)^2]} \end{cases} \quad (21)$$

式(21)中: $(x_i, y_i, z_i)$ 为目标真实位置; $(\hat{x}_i, \hat{y}_i, \hat{z}_i)$ 为估计位置; $(\bar{x}_i, \bar{y}_i, \bar{z}_i)$ 为多次估计位置的平均结果; $n$

EKF 融合定位性能。将基于 RSS 的 BLE 测距定位、基于 RSS 无线地图的 BLE 指纹定位<sup>[25]</sup>、EKF 融合定位以及测距修正后的 BLE 和 EKF 定位进行对比,其定位轨迹及误差 CDF 如图 11 所示。

从图 11a 中可以看到,BLE 指纹定位受室内环境(多径效应、NLOS 干扰等)影响以及参考点选取的密集程度限制,定位轨迹较为凌乱,主要集中在中心区域。而采用 BLE 测距定位通过 VAE-CNN 模型进行测距误差预测修正,提高测距的精确度,从而提升了其定位精度,使其与未进行测距修正的 BLE 定位相比更接近真实轨迹。进一步地,通过 EKF 融合定位后,轨迹更加平滑,定位效果更优。图 11b 显示,BLE 定位最大误差在 8.2 m 左右,EKF 定位的最大误差为 3.8 m,而采用 VAE-CNN 测距误差预测修正后 BLE 定位的最大误差为 2.8 m 左右,对应的 EKF 融合定位的最大误差可控制在 2 m 内,取得了较好的定位性能。

表 4 给出了 PDR 定位、BLE 测距定位、BLE 指纹定位以及 EKF 定位算法与采用 VAE-CNN 模型预测测距误差修正的定位算法的定位误差指标值。其中,均方根误差(root mean squared error, RMSE)和标准差(standard deviation, STD)表示为

为计算的样本个数,即待定位点的个数,本文中  $n=29$ 。

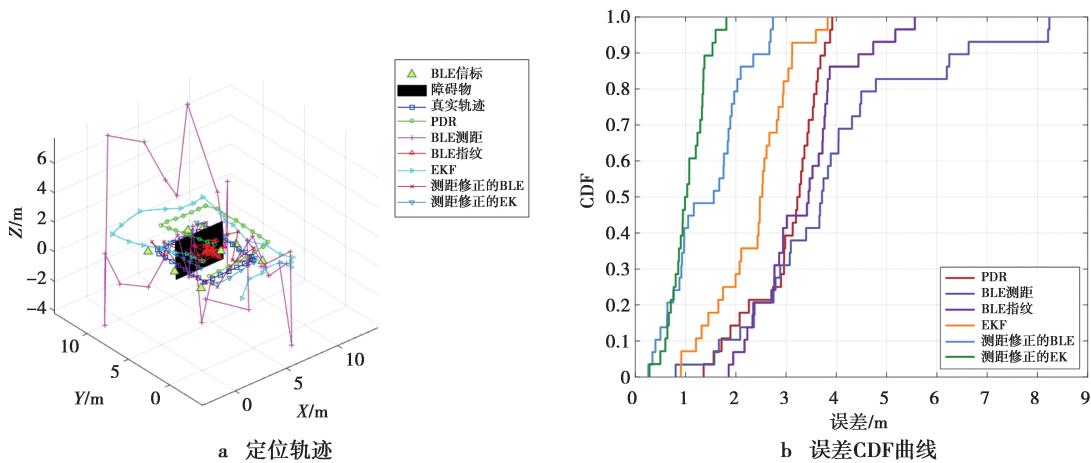


图 11 定位轨迹及误差 CDF 曲线

Fig.11 Positioning trajectory and error CDF curve

可以看到,BLE 测距定位的 RMSE 和 STD 分别为 10.41 m、4.46 m,通过与 PDR 定位算法进行 EKF

融合可使两指标分别降至 4.73 m、2.34 m,对 BLE 测距定位效果有着一定程度的改善,但 NLOS 的影响

未能从根本上进行解决。BLE 指纹定位同样也受 NLOS 影响,其定位性能不佳。而通过测距修正后的 BLE 定位 RMSE 和 STD 分别为 2.42 m 和 1.53 m。这是因为采用 VAE-CNN 深度学习模型对测距误差与信标位置、RSS 等相关因素之间的关系进行建模,在实际测试中对测距值进行误差修正,从根本上消除了 NLOS 对测距的影响,进而提升了定位性能。进一步地,采用测距修正后的 EKF 融合定位的 RMSE 和 STD 可分别降至 0.81 m 和 0.28 m。

表 4 定位性能指标

Tab.4 Positioning performance metrics

m		
误差指标	RMSE	STD
PDR	6.83	2.97
BLE 测距	10.41	4.46
BLE 指纹	7.15	3.56
EKF	4.73	2.34
测距修正的 BLE	2.42	1.53
测距修正的 EKF	0.81	0.28

另一方面,设置不同的 BLE 信标部署数量,分别选择 5 个信标(4 个信标放置在各角落,距地面 1 m 高的位置,房间的中央放置一个信标,距地面 2.2 m 高的位置)、6 个信标(按图 6 所示去掉中间靠墙一侧的两个信标即可)、8 个信标(即图 6 所示)进行实验,得到每种信标部署下的 RMSE 及 STD 值分别如表 5、表 6 所示。

表 5 不同信标数量下的 RMSE 指标

Tab.5 RMSE metrics for different numbers of beacons

m			
RMSE	5 信标	6 信标	8 信标
BLE 测距	24.38	15.76	10.41
BLE 指纹	12.73	8.54	7.15
EKF	10.46	6.92	4.73
测距误差修正的 BLE 定位	4.36	3.76	2.42
测距误差修正的 EKF 定位	2.07	1.23	0.81

不难发现,当信标数量为 6 时,相比 8 个 BLE 信标,各定位算法误差增大趋势各有不同,这表明信标数量减小后测量信息随之减少,未采用测距修正的定位算法更易受 NLOS 影响导致定位精度急剧下降,而采用测距修正的定位方法通过修正 NLOS 误差进行定位,仍具有鲁棒的定位性能。特别地,当信标数量只有 5 时,未经过测距修正的 BLE 测距定位和 EKF 定位的 RMSE 和 STD 值呈现指数级增长,而

基于测距误差修正的定位算法可以适应这种 BLE 信标稀疏部署的情形,其 RMSE 值分别为 4.36 m 和 2.07 m,而 STD 值分别为 2.78 m 和 1.82 m,进一步说明了该方法具有较好的定位性能。

表 6 不同信标数量下的 STD 指标

Tab.6 STD metrics for different numbers of beacons

m			
STD	5 信标	6 信标	8 信标
BLE 测距	10.45	6.61	4.46
BLE 指纹	6.36	4.78	3.56
EKF	5.93	3.72	2.34
测距误差修正的 BLE 定位	2.78	1.95	1.53
测距误差修正的 EKF 定位	1.82	1.36	0.28

## 6 结束语

本文利用 VAE-CNN 深度学习模型预测 BLE 测距误差,在定位过程中进行修正,提升了 BLE 和 PDR 融合的定位精度。其中,为减少实际 RSS 采集工作量,通过 SketchUp 室内 3D 建模结合 RT 算法尽可能地模拟真实环境中 RSS 值,在实际测试过程中证实了这种方法的有效性。根据实验结果,采用测距修正后的 BLE 测距定位以及 EKF 融合定位的最大定位误差分别在 3 m、2 m 以内,较未进行测距修正的 BLE 测距定位和 EKF 融合定位有着较大的性能提升。另一方面,在 BLE 部署密度较低时,所提算法仍能获得较好的定位精度,具有普遍的适用性。在后续研究中,将增加更多的观测信息量以提升定位性能。

## 参考文献:

[1] KOUASSI H K W, STIENNE G, REBOUL S. GNSS phase positioning without ambiguity resolution [ C ] // 2024 International Conference on Localization and GNSS (ICL-GNSS). Antwerp, Belgium: IEEE, 2024: 1-7.

[2] XU Y, SHMALIY Y S, BI S, et al. Extended Kalman/UFIR filters for UWB-based indoor robot localization under time-varying colored measurement noise [ J ]. IEEE Internet of Things Journal, 2023, 10(17): 15632-15641.

[3] QI H, SONG X, ZHANG Y, et al. Multi-scale sensing network for WiFi Indoor localization [ C ] // 2023 IEEE 23rd International Conference on Communication Technology (ICCT). Wuxi, China: IEEE, 2023: 1087-1092.

[4] GUO G, CHEN R, YAN K, et al. Multi-channel and multi-RSS based BLE range estimation for indoor tracking of commercial smartphones [ J ]. IEEE Sensors Jour-

- nal, 2023, 23(24): 30728-30738.
- [5] SUN M, WANG Y, JOSEPH W, et al. Indoor localization using mind evolutionary algorithm-based geomagnetic positioning and smartphone IMU sensors[J]. IEEE Sensors Journal, 2022, 22(7): 7130-7141.
- [6] ROSE C, BRITT J, ALLEN J, et al. An integrated vehicle navigation system utilizing lane-detection and lateral position estimation systems in difficult environments for GPS[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(6): 2615-2629.
- [7] WEN K, YU K, LI Y, et al. A new quaternion Kalman filter based foot-mounted IMU and UWB tightly-coupled method for indoor pedestrian navigation[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 4340-4352.
- [8] TAO Y, ZHAO L. AIPS: An accurate indoor positioning system with fingerprint map adaptation[J]. IEEE Internet of Things Journal, 2021, 9(4): 3062-3073.
- [9] LAN T, WANG X, CHEN Z, et al. Fingerprint augment based on super-resolution for WiFi fingerprint based indoor localization[J]. IEEE Sensors Journal, 2022, 22(12): 12152-12162.
- [10] WANG X, GAO L, MAO S, et al. CSI-based fingerprinting for indoor localization: A deep learning approach [J]. IEEE Transactions on Vehicular Technology, 2016, 66(1): 763-776.
- [11] 刘宇,李汪润,陈燕苹.基于自适应峰值检测的PDR算法研究[J].电子测量技术, 2023, 46(17): 37-42.  
LIU Y, LI W R, CHEN Y P. Research on PDR algorithm based on adaptive peak detection[J]. Electronic Measurement Technology, 2023, 46(17): 37-42.
- [12] CHEN Z, ZHU Q, SOH Y C. Smartphone inertial sensor-based indoor localization and tracking with iBeacon corrections[J]. IEEE Transactions on Industrial Informatics, 2016, 12(4): 1540-1549.
- [13] WU Y, CHEN R, FU W, et al. Indoor positioning based on tightly coupling of PDR and one single Wi-Fi FTM AP[J]. Geo-spatial Information Science, 2023, 26(3): 480-495.
- [14] YUAN D, ZHANG J, WANG J, et al. Robustly adaptive EKF PDR/UWB integrated navigation based on additional heading constraint [J]. Sensors, 2021, 21(13): 4390.
- [15] ZHANG X, CHEN Y, YU L, et al. Three-dimensional modeling and indoor positioning for urban emergency response[J]. ISPRS International Journal of Geo-Information, 2017, 6(7): 214.
- [16] YUN Z, ISKANDER M F. Ray tracing for radio propagation modeling: Principles and applications[J]. IEEE access, 2015, 3: 1089-1100.
- [17] HE D, AI B, GUAN K, et al. The design and applications of high-performance ray-tracing simulation platform for 5G and beyond wireless communications: A tutorial[J]. IEEE Communications Surveys & Tutorials, 2018, 21(1): 10-27.
- [18] LIANG S, PAN Z, LIU W, et al. A survey on variational autoencoders in recommender systems[J]. ACM Computing Surveys, 2024, 56(10): 1-40.
- [19] BHATT D, PATEL C, TALSANIA H, et al. CNN variants for computer vision: History, architecture, application, challenges and future scope[J]. Electronics, 2021, 10(20): 2470.
- [20] 田昕,魏国亮,王建华,等.NLOS环境下的改进EKF定位算法研究[J].控制工程, 2020, 27(5): 909-913.  
TIAN X, WEI G L, WANG J H, et al. Research on improved EKF localization algorithm under NLOS environment [J]. Control Engineering of China, 2020, 27(5): 909-913.
- [21] EL-SHEIMY N, HOU H, NIU X. Analysis and modeling of inertial sensors using Allan variance[J]. IEEE Transactions on Instrumentation and Measurement, 2007, 57(1): 140-149.
- [22] LANDI F, BARALDI L, CORNIA M, et al. Working memory connections for LSTM [J]. Neural Networks, 2021(144): 334-341
- [23] NGAMAKEUR K, YONGCHAREON S, YU J, et al. Deep CNN-LSTM network for indoor location estimation using analog signals of passive infrared sensors [J]. IEEE Internet of Things Journal, 2022, 9(22): 22582-22594.
- [24] RAFIQUE H, PATTI D, PALESI M, et al. Fusing visuals with magnetic signals to improve indoor localization using vision transformer [C]//2024 14th International Conference on Indoor Positioning and Indoor Navigation (IPIN). Kowloon, Hong Kong, China; IEEE, 2024: 1-6.
- [25] RENAUDIN O, ZEMEN T, BURGESS T. Ray-tracing based fingerprinting for indoor localization [C]//2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications ( SPAWC ). Kalamata, Greece; IEEE, 2018: 1-5.

#### 作者简介:

刘 辉,正高级工程师,硕士,主要研究方向为目标检测、深度学习、室内定位。E-mail: liuhui@cqcyit.com。

何航川,硕士研究生,主要研究方向为深度学习、室内定位。E-mail: hangchuan\_he@163.com。

(编辑:刘 勇)