

DOI:10.13382/j.jemi.B2508477

基于 WiFi-CSI 嗅探技术的高精度室内 无人机定位方法研究 *

陈 静^{1,2} 林同禹^{1,2} 阴存翊^{1,2} 江 灏^{1,2} 郑绍聪^{1,2}

(1. 福州大学电气工程与自动化学院 福州 350100; 2. 福州大学电力系统与产业研究院 福州 350100)

摘 要: 针对现有无人机室内定位方案定位精度不足、高成本、需搭载专用定位模块的问题,设计一种基于 WiFi 信道状态信息 (WiFi-channel state information, WiFi-CSI) 嗅探技术的高精度无人机三维定位系统。该系统通过部署若干低成本的 ESP32-S3 传感器组成无人机感知网络,直接嗅探无人机 WiFi 信号并从中解析出 CSI 信号,结合飞行时间(time of flight, ToF)传感器获取的高度信息,实现了无需无人机搭载专用定位接收模块的轻量化高精度定位方案。针对不同高度层的 CSI 信号特性,进一步创新性地设计分层训练策略和稀疏神经回归网络(SE-inception-ResNE-IDCNN, SIRD),通过融合 SE 注意力机制、Inception 多尺度卷积与残差连接,构建 CSI 信号与二维坐标的映射关系,最终将预测坐标与 ToF 高度信息融合实现三维定位。实验结果验证了所提出系统的有效性:平均定位误差 (MLE) 为 0.107 9 m,定位均方误差 (LMSE) 为 0.100 3 m,定位误差的决定系数 R^2 为 0.956 2。所提出的方法较现有无人机室内定位方法精度有显著提升,为无人机室内应用提供了低成本、高精度的解决方案。

关键词: 室内定位;无人机;信道状态信息;深度学习;三维定位

中图分类号: TN98;TH89 **文献标识码:** A **国家标准学科分类代码:** 510.99

Research on high-precision indoor UAV positioning method based on WiFi-CSI sniffing technology

Chen Jing^{1,2} Lin Tongyu^{1,2} Yin Cunyi^{1,2} Jiang Hao^{1,2} Zheng Shaocong^{1,2}

(1. School of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350100, China;
2. Power Equipment System Industry Research Institution, Fuzhou University, Fuzhou 350100, China)

Abstract: To address the issues of insufficient positioning accuracy, high cost, and the requirement for dedicated onboard positioning modules in existing indoor UAV positioning schemes, this paper proposes a high-precision three-dimensional (3D) UAV positioning system based on WiFi channel state information (WiFi-CSI) sniffing. Specifically, the system deploys a number of low-cost ESP32-S3 sensors to construct a UAV sensing network, which directly sniffs the WiFi signals transmitted by the UAV and parses the CSI signals from them. Combined with the altitude information acquired by time of flight (ToF) sensors, this system achieves a lightweight and high-precision positioning solution that eliminates the need for dedicated positioning receiving modules on the UAV. Considering CSI characteristics at different altitude layers, we innovatively design a hierarchical training strategy and a sparse neural regression network (SIRD). Fusing the SE attention mechanism, Inception multi-scale convolution, and residual connections, the network establishes the mapping between CSI and 2D coordinates. 3D positioning is finally realized by fusing predicted 2D coordinates with ToF altitude. Experimental results verify the effectiveness of the proposed system are the mean localization error (MLE) is 0.107 9 m, the localization mean squared error (LMSE) is 0.100 3 m, and the coefficient of determination R^2 is 0.956 2. Compared with existing indoor UAV positioning methods, the proposed method achieves a significant improvement in positioning accuracy, providing a low-cost and high-precision solution for indoor UAV applications.

Keywords: indoor positioning; unmanned aerial vehicle; channel state information; deep learning; 3D positioning

0 引言

随着无人机技术的不断进步和发展,无人机室内定位的应用场景越来越广泛,对于无人机室内定位技术的需求也随之增加。无人机室内定位的准确性对任务有着决定性影响,例如在室内巡检、仓库管理和紧急救援等领域。传统全球定位系统能够为无人机在室外作业提供高精度的定位,然而在复杂多变室内环境中,该系统难以实现高精度的定位服务。因此如何提供高精度的室内定位服务成为了新的研究热点。随着传感器技术的发展,许多新型传感器技术得到应用,例如 WiFi^[1-2]、蓝牙^[3-5]、RFID^[6]、低分辨率红外传感技术^[7-10]等。基于 WiFi 传感器技术根据 WiFi 信号度量的不同可以分为基于 WiFi 信号接收强度 (received signal strength, RSS) 传感器技术^[11-13]与基于 WiFi 信道状态信息 (WiFi-CSI) 传感器技术^[14-15]。在室内定位中,基于 RSS 的定位技术通过接收信号强度来判断距离。然而,信号在室内传播时会受到多径效应、障碍物遮挡、环境噪声等多种因素的干扰,这严重影响了定位的精度和可靠性。此外,基于蓝牙的定位技术虽然也是一种常见的室内定位手段,但其通信距离有限,且容易受到其他 WiFi 设备的干扰,从而进一步限制了其在复杂环境中的应用效果。基于 RFID 的定位技术需要部署大量的读写器和标签,且容易受到室内复杂环境因素的干扰,相比于上述传感技术,CSI 信号具备丰富的频域信息,且在复杂的室内环境下有着更强的抗干扰能力,从而为基于 CSI 的定位技术实现高精度定位提供了有力支持。Kotaru 等^[16]创新性的将 CSI 与虚拟现实中的位置追踪相结合,设计了一个无线信道数学模型,实现了追踪目标设备的移动,然而,在复杂多变的室内环境下,基于单一数学模型的位置解算方法存在局限性,需要进行复杂的优化与调整。Zhang 等^[17]以目标反射路径的迎角作为观测信息,基于粒子滤波算法估计目标位置提出了 DeFi 系统,该系统中位定位误差小于 0.6 m。尽管该方法可以提高 CSI 的定位精度,但是需要多天线或者复杂的硬件系统难以应用在真实的室内场景。Choi 等^[18]提出使用长短期记忆 (LSTM) 块组成的循环神经网络结构对 RSS 和 CSI 融合的指纹进行分类,平均检测率和准确率分别能达到 93.7% 和 91.4%。然而,这些方法大多集中在普通室内定位场景,其定位精度有限,难以满足室内无人机定位等高精度应用场景的需求。

由于 CSI 信号能够提供更丰富的信道信息,一些学者尝试将 CSI 技术用于对无人机的研究中,Piao 等^[19]提出使用无人机自动构建 CSI 地图来解决人工构建高精度的指纹库需要耗费大量的人力的限制,该方法专注于通过无人机搭载 CSI 采集设备来采集数据并构建地图,且

需要大型无人机搭载专门的 CSI 采集设备,不适用于室内环境。Lu 等^[20]针对无人机着陆高精度高度需求,提出无设备高度定位方案,通过降落平台周边部署双路由器,基于无人机扰动原始 CSI 构建高度指纹库,结合 W-KNN 实现定位。然而该方案为一维定位,且专注辅助无人机降落。Nie 等^[21]采用 3 台软件无线电获取商用无人机 WiFi 及 CSI,结合机器学习实现检测准确率达 97.85%,后续通过超分辨率估计提取方位角等特征定位实现 2 D 中位精度 0.76 m。该被动嗅探法较无人机扰动 CSI 法抗干扰性与定位精度更优,但软件无线电部署成本高,仅适用于检测黑飞非高精度检测。现有基于 CSI 的无人机研究多集中于数据采集或特定辅助功能,缺乏对室内高精度定位的系统性探索。此外,许多现有方法需要无人机搭载专门的定位模块(如 UWB 模块)这些模块虽然能够提供较高的定位精度,但会显著增加无人机的功耗,降低无人机的续航能力,因此本文研究重点在于如何针对室内场景下采集并利用 CSI 信号以实现无人机室内的高精度定位。与 UWB 的方法不同,本研究提出的方案是无需搭载额外的定位模块的轻量化定位方案,避免了因增加功耗和负载而对无人机续航能力造成的负面影响。综合考虑 CSI 信号特征,研究一种有效提取 CSI 信号特征的方法对实现高精度的无人机室内定位的研究具有重要意义。

针对上述问题,研究提出一种基于 WiFi-CSI 嗅探技术的无人机室内三维定位系统。系统通过部署低成本 ESP32-S3 的 CSI 传感器,主动嗅探无人机 WiFi 信号解析 CSI 信息,并结合无人机自带飞行时间 (time of flight, ToF) 传感器获取高度信息,无需额外定位模块,有效降低了硬件成本。针对不同高度层的 CSI 信号特性,研究创新性地提出采用分层训练的方式来对不同高度层的 CSI 信号进行训练的策略,在提高精度的同时也降低了模型的复杂度。针对 CSI 信号对室内定位的关键信息,构建了一种稀疏神经回归网络 (SE-inception-ResNE-1DCNN, SIRD),通过融合 SE 注意力机制、Inception 多尺度卷积与残差连接,构建 CSI 信号与二维坐标的映射关系,最终将预测坐标与 ToF 高度信息融合,实现室内无人机的三维定位。经实验验证,研究构建的无人机室内定位系统平均定位误差 (MLE) 仅为 0.107 9 m。

1 实验原理

1.1 无人机定位系统设计

无人机室内定位系统原理如图 1 所示,在室内天花板三角形部署若干个基于 ESP32-S3 的 CSI 传感器,过路由器使得无人机、CSI 传感器和上位机处于同一局域网内。CSI 传感器通过不断的 ICMP 的 Ping 技术去诱发无

人机交换 WiFi 数据,进而解析出 CSI 信息,并通过 UDP 通信将 CSI 数据传输至上位机。针对 CSI 信号对室内定位的关键信息,本文构建出 SIRD 网络并采用分层训练的方式对不同高度层下的 CSI 信号进行训练和特征提取,以固化模型。模型训练完毕后,根据不同高度层的 CSI

信号输入到对应高度层的训练好的室内定位模型 SIRD 中,来预测无人机在不同高度下的二维位置信息。最后,将预测的无人机二维坐标与 ToF 传感器获取的高度值融合起来,从而实现无人机在室内空间中的三维定位。




图1 基于 CSI 的无人机室内定位系统原理

Fig. 1 Schematic diagram of CSI-based UAV indoor positioning system

1.2 数据采集

研究提出一种轻量化定位方案,适用于室内无搭载能力的小型无人机,且无需对无人机本体进行任何改造和搭载额外的定位模块。该方案借助 CSI 传感器嗅探无人机本体上的 CSI 信号,无需无人机搭载专用定位模块、主动建立通信链路或发射辅助信号。在采集 CSI 信号时,无人机保持正常工作状态,对信号采集过程无感知。这里的“嗅探”指 CSI 采集设备感知无人机存在并获取其 CSI 信号的技术手段。

为实现上述轻量化定位方案,研究提出的无人机室内定位系统采用基于乐鑫 ESP32-S3 微控制器开发的 CSI 传感器,实现了传感器主动嗅探无人机 CSI 信号的过程。ESP32-S3 MCU 原生支持各种 WiFi 控制协议并且开放了 CSI 数据包的获取接口,并且可以通过官方原生的开发框架来实现对于 CSI 采集设备硬件底层的定制化的开发与操作。本文系统的数据采集依靠部署在目标区域内的多个 CSI 传感器,通过多个 CSI 传感器共同嗅探无人机本体上的 CSI 信号并发送 CSI 信号数据给上位机。为了实现上述功能,本文采用官方的 Smartconfig 技术实现各个设备的局域网无线连接,并通过 MQTT 协议实现对于 CSI 传感器的快速配置,配置 MAC 地址识别待探测采集的无人机设备。同时采用了 ICMP 技术向无人机发送一份 ICMP 回显请求报文,从而解析回显报文中携带的 CSI 数据包,并通过 UDP 协议和串口实现上位机与 CSI 传感器的 CSI 数据的传输。研究配置 CSI 的采集频率为 50 Hz。推送到上位机的 CSI 采样子载波,也即 ESP32-S3 获取的原始子载波的每个通道 CFR 频率响应由两个字节的带符号字符记录,可以表示为:

$$value = a + bj \quad (1)$$

其中,实际获取到的数据值第 1 个是虚部,第 2 个是实部,是 a 和 b 的复数形式,通过上位机可以进一步计算出 CSI 每一个子载波的幅值和相位信息。

1.3 基于 Inception 的无人机室内定位模型 SIRD

根据 1.2 节所述数据采集和标注,研究采集了大量带有二维坐标的 CSI 数据,为了实现这些 CSI 数据到二维坐标的映射,研究构建一个带有通道注意力机制与残差网络与深度卷积 InceptionNet 相结合的网络 SIRD 如图 2 所示。为适应一维的 CSI 信号训练与特征提取,本文基于 Inception 网络进行改进,使用 Conv1D 替换原网络中的卷积层,并将滤波器数量设置为 16,并防止太多滤波器数量造成过于复杂的计算。为了深度挖掘 CSI 信号特征,引入了残差连接和 (squeeze-and-excitation-block, SE-Block)。残差连接用于有效传递梯度和学习残差特征,而 SE-Block 则能自适应地调整通道特征的权重。为了构建更深的网络架构,将初始的架构级联重复 3 次。每个级联重复包括 Inception 模块、残差连接和 SE-Block。最后,在卷积网络架构之后添加了一个池化层和全连接层,用于输出最终的二维位置坐标。IR-1DCNN (inception-ResNet-1DCNN) 网络如图 3 所示,为了解决网络深度增加而导致的梯度消失的问题,在设计 Inception 模块时引入了残差连接。残差网络在前向传播过程中保留更多的信息,有效地解决梯度消失的问题。残差连接的表达式为:

$$H(X) = F(X) + X \quad (2)$$

式中: $F(X)$ 是残差映射,也是 InceptionNet 网络的输出; $H(X)$ 是期望得到的最终映射; X 是恒等映射。




图 2 SIRD 网络架构

Fig. 2 SIRD network architecture

如图 3 所示,IR-1DCNN 网络通过采用稀疏网络结构和不同尺度的卷积核与池化操作,在减少参数数量的同时捕捉多尺度特征,有效提升了网络表现能力并优化了计算资源利用。为适配多个 CSI 传感器融合的一维信号特征,将网络中的二维卷积核替换为一维卷积核,并在同一层中使用尺寸为 1×1 、 3×1 和 5×1 的 3 种卷积核。为减少上层输出特征数量, 3×1 和 5×1 卷积前添加 1×1 卷积层以合并通道并降低参数。卷积层后采用 Batch Normalization 加速训练并提升精度,激活函数为 ReLU,通过 L2 正则化防止过拟合。模型损失函数如下:

$$Loss = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_n - \hat{y}_n)^2} + \lambda \|\omega\| \quad (3)$$

式中: y_n 表示无人机真实的位置坐标; $\hat{y}_n$ 表示模型预测出的位置坐标; N 表示样本数量; λ 表示正则化系数; ω 是权重矩阵。




图 3 IR-1DCNN 网络

Fig. 3 IR-1DCNN Network

信号特征图通道间关系的问题,本文引入 SE-Block 通道注意力机制模块,自适应学习各通道重要性,增强 IR-1DCNN 网络对 CSI 信号的特征表达能力。该注意力机制包括两个关键步骤,压缩 (squeeze) 和激励 (excitation)。如图 4 所示,在 CSI 信号的卷积过程中,若干滤波器生成一个维度为 $[h, w, c]$ 的特征图。在 Squeeze 操作中,通过全局平均池化将全局空间信息压缩为一个通道描述符,生成通道统计信息,公式如下:

$$Z_c = F_{sq}(u_c) = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w u_c(i, j) \quad (4)$$

式中: Z_c 代表 CSI 卷积特征图中第 c 通道的全局信息; $F_{sq}(\cdot)$ 指的是 Squeeze 功能的函数表示; h 和 w 分别是 CSI 特征图中需要压缩的维度; $u_c(i, j)$ 指的是在第 c 个通道位置为 (i, j) 处的 CSI 特征图单元的值; $1/h \times w$ 指的是全局平均池化步骤,用于计算通道描述符的标准化因子。经过 squeeze 操作后,CSI 特征图的形状从 $[h, w, c]$ 变为 $[1, 1, c]$ 。




图 4 SE 注意力机制模块

Fig. 4 SE-Block module

下一步是 Excitation 操作,该操作包含两个全连接层和一个 ReLU 激活层以及对应的 sigmoid 激活层,第 1 层如下:

$$s = F_{ex}(z, W) = \delta(W_1 \cdot z) \quad (5)$$

式中: s 是激活层后的输出向量; $F_{ex}(\cdot)$ 是 Excitation 函数表示; δ 是 ReLU 激活函数; W_1 是全连接层的权重矩阵。第 2 层每个重要通道权重表示为:

$$\sigma = \text{sigmoid}(W_2 \cdot s) \quad (6)$$

式中: σ 表示每个通道的重要性权重,即缩放因子; W_2 是第 2 个全连接层的权重矩阵。接下来,CSI 卷积通道的

为解决传统 Inception-ResNet 网络未充分考虑 CSI

重新标定可以通过下式执行:

$$\tilde{U}_c = F_{scale}(U_c, \sigma_c) = \sigma_c \cdot U_c \quad (7)$$

式(7)定义了如何应用每个通道的缩放因子 σ_c 。向量 σ 中的每个元素 σ_c 与原 CSI 特征图 U 对应通道的特征响应 U_c 逐元素相乘。得到标定后的输出 $\tilde{U}_c$ 。其中 $F_{scale}(\cdot)$ 是进行尺度调整的函数。

定位系统算法流程如图 5 所示,针对不同高度层 CSI 信号的特性,为无人机室内三维定位系统提出了一种分层训练和定位的方法,该方法提高了 SIRD 模型对二维坐标的预测精度,同时使得 SIRD 模型无需学习所有高度层下的过于庞大和复杂的数据。




图5 定位系统算法流程

Fig. 5 Positioning system algorithm flowchart

该方法可以分为训练和测试阶段。在训练阶段,CSI 幅值数据与无人机实时回传的 ToF 高度值相结合。根据高度值对无人机的 CSI 信号进行分层训练,训练完成后固化所有层的模型。在测试阶段,根据无人机在三维空间区域采集到的 CSI 数据,与无人机的 ToF 高度值进行匹配,送入训练固化后的不同高度层的模型中,进行无人机二维位置坐标的预测,将预测后的二维位置坐标与无人机本体的 ToF 高度值进行融合,计算得出了无人机在三维空间中的三维位置坐标。

2 实验结果与分析

2.1 实验环境与设置

为模拟配电站房巡检应用,整体实验环境的布局如图 6 所示,红色区域为实际使用的实验区域。实验区域内 3 枚 ESP32-S3 传感器采用三角形排列部署在离地高度 2.5 m 的同一天花板平面上,贴合配电站房室内空间的典型布局特征。无人机在红色框的区域内进行实验数据的采集,实际采集区域大小为 5 m×5 m 的定位地毯区域,与配电站房内巡检作业的核心活动范围相匹配。

在实验设置中(图 6),使用一台型号为 TL-XDR3010 的无线路由器进行局域网通讯链路的组建,其中 3 个



图6 实验环境

Fig. 6 Experimental environment

ESP32-S3 制作的 CSI 传感器通过一键配网连接至路由器 WiFi,无人机同样通过 WiFi 连接至路由器。上位机采用一台 PC (Intel Core i5-7300HQ CPU, 16RAM, NVIDIA GeForce GTX1050Ti GPU) 通过有线连接到路由器的 LAN 口进行组网,保证所有实验设备都处于同一个局域网内,可以相互通信,并搭配一套专用于深度学习的服务器 (Intel Core i7-6850K CPU, NVIDIA GeForce GTX 1080 Ti GPU, 64GB RAM), 为本文实验提供算力支撑。该无线网络的频段为 2.4 GHz,数据传输使用 UDP 协议,无人机的控制与数据流通过 Tello 无人机自定义的 API 接口进行传输。

2.2 数据采集与评价指标

实验区域实景如图 7 所示,上位机通过程序引导无人机到 5 m×5 m 实验区域内的 121 个红色格点处不同高度下,通过 3 个 CSI 传感器实时采集 CSI 信号,每个点采集完成 500 帧数据后移动至下一点进行采集,直至当前高度下所有点的数据采集完成。为了保证数据具有一定的时间泛化能力,连续采集 3 d,即每个点 1 500 帧作为训练数据。再分别采集一天的数据作为验证集,1 d 的数据作为测试集进行室内定位系统的性能分析。采集 0.75、1.05、1.35、1.65、1.95 m 的 5 个高度层作为本次实验的数据,覆盖配电站房内设备巡检所需的典型高度范围。

本文采用如下 4 个指标来评估回归网络的定位效




图 7 实验区域实景图

Fig. 7 Experimental area real view

果,假设有个 n 位置点,每个点的实际位置坐标为 (x, y) ,模型预测的结果为 $(\tilde{x}, \tilde{y})$,真实位置坐标的均值为 $(\bar{x}, \bar{y})$,则具体的评价指标如下。

1) 平均定位误差 (mean localization error, MLE) 计算实际坐标与预测坐标差值的绝对值的平均值,直接反映了定位误差的平均大小,是定位系统平均偏离真实位置的距离。公式如下:

$$MLE = \frac{1}{n} \sum_{i=1}^n (\|x_i - \tilde{x}_i\| + \|y_i - \tilde{y}_i\|) \quad (8)$$

2) 定位均方误差 (localization mean squared error, LMSE) 计算实际坐标与预测坐标差值平方的平均值。公式如下:

$$LMSE = \frac{1}{n} \sum_{i=1}^n ((x_i - \tilde{x}_i)^2 + (y_i - \tilde{y}_i)^2) \quad (9)$$

3) 定位误差的决定系数 (coefficient of determination, R^2) 用于评估模型对定位数据的拟合效果。公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n ((x_i - \tilde{x}_i)^2 + (y_i - \tilde{y}_i)^2)}{\sum_{i=1}^n ((x_i - \bar{x})^2 + (y_i - \bar{y})^2)} \quad (10)$$

4) 定位误差的累计分布函数 (cumulative distribution function, CDF) 描述了定位误差小于或等于某个值的概率。公式如下:

$$F(x) = P(X \leq x) \quad (11)$$

式中: $F(x)$ 是 CDF; $P(X \leq x)$ 表示定位误差小于或等于某个值 x 的概率。

2.3 SIRD 网络模型在不同高度层的定位结果

如表 1 所示,在 0.75、1.05、1.35、1.65 和 1.95 m 5 个高度层中,模型的 MLE 呈现与高度非线性格局的波动特征,其数值分别为 0.087 4、0.124 7、0.116 6、0.079 8、0.130 8 m。这是由于不同高度下,CSI 信号与地面、中层设备、天花板等反射面的交互程度差异显著,从而导致不同高度层 MLE 精度差异显著,综合所有高度层,平均 MLE 约为 0.107 9 m,表明模型在整体定位精度上的一致性。针对各层高度,LMSE 分别是 0.086 9、0.127 4、0.083 3、0.102 2、0.101 9 m,平均 LMSE 约为 0.100 3 m,

表明模型在定位精度方面具有较好的一致性和可靠性。各层次 R^2 分别为 0.962 2、0.944 3、0.962 4、0.956 1、0.955 9,平均 R^2 约为 0.956 2,表明模型对 CSI 数据的拟合效果较好。

表 1 不同高度层的定位误差结果
Table 1 Positioning error results for different altitude layers

高度层/m	MLE/m	LMSE/m	R^2
0.75	0.087 4	0.086 9	0.962 2
1.05	0.124 7	0.127 4	0.944 3
1.35	0.116 6	0.083 3	0.962 4
1.65	0.079 8	0.102 2	0.956 1
1.95	0.130 8	0.101 9	0.955 9

不同高度层的定位误差 CDF 如图 8 所示,每个高度层均有超过 90% 的定位误差都低于 0.5 m,超过 75% 的定位误差都低于 0.25 m。误差中位数也是衡量系统定位精度的一个重要指标,通过曲线可以看出误差中位数即 50% 定位误差出现的点均小于 0.125 m。并且 5 条不同高度层的曲线误差的分布基本一致,说明本文构建的模型对于基于 CSI 的无人机室内定位系统有着较好的定位效果。因此本研究后续实验中均采用 0.75 m 的高度层进行分析。




图 8 不同高度层的定位误差 CDF

Fig. 8 Positioning error CDF for different altitude layers

2.4 传感器数量对定位精度的影响

为了保证通信感知一体化系统都能正常运行,在 2.4 GHz 频段带宽有限的情况下,本文测试发现当传感器数量 >3 时,CSI 传感器在上位机端的采集到的 CSI 数据频率会降低到 30 fps 左右,这种帧率丢失经过测试是因为信道堵塞导致的,使得已经采集到的 CSI 数据并未成功在上位机端被接收到。采用如表 2 所示 7 种传感器数量组合在 0.75 m 高度层下进行研究传感器数量对定位精度的影响。

表 2 传感器数量配置

Table 2 Configuration for the number of sensors	
传感器数量	传感器序号
1	传感器 0
	传感器 1
	传感器 2
2	传感器 0,1
	传感器 1,2
	传感器 0,2
3	传感器 0,1,2

不同传感器的定位误差 CDF 如图 9 所示,数量为 一个传感器时的 3 种组合时,有 80% 的误差均在 4.27 m 以内,此时室内定位系统处于失效状态。数量为两个传感器的 3 种组合时,有 80% 的误差处于 1.16 m 以内,相比于仅使用一个传感器时,定位系统的精度有了大幅度提高。数量为 3 个传感器时,有 90% 的定位误差在 0.5 m 以内,平均定位误差达到了 0.087 4 m。实验结果表明,在定位可以正常通信的状态下,提高传感器数量可以提高定位系统的精度。




图 9 不同传感器的定位误差 CDF

Fig. 9 Positioning error CDF for different sensors

不同传感器的误差分布箱线如图 10 所示,使用传感器 0 和传感器 1 进行定位时,模型的中位数较低但是四分位数间距(interquartile range,IQR)较大,这表示模型存在一定的预测准确度,但预测的不确定性较大。而传感器 2 中位误差值在 2~3 m,处于不可用状态,这是由于传感器 2 更加贴近图 7 中双层中空玻璃隔断与断桥铝合金框架结构显著加剧 CSI 信号传播的不确定性,导致定位精度劣化。增加传感器数量到两个 0 和 1、1 和 2、0 和 2 时,整体误差的分布降低,但稳定性依然不够。3 个传感器 0、1 和 2 同时使用时,箱体更窄且中位数较低,定位误差值数据的分布集中,模型的稳定性提升显著。

2.5 算法参数对定位精度的影响

探究模型参数对室内定位系统的定位精度的影响,




图 10 不同传感器的定位误差箱线图

Fig. 10 Boxplot of positioning error for different sensors

其中主要针对训练的批次大小(batch size)和优化器两个重要的算法参数进行实验,并对实验结果进行分析。实验均在 0.75 m 高度层进行。

如图 11 所示,实验分别测试了批次大小为 32、64、128、256、512、1 024 依次增大时,定位系统的定位误差及训练时间。批次大小从 32 增加到 64 时,误差值增大;批次大小增大到 128 时,误差值下降;批次大小为 256 时,误差值基本不变,但是训练时间减少了 35.12 min;批次大小为 512 和 1 024 时,误差值依次增大。




图 11 不同批次的定位误差和训练时间

Fig. 11 Positioning error and training time for different batch sizes

不同批次大小的定位误差的 CDF 图如图 12 所示,批次大小为 128 和 256 时的曲线略好于 32 和 64,远好于 512 和 1 024。因此,本研究后续实验选择模型的批次大小均为 256。

如表 3 所示,对比了 SGD、RMSprop、Nadam、Adamax 和 Adam 几种优化器的性能,结果显示使用 SGD 优化器的模型预测结果在 MLE、LMSE 等各项指标上都不佳,显示出相对其他优化器更差的性能,这可能与 SGD 优化器在处理非凸问题或应对局部最优解时可能存在效率不足




图 12 不同批次大小的定位误差 CDF

Fig. 12 Positioning error CDF for different batch sizes

有关。RMSprop 优化器比 SGD 优化器有更好的表现,表明 RMSprop 优化器适用于处理非平稳目标,解决了 SGD 优化器在非凸优化问题中的一些弱点。Nadam 优化器在效果方面比 SGD 优化器好一些,在 LMSE 和 MLE 上稍微高于 RMSprop、Adamax 和 Adam。Adamax 优化器是 Adam 的一种变体,用无穷范数代替二范数,表现良好。Adam 优化器相比其他的优化器,该优化器的表现最为突出,LMSE 值和 MLE 都是最低,分别为 0.086 9 和 0.087 4,同时 R^2 值最高,达到了 0.962 2。在研究的实验中,Adam 由于其具备更高的稳定性、更小的误差以及更小的超参数调整需求,被认为是更优的选择。

表 3 不同优化器定位误差结果

Table 3 Localization error results for different optimizers

优化器	MLE/m	LMSE/m	R^2
SGD	0.330 4	0.301 9	0.865 8
RMSprop	0.125 5	0.109 3	0.951 3
Nadam	0.146 4	0.159 9	0.927 8
Adamax	0.125 2	0.163 0	0.926 6
Adam	0.087 4	0.086 9	0.962 2

2.6 不同算法的性能对比

为对本文所提出的 SIRD 网络架构有效性进行验证,为确保实验结果的公平性与准确性,实验均在 0.75 m 高度层进行,同时实验研究选择了几种具有代表性的经典 CNN 网络进行对照。这些网络分别为 VGG-1DCNN、DenseNet-1DCNN、MobileNet-1DCNN、ResNet-1DCNN、ResNet-1DCNN,并且它们均已经过改造,以适配 CSI 传感器—维信号处理的要求。

不同算法的定位误差结果如图 13 所示,不同算法在对 CSI 信号进行特征提取时的表现在 MLE 指标上,本文提出算法的平均定位误差约为 0.08 m,与之相比,VGG-1DCNN 算法、DenseNet-1DCNN 算法及 MobileNet-1DCNN

算法的 MLE 分别为 0.27、0.21 和 0.21 m,展示出更高的平均误差。ResNet-1DCNN 及 InceptionNet-1DCNN 的 MLE 分别约为 0.16 和 0.15 m,体现出中等水平的误差。本研究提出的算法 LMSE 较低,证明所提算法在处理异常值时的鲁棒性较强。VGG-1DCNN 算法的 LMSE 为 0.26 m, DenseNet-1DCNN 和 MobileNet-1DCNN 的 LMSE 分别高达 0.29、0.31 m,证明了本研究提出的算法对个别高误差的处理优于其他算法。对于 R^2 ,构建的算法达到了 0.96 的高值,凸显其对数据变量解释能力的优势。这证实了该算法不仅误差小,而且预测值的变化与实际值的变化具有很强的相关性。综上所述,本研究提出的算法在这些关键性能指标上均表现卓越。




图 13 不同算法的定位误差结果

Fig. 13 Positioning error results for different algorithms

2.7 不同方法的性能与成本对比分析

不同方法的性能与成本对比如表 4 所示,本文无需无人机携带任何专用定位模块,只需若干个单价为 3 \$ 的 ESP32 传感器,便适用于室内低功耗场景且有高精度需求的室内无人机定位场景。相比于其他方法,本研究方法在保证高精度无人机室内定位的同时,无论是对无人机本身还是部署成本的要求都是最低的。

表 4 不同方法性能与成本对比

Table 4 Comparison of performance and cost between different methods

方法	无人机要求	部署设备	价格	适用场景
本文	无需特殊携带	若干 esp32	低	室内低功耗
文献[21]	无需特殊携带	3×SDR	高	室外
UWB	需要标签设备	3×UWB	高	室内
视觉	需要摄像头	若干摄像头	中	依赖光照

3 结 论

本文针对无人机室内定位高精度的需求,提出一种

基于 WiFi-CSI 嗅探技术的高精度室内三维定位系统,实现了无需无人机搭载专用定位模块的轻量化定位方案。针对 CSI 信号对室内定位的关键信息,构建了一种稀疏神经网络 SIRD,并创新性地采用分层训练的方式来实现对无人机二维坐标的精准预测,最后融合 ToF 传感器获取的高度信息实现无人机的三维定位。通过实验讨论了不同高度层、不同传感器数量、不同训练批次以及不同优化器对无人机定位精度的影响,并进行了不同机器学习算法的对比性实验。经实验表明,相较于现有经典卷积神经网络,所提算法 SIRD 能够更好的捕捉到 CSI 信号对无人机二维坐标的映射关系,在不同高度层下均展现出稳定的定位精度,具有高度一致性,其平均定位精度 MLE 仅为 0.1079 m,相比于现有无人机室内定位方法精度有显著提升,为无人机室内应用提供了低成本、高精度的解决方案。

参考文献

- [1] 汪杰,宋书林,秦宁宁. 信号指纹测量下双度量协同的室内定位方法[J]. 电子测量与仪器学报, 2024, 38(3):133-142.
WANG J, SONG SH L, QIN N N. Indoor localization method based on dual-metric coordination of signal fingerprint measurement [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (3): 133-142.
- [2] 薛敏,孙炜,余洪山,等. 基于 WiFi 指纹的层级学习室内定位模型[J]. 电子测量与仪器学报, 2021, 35(4):118-126.
XUE M, SUN W, YU H SH, et al. Hierarchical deep learning model to locate the mobile device via WiFi fingerprints [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(4):118-126.
- [3] YIN C Y, JIANG H, CHEN J. Overview of approaches for device heterogeneity management during indoor localization [M]. Machine Learning for Indoor Localization and Navigation. Cham:Springer International Publishing, 2023:259-282.
- [4] LUO R C, HSIAO T J. Indoor localization system based on hybrid Wi-Fi/BLE and hierarchical topological fingerprinting approach [J]. IEEE Transactions on Vehicular Technology, 2019, 68(11):10791-10806.
- [5] YIN C Y, JIANG H, CHEN J, et al. A high-adaptability indoor localization algorithm for large-scale BLE sensors[C]. 2021 40th Chinese Control Conference (CCC). IEEE, 2021:5691-5695.
- [6] 韦进文,谭龙明,郭志俊,等. 基于单天线视轴信号传播模型的 RFID 定位方法[J]. 电子测量技术, 2024, 47(6):8-13.
WEI J W, TAN L M, GUO ZH J, et al. RFID localization method based on single antenna boresight signal propagation model [J]. Electronic Measurement Technology, 2024, 47(6):8-13.
- [7] YIN C Y, CHEN J, MIAO X R, et al. Device-free human activity recognition with low-resolution infrared array sensor using long short-term memory neural network[J]. Sensors, 2021, 21(10):3551.
- [8] NEWAZ N T, HANADA E. A low-resolution infrared array for unobtrusive human activity recognition that preserves privacy[J]. Sensors, 2024, 24(3):926.
- [9] YIN C Y, MIAO X R, CHEN J, et al. Human activity recognition with low-resolution infrared array sensor using semi-supervised cross-domain neural networks for indoor environment[J]. IEEE Internet of Things Journal, 2023, 10(13):11761-11772.
- [10] 高闻霁,杨波,闵琳孜. 低分辨率红外感知系统的人体行为数据增强[J]. 仪器仪表学报, 2023, 44(1):163-171.
GAO W P, YANG B, MIN L Z. Human behavior data augmentation for the low-resolution infrared perception system [J]. Chinese Journal of Scientific Instrument, 2023, 44(1):163-171.
- [11] 陈丹,阴存翊,江灏,等. 基于 WiFi 交错信号与深度神经网络的室内人群数量检测方法[J]. 仪器仪表学报, 2019, 40(7):178-186.
CHEN D, YIN C Y, JIANG H, et al. Indoor crowd counting method based on WiFi crossover signals and deep neural network [J]. Chinese Journal of Scientific Instrument, 2019, 40(7):178-186.
- [12] 罗日,李燕君,金志昂,等. 融合 WiFi 与可穿戴惯导模块的室内定位方法[J]. 仪器仪表学报, 2022, 43(3):267-276.
LUO R, LI Y J, JIN ZH A, et al. An indoor positioning method integrating WiFi and wearable inertial navigation module [J]. Chinese Journal of Scientific Instrument, 2022, 43(3):267-276.
- [13] 江灏,阴存翊,崔文铮,等. 基于被动式 Wi-Fi 的实验室内人流密度监测系统的设计[J]. 实验技术与管理, 2021,38(3):272-277.
JIANG H, YIN C Y, CUI W ZH, et al. Design of

laboratory staff flow density monitoring system based on passive Wi-Fi [J]. *Experimental Technology and Management*, 2021, 38(3):272-277.

- [14] 李玉柏, 孙迅. 基于迁移学习提高 WiFi 室内定位中信道状态信息指纹库的鲁棒性[J]. *电子与信息学报*, 2023, 45(10):3657-3666.

LI Y B, SUN X. A highly robust indoor location algorithm using WiFi channel state information based on transfer learning reinforcement[J]. *Journal of Electronics & Information Technology*, 2023, 45(10):3657-3666.

- [15] YIN C Y, MIAO X R, CHEN J, et al. PowerSkel: A device-free framework using CSI signal for human skeleton estimation in power station[J]. *IEEE Internet of Things Journal*, 2024, 11(11):20165-20177.

- [16] KOTARU M, KATTI S. Position tracking for virtual reality using commodity WiFi [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017:68-78.

- [17] ZHANG L Y, GAO Q H, MA X R, et al. DeFi: Robust training-free device-free wireless localization with WiFi[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(9):8822-8831.

- [18] CHOI J S, LEE W H, LEE J H, et al. Deep learning based NLOS identification with commodity WLAN devices [J]. *IEEE Transactions on Vehicular Technology*, 2017, 67(4):3295-3303.

- [19] PIAO S X, BA Z J, SU L, et al. Automating CSI measurement with UAVs: From problem formulation to energy-optimal solution [C]. *IEEE INFOCOM 2019 - IEEE Conference on Computer Communications*. IEEE, 2019:2404-2412.

- [20] LU K I, CHIU C J, FENG K T, et al. Device-free CSI-based wireless localization for high precision drone landing applications [C]. *2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall)*. IEEE, 2019: 1-5.

- [21] NIE W, HAN Z C, LI Y, et al. UAV detection and localization based on multi-dimensional signal features[J]. *IEEE Sensors Journal*, 2021, 22(6):5150-5162.

作者简介



陈静, 2010 年于厦门大学获得学士学位, 2013 年于厦门大学获得硕士学位, 2016 年于厦门大学获得博士学位, 现为福州大学副教授, 主要研究方向为人体行为识别、室内定位技术、智能感知系统、机器学习。

E-mail: chengji@fzu.edu.cn

Chen Jing received her B. Sc. degree, M. Sc. degree and Ph. D. degree all from Xiamen University in 2008, 2011 and 2013, respectively. She is currently an associate professor at Fuzhou University. Her main research interests include human activity recognition, indoor positioning technology, intelligent sensing systems and machine learning.



阴存翊 (通信作者), 2016 年于成都信息工程大学获得学士学位, 2020 年于福州大学获得硕士学位, 2024 年于福州大学获得博士学位, 现为福州大学电力系统与装置产业研究院博士后研究员, 主要研究方向为无线感知、室内定位和机器学习。

E-mail: cunyi1125@gmail.com

Yin Cunyi (Corresponding author) received his B. Sc. degree from the School of Control Engineering, Chengdu University of Information Technology in 2016, and the M. Sc. and Ph. D. degrees from Fuzhou University in 2020 and 2024, respectively. He is currently a postdoctoral researcher at Power Equipment System Industry Research Institution of Fuzhou University. His main research interests include wireless sensing, indoor localization, and machine learning.



江灏, 2008 年于厦门大学获得学士学位, 2011 年于厦门大学获得硕士学位, 2013 年于厦门大学获得博士学位, 2013~2015 年新加坡南洋理工大学博士后研究员, 现为福州大学教授, 主要研究方向为无线传感网络、室内定位技术、智能感知系统、光传感器网络和机器学习。

E-mail: jiangh@fzu.edu.cn

Jiang Hao received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Xiamen University in 2008, 2011 and 2013, respectively. He was a postdoctoral researcher at Nanyang Technological University from 2013 to 2015. He is currently a professor at Fuzhou University. His main research interests include wireless sensor network, indoor positioning technology, intelligent sensing systems, optical sensor networks and machine learning.