

基于联邦学习的多源机会信号融合指纹定位^①

刘斌^{②*} 黎晨* 史秀纺^{③**}***

(* 浙江工业大学信息工程学院 杭州 310023)

(** 南京理工大学计算机科学与工程学院 南京 210094)

(*** 浙江三锋实业股份有限公司 金华 321300)

摘要 目前基于联邦学习的指纹定位研究主要基于单一信号,未能充分利用空间中广泛存在的无线信号。本文提出了一个基于联邦学习的多源机会信号融合指纹定位系统。首先,设计了一个基于两级注意力机制的深度学习模型融合多种机会信号,包括单个机会信号特征提取和多种机会信号融合,这个模型作为用户本地模型;然后,在模型聚合阶段,考虑到用户之间的数据异质性会降低模型训练性能,提出基于用户本地数据的采样密度和信息熵来确定本地模型在聚合过程中的权重;最后,基于实际采集的数据开展了实验验证,结果表明融合多种机会信号可以有效提高定位精度,并且在用户数据非独立同分布的场景下本文所提出的联邦学习聚合算法优于传统的联邦学习聚合算法。

关键词 指纹定位;机会信号;深度学习;注意力机制;联邦学习

近年来,基于位置的服务(location based services, LBS)经历了爆炸式增长并广泛应用到各个领域,LBS的关键信息是精确的位置,全球卫星导航系统(global navigation satellite systems, GNSS)^[1-3]是最常用的定位系统。由于卫星信号很容易受到地面障碍物的影响,GNSS在如室内区域、城市峡谷等复杂环境中表现不佳。随着无线技术的发展,现在的移动设备可以接收多种无线信号,如WiFi、蓝牙、4G/5G以及FM等。由于无线信号无处不在,基于无线信号的定位已经成为了基于GNSS定位的有效补充手段。这种能够随时捕捉的无线信号,又称为机会信号(signals of opportunity, SOP)^[4-6]。

基于单一SOP的定位方法已经得到了广泛研究,例如基于蜂窝网络、WiFi的定位。一方面,移动设备可以接收多种SOP,利用多种无线技术的互补优势,在定位中把多种SOP融合起来,可提升单一SOP定位的精度。另一方面,由于无线传输模型的

多样性,使用基于传输模型^[7-10]的传统方法来融合多种异质的SOP进行定位是非常困难的。而基于指纹^[11-13]的定位方法利用捕获的信号特征与无线地图中信号特征的相似性进行位置估计,对无线传输模型没有任何假设。因此,基于指纹的定位方法成为融合多种异质SOP的有效方法。

基于指纹的定位方法通常包括2个阶段:离线阶段和在线阶段。离线阶段通常在参考点收集无线信号的指纹来构建指纹库,其中指纹包括接收信号强度(received signal strength, RSS)和信道状态信息(channel state information, CSI)等;在线阶段通过比较实时收集的指纹和数据库中指纹的相似性来进行定位。早期基于指纹定位的方法主要依赖于轻量级匹配算法,如K最近邻(K nearest neighbor, KNN)^[14],这些方法很容易部署,但不能深入挖掘指纹的地理特征。近年来,深度学习已经成为了指纹定位最主要的方法。Wang等人^[15]提出了DeepFi,一种基于CSI

① 国家自然科学基金(62372414)和浙江省博士后科研项目择优资助项目。

② 男,1995年生,硕士生;研究方向:联邦学习,室内定位;E-mail: liubin_cool@qq.com。

③ 通信作者,E-mail: xiufangshi@zjut.edu.cn。

(收稿日期:2023-05-16)

指纹的深度学习定位系统。Purohit 等人^[16]利用 Lo-Ra 的 RSS 指纹基于深度学习实现了室内和室外定位。Abbas 等人^[17]提出了一种基于 WiFi 的 RSS 的深度学习室内指纹定位系统 WiDeep。Lei 等人^[12]提出了基于 FM 的 RSS 的深度学习辅助室内车辆定位系统 DeFLoc。现有的大部分文献中指纹只来自于单一类型无线信号,如何在指纹定位中融合多种异质的 SOP 仍是一个需要解决的问题。

早期的研究中,指纹采集都是现场采集,这种采集方法需要投入巨大的人力成本和时间成本。后来,众包^[18-20]被提出用于指纹采集,其基本思想将繁重指纹采集工作分配给手机用户,用户把采集的数据再传输到服务器中心。由于用户的位置数据通常与用户的个人行为习惯密切相关,在位置数据传输过程中存在隐私泄露风险。这样用户更倾向于把数据保存自己手中,从而形成数据孤岛。为了打破这种数据孤岛的局,文献[17]提出的联邦学习可以解决众包带来的隐私问题,旨在建立一个基于分布式数据集的联邦学习模型。在模型训练的过程中模型相关信息能够在各方之间交换,但数据不能,即每一个参与方拥有的数据都不会离开该参与方。

实际操作中,用户的行为习惯、设备的异构性、外界环境动态变化等复杂因素会导致用户间采集的数据具有较强的异质性,具有非独立同分布属性。在模型聚合时,数据异质性是不可忽略的因素。现有基于联邦学习的室内定位方法^[21-24]中,聚合算法大多采用传统的联邦平均算法^[25],这个算法仅仅根据用户数据总量占全局数据总量的比值来确定各个用户的贡献,即数据量越大,贡献越大,聚合过程中权重越大。然而,用户所拥有的数据总量并不能完全反映出用户本地模型的性能。文献[26]通过实验发现,实际位置和估计位置平均绝对误差(mean absolute error, MAE)和用户位置点的凸包面积成反比,从而提出了基于凸包面积的聚合算法。这个方法对于用户位置点的空间分布没有限制,而对于一些有物理约束的室内空间,往往存在大量不可达空间点。仅用位置点的凸包不能很好地反映用户位置点的实际覆盖面积,在模型聚合过程中,凸包面积并不能很好地反映用户本地模型的贡献。

因此,本文提出一种基于联邦学习的多源机会信号融合定位系统,主要贡献包括以下 2 个方面:(1)提出一种基于两级注意力机制的深度学习模型架构 SOPLoc。该架构融合多种 SOP 进行指纹定位:在第 1 级,采用通道注意力和空间注意力相结合用于提取单个 SOP 特征;在第 2 级,采用具有通道注意力和自适应感受野的模块来融合多个 SOP 特征。(2)提出一个基于采样密度和信息熵的联邦学习聚合算法 FedLOC-DIE。用户在参与模型聚合时,通过采样密度和信息熵来确定参与用户的权重。

1 系统描述

本文提出了一种基于联邦学习的多源机会信号融合定位系统,如图 1 所示,系统分为离线阶段和在线阶段。离线阶段包括指纹数据采集、多源机会信号融合模型搭建以及基于联邦学习的模型训练。在线阶段,用户基于实时采集的指纹数据和训练好的模型来进行位置估计。

考虑到 RSS 指纹对硬件要求较低且易于收集,本文采用机会信号的 RSS 作为指纹。特别地,考虑以下 2 种类型的 RSS 指纹。

(1) 基于接入点(access points, AP)的 RSS:假设采样区域共有 M 个 AP,第 i 个参考点的位置为 x_i ,在该点收集的所有 AP 的 RSS 指纹 $f_{AP}(x_i) = [p_{a_1}(x_i), \dots, p_{a_M}(x_i)]^T$,其中 $p_{a_k}(x_i)$ 表示在 x_i 处收集的第 k 个 AP 的 RSS 测量值。这种指纹类型适用于 WiFi、蓝牙等。

(2) 基于信道的 RSS:SOP 通常覆盖一定的频带,例如 FM 信号频带范围为 88 ~ 108 MHz。这个频带可以分成 N 个信道,通过扫描这些信道,可以获得每个信道的 RSS 值,从而构建基于信道的指纹为 $f_c(x_i) = [p_{c_1}(x_i), \dots, p_{c_N}(x_i)]^T$,其中 $p_{c_l}(x_i)$ 表示在位置 x_i 扫描的第 l 个信道的 RSS 测量值。这种指纹类型适用于 FM 信号、电视信号等。

在所提出的系统中,并不严格限于某种指纹或某种信号,即不同采集区域 SOP 可能不同,不同设备的相应指纹也可能不同。本文旨在提供一种通用的收集方法,可根据实际收到的 SOP 进行调整。基于收集的 SOP 指纹数据,构建基于两级注意力的深度

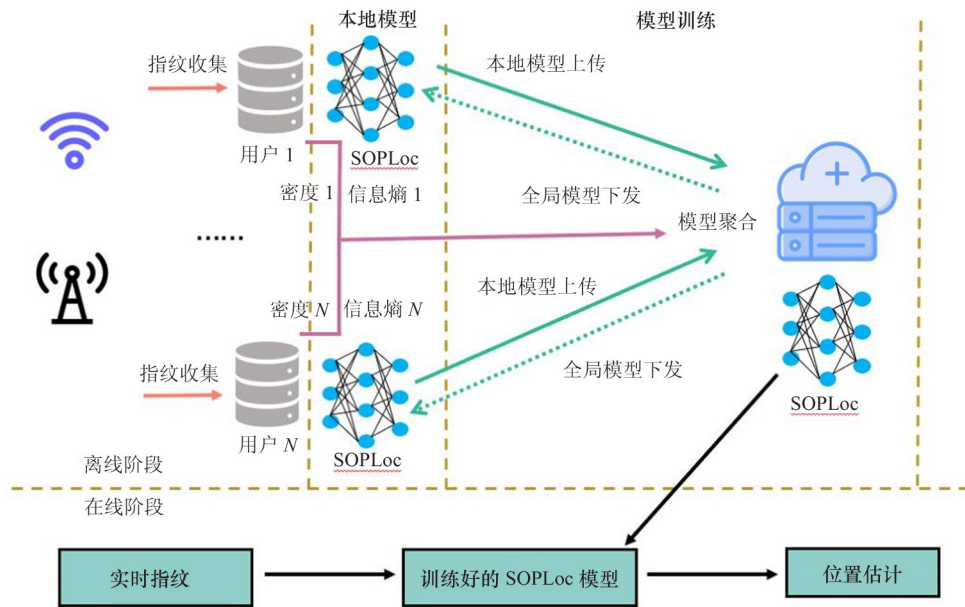


图 1 基于联邦学习的多源 SOP 融合指纹定位系统

学习模型 SOPLoc,以融合多源 SOP 指纹,并作为模型架构,进行基于联邦学习的分布式模型训练。定位模型构建及模型训练模块将分别在第 2 节和第 3 节进行详细介绍。

2 多源 SOP 融合架构 SOPLoc

本文设计了一个基于两级注意力机制的多源 SOP 融合架构 SOPLoc,如图 2 所示。第 1 阶段进行

单个 SOP 特征提取;第 2 阶段进行多个 SOP 的特征融合。

(1) 单个 SOP 特征提取。单个 SOP 的指纹可能具有非常大的尺寸,可以达到数百甚至数千。例如,在某个区域,扫描 WiFi 的 AP 总数可以超过 200 个,从而产生具有超过 200 个维度的 WiFi 指纹向量。而对于 FM 来说,一般采用基于信道的 RSS 指纹,指纹向量维度固定。不同 SOP 指纹的尺寸不同,需要进行特征提取,令不同 SOP 指纹的特征具有

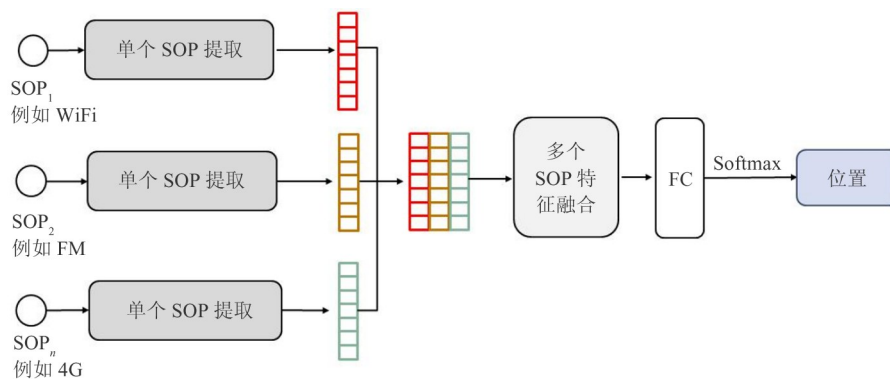


图 2 基于两级注意力机制的多源 SOP 融合架构

相同的维度,以便于特征融合。单个 SOP 指纹特征提取的流程如图 3 所示。

假设有 n 种 SOP,其指纹维度分别为 $\{d_1, d_2, \dots, d_n\}$ 。对于一个 d_i 维的 SOP 指纹向量,首先,使用

8 个不同的卷积核进行一维卷积处理,其大小为 7×1 。然后,在经过批归一化(bacth normalization, BN)和 ReLU 函数后,输出一个维度为 $(d_i/2) \times 8$ 的矩阵,通过 4 个带有 CBAM^[27]的一维残差模块进行依

次处理。与传统的残差网络相比,本文添加了一个轻量级的注意力模块 CBAM,以自适应地优化 2 个一维卷积层的输出特征。CBAM 包括 2 个注意力模块,即通道注意力模块和空间注意力模块,它们分别利用特征通道的关系和空间的关系。假设 CBAM 的输入是 $F_0 \in \mathbb{R}^{L \times c}$, 一维通道注意力向量是 $m_c \in \mathbb{R}^{1 \times c}$, 并且一维空间注意力向量是 $m_s \in \mathbb{R}^{L \times 1}$, CBAM 的整个过程如下所示。

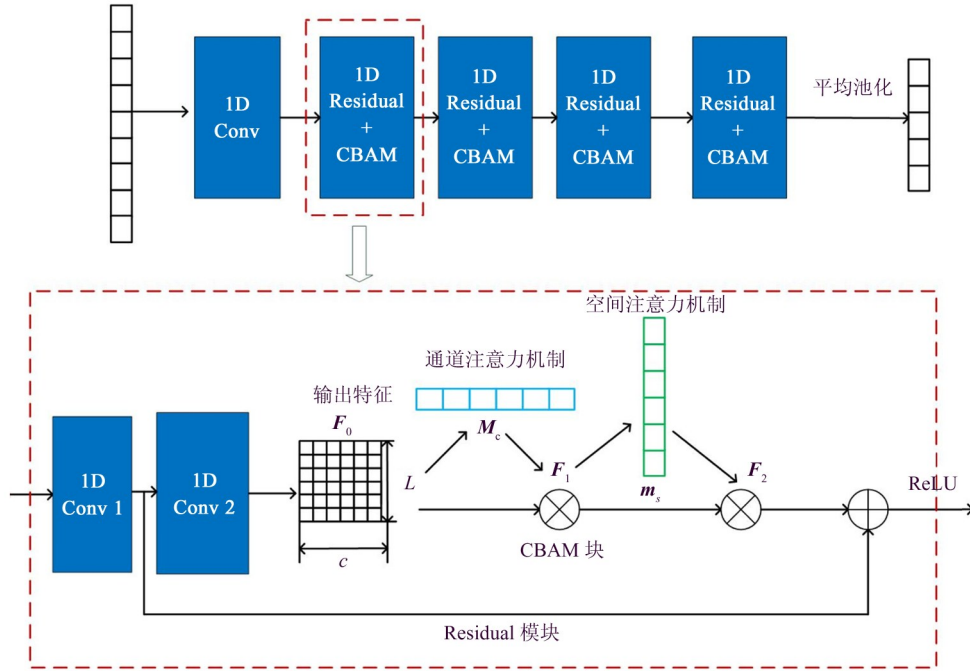


图 3 单个 SOP 特征提取的流程图

首先用对输入特征 F_0 分别进行平均池化 (*Avgpool*) 和最大池化 (*Maxpool*), 然后在经过多层感知器 (*MLP*) 将其得到的结果再进行聚合, 最后使用 Sigmoid 函数 σ 进一步处理。空间注意力向量的计算为

$$m_s(F_1) = \sigma(f_{7 \times 1}(Avgpool(F_1); Maxpool(F_1))) \quad (4)$$

式中:首先对输入特征 F_1 分别进行平均池化和最大池化, 将计算后的结果进行聚合后使用 7×1 的卷积核进行卷积运算 $f_{7 \times 1}$, 并使用 Sigmoid 函数 σ 进一步处理。CBAM 可以有效地学习特征图中每个元素的重要性, 并自适应地优化它们的权重, CBAM 的更多细节可参见文献[27]。在单个 SOP 特征提取过程中, CBAM 通道注意力自适应地优化不同卷积核

$$F_1 = m_c(F_0) \otimes F_0 \quad (1)$$

$$F_2 = m_s(F_1) \otimes F_1 \quad (2)$$

式中: \otimes 是按元素乘法, F_1 是通道注意力模块后的输出, F_2 是最终的输出。通道注意力向量的计算如式(3)所示。

$$m_c(F_0) = \sigma(MLP(Avgpool(F_0)) + MLP(Maxpool(F_0))) \quad (3)$$

的权重, CBAM 空间注意力自适应地优化不同 AP/信道的权重。图 3 中 4 个 1D Residual + CBAM 模块中卷积的数量分别为 8、16、32 和 64。最后, 通过平均池化, 输出的单个 SOP 指纹特征维度为 64 维。

(2) 多个 SOP 融合。在单个 SOP 特征提取之后, 将 n 个 SOP 的特征堆叠成维度为 $64 \times n$ 的矩阵 F , 将 F 作为特征融合模块的输入, 如图 4 所示。该模块基于 SK 模块^[28], 通过在卷积中使用不同的卷积核自适应地调整神经元的感受野。这个模块的完成分为 3 个阶段: 分离、融合和选择。每个阶段分别如下所述。

分离: 输入特征矩阵 $F \in \mathbb{R}^{64 \times n}$ 被 2 个并行的一维卷积分成 2 个分支, 其核大小分别为 3×1 和 5×1 。每个分支将通过 BN 和 ReLU 函数进行顺序处




图 4 多种 SOP 融合的流程

理,从而产生 2 个新的特征矩阵,分别为 $\hat{U} \in \mathbb{R}^{64 \times n}$ 和 $\tilde{U} \in \mathbb{R}^{64 \times n}$ 。

融合:通过逐元素求和来融合特征矩阵 \hat{U} 和 \tilde{U} , 即 $U = \hat{U} \oplus \tilde{U}$ 。然后采用通道注意机制来调整不同通道的权重。原始 SK 在通道注意力计算中仅采用平均池化,不能充分利用不同通道之间的相关性。本文对原始 SK 模型进行了改进,同时采用平均池化和最大池化。由于 n 的值通常小于 10,因此不需要减小通道尺寸。在池化层之后仅连接一个共享的全连接层 (fully connected, FC), 相应的结果如式(5)所示。

$$z = (\text{Avgpool}(U))W + (\text{Maxpool}(U))W \quad (5)$$

式中: $z \in \mathbb{R}^{1 \times n}$ 表示多个 SOP 的权重, $W \in \mathbb{R}^{n \times n}$ 是 FC 层中的权重矩阵。

选择:为了调整 2 个分支的权重,与 SK 相同,本文采用软注意机制来自适应地选择感受野。对于第 c 种 SOP,经分离后,2 个分支的特征权重分别为

$$a_c = \frac{e^{zA_c}}{e^{zA_c} + e^{zB_c}}, b_c = 1 - a_c \quad (6)$$

式中: $A \in \mathbb{R}^{n \times n}$ 和 $B \in \mathbb{R}^{n \times n}$ 表示 2 个 FC 层的权重矩阵, A_c 和 B_c 分别是 A 和 B 的第 c 列。假设特征融合模型的输出为 $V \in \mathbb{R}^{64 \times n}$, 则其第 c 列为

$$V_c = a_c \hat{U}_c + b_c \tilde{U}_c \quad (7)$$

式中: \hat{U}_c 和 \tilde{U}_c 分别为 \hat{U} 和 \tilde{U} 的第 c 列。

在多个 SOP 特征融合之后,FC 层和 Softmax 激活层将依次连接,输出为参考点的位置。

3 基于联邦学习的模型训练

3.1 模型训练框架

在离线训练阶段,如图 1 所示,联邦学习分为 4

个阶段:本地模型训练、本地模型参数上传、模型聚合和全局模型广播。

(1) 本地模型训练。每个客户端利用自己本地的数据,基于所提出的融合架构 SOPLoc,对本地模型进行训练。在训练阶段,将 MAE 作为总损失函数 $L(\omega)$, 其定义为

$$L(\omega) = \frac{1}{N_s} \frac{1}{N_L} \sum_j^{N_s} \sum_i^{N_L} \|\tilde{x}_{ij}(\omega) - x_i\| \quad (8)$$

式中: ω 是 SOPLoc 模型中的可训练参数集, $\tilde{x}_{ij}(\omega)$ 是使用样本 j 在第 i 个参考点处预测的位置, x_i 是第 i 个参考点的真实位置, $\|\cdot\|$ 表示 l_1 范数算子, N_s 和 N_L 分别是样本数和参考点数。深度模型参数训练使用 Adam 优化器来使损失函数达到最小。

(2) 本地模型参数上传。在 t 轮全局通信时,在第 u 个客户端将训练好的局部模型参数 ω'_u 上传到服务器端。

(3) 模型聚合。服务器端聚合所有客户端上传的模型参数来生成全局模型。假设一共有 N_c 个客户端参与训练,在第 t 轮,全局模型更新为

$$\omega' = \sum_{u=1}^{N_c} w_u \omega'_u \quad (9)$$

式中: w_u 为第 u 个客户端的本地模型在模型聚合中的权重。在传统的联邦学习聚合算法中,本地模型权重 w_u 一般基于客户端的数据量设置,如最常用的联邦平均算法^[25]。不同于传统方法,本文将对权重参数进行改进以优化聚合性能。具体将在第 3.2 节进行描述。

(4) 全局模型广播。服务器端将聚合后的全局模型 ω' 播给所有的客户端,进行下一轮的本地模型训练。

重复阶段(1)~(4),直到模型达到收敛。

3.2 聚合算法

由于用户行为习惯各异、设备异构、外界动态变

化等因素的影响,不同用户采集的数据存在差异,呈现非独立同分布的特点,导致每个客户端所训练出的模型性能也有所差异。传统的联邦平均聚合算法^[25]基于用户本地数据量并不能充分反映出模型的性能。在本文考虑的指纹定位问题中,用户本地数据的空间分布和数据量都会影响模型聚合效果。基于以上考虑,本文在本地模型聚合权重中引入了采样密度和信息熵,采样密度用来描述用户数据中位置点的分布,信息熵用来描述用户位置点样本的分布。

3.2.1 采样密度

假设第 u 个用户的位置点来自 D 个区域,第 $a(a = 1, 2, \dots, D)$ 个区域的面积为 S_{ud} , 则用户 u 的本地数据中位置点的空间密度 ρ_u 为

$$\rho_u = \frac{P_u}{\sum_{a=1}^D S_{ud}} \quad (10)$$

式中: P_u 是位置点的个数。

位置点的空间密度反映了用户数据的采样密度,采样密度越高,定位精度越高。因此采样密度较高的客户端在模型聚合时应该获得较高的权重。

3.2.2 信息熵

在实际执行中,每个客户端的数据中每个位置点的样本数会不同,导致样本数据的不均衡,模型在实时预测时会侧重于拥有较多样本的位置点。为了描述这种不均衡性,本文引入了信息熵 IE_u 这一概念,计算公式为

$$IE_u = - \sum_{i=1}^{P_u} \frac{N_{ui}}{N_u} \log_2 \frac{N_{ui}}{N_u} \quad (11)$$

式中: IE_u 表示第 u 个用户的信息熵, N_{ui} 表示第 u 个客户端在第 $i(i = 1, 2, \dots, P_u)$ 个位置点采集的样本数量。当样本数符合均匀分布时,信息熵最大。

3.2.3 基于采样密度与信息熵的聚合权重

基于以上分析,在联邦学习全局模型聚合过程中,本文在聚合权重中同时考虑采样密度及样本数据的信息熵。

首先分别将客户端的采样密度和样本数据信息熵进行归一化,即:

$$DTI_u = \frac{\rho_u}{\sum_{u=1}^{N_c} \rho_u} \quad (12)$$

$$IEW_u = \frac{IE_u}{\sum_{u=1}^{N_c} IE_u} \quad (13)$$

对于第 u 个客户端,其本地模型的权重为

$$w_u = \frac{DTI_u + IEW_u}{2} \quad (14)$$

基于以上改进,本文提出的联邦学习算法描述为 FedLoc-DIE,如算法 1 所示。不同于传统联邦学习算法,客户端除了向服务器端上传模型参数外,还要上传采样密度与样本信息熵。待所有用户上传完后,服务器端基于客户端的采样密度与样本信息熵计算每个客户端在模型聚合过程中的权重。

算法 1 基于密度和信息熵的联邦学习算法 FedLoc-DIE

输入:本地迭代次数 E , 通信次数 T , 学习率 η , 本地数据库 D_u

输出: ω^t

1. for $u = 1, 2, \dots, N_c$ do
 2. 客户端 u 统计出 D_u 的位置点个数 P_u , 每个位置点所持有的样本 N_{ui} 以及总样本数 N_u ;
 3. 计算出每个区域的面积 S_{ud} ;
 4. 根据式(10)和(11)计算出 ρ_u 以及 IE_u ;
将 ρ_u 、 IE_u 上传到服务器端;
 5. end for
 6. 初始化: $t = 1$
 7. while $t \leq T$ do
 8. //并行运行,本地模型训练过程
 9. for $u = 1, 2, \dots, N_c$ do
 10. $\omega \leftarrow \omega^{t-1}$
 11. for $e = 1, 2, \dots, E$ do
 12. $\omega \leftarrow \omega - \eta \nabla L_u(\omega)$
 13. $\omega'_u \leftarrow \omega$
 14. end for
 15. 上传参数 ω'_u ;
 16. end for
 17. //模型聚合
 18. 根据式(14)来计算每个客户端的权重;
 19. 全局模型更新为:
 20. $\omega^t = \sum_{u=1}^{N_c} w_u \omega'_u$
 21. 服务器端广播模型参数 ω^t
 22. $t = t + 1$
 23. end while
-

4 实验结果及分析

4.1 数据集介绍

本文基于无线电设备 USRP N210 搭建了多源

机会信号采集的软硬件平台,采集设备如图 5 所示。实验场地在浙江工业大学信息工程学院,总共有 5 个楼层,每个楼层结构基本相同,如图 6 所示,可以分为 A 区、B 区、C 区、D 区,其面积分别是 $40.0\text{ m} \times 2.4\text{ m}$ 、 $48.0\text{ m} \times 2.4\text{ m}$ 、 $40.0\text{ m} \times 2.4\text{ m}$ 和 $100.0\text{ m} \times 2.4\text{ m}$ 。参考点位于这 4 个区域走廊上,在 A 区域共有 26 个参考点,一楼 B 区域共有 29 个参考点,二楼




图 5 数据采集平台

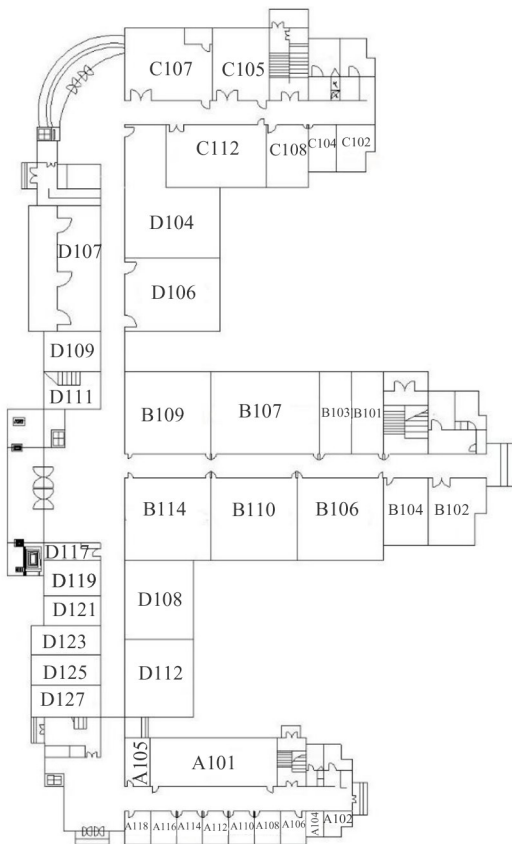


图 6 实验场地平面图

到五楼 B 区域共有 30 个点,C 区域有 26 个参考点, D 区域共有 62 个参考点。在每个参考点收集的 SOP 包括 4G、5G、FM、DTMB 以及 WiFi。FM 的频带范围是 $88 \sim 108\text{ MHz}$,4G 的频带范围 $1\ 885 \sim 1\ 915\text{ MHz}$ 、 $2\ 330 \sim 2\ 370\text{ MHz}$,5G 的频带范围是 $2\ 515 \sim 2\ 615\text{ MHz}$ 、 $4\ 800 \sim 4\ 900\text{ MHz}$ 。将 FM 的带宽设置为 100 kHz ,4G 的带宽设置为 15 kHz ,5G 的带宽设置为 30 kHz ,DTMB 的带宽设置为 8 MHz 。最终,FM 划分的频道数为 200,DTMB 划分的频道数为 56,4G 划分的频道数为 4 666,5G 划分的频道数是 6 666。WiFi 指纹由安装在智能手机中的第三方应用程序进行收集。参考点总数为 719,样本数为 11 360。

本文将基于以上数据集进行离线模型训练和在线定位。为了验证本文所提的多源 SOP 融合架构 SOPLoc 和联邦学习算法 FedLoc-DIE,本文将选择部分数据进行测试和验证。在线定位主要基于训练好的模型利用测试集评估位置估计误差。在线定位阶段中,模型输出层将提供每个参考点的预测概率,采用参考点位置的加权和作为最终位置估计,即

$$\bar{x} = \sum_{i=1}^{N_L} p(x_i) x_i \quad (15)$$

式中: $p(x_i)$ 表示移动设备位于 x_i 的概率, N_L 是参考点的数量。在位置 i 的样本 j 位置估计误差 $error_{ij}$ 描述为

$$error_{ij} = \|x_{ij} - \bar{x}\|_2 \quad (16)$$

4.2 SOPLoc 性能评估

本文采用三楼 B 区域的数据对 SOPLoc 的性能进行评估,选择的 SOP 包括 4G、FM 以及 WiFi,在每个参考点有 100 个样本。采用了一对一交叉验证,将 29 个参考点的样本作为训练数据,将 1 个点的样本用作测试数据。本文所提出的模型与以下方法进行了比较:(1)无注意力机制的 ResNet,其中未采用 CBAM 模块和改进的 SK 模块;(2) ResNet + CBAM,其中在单个 SOP 特征提取中仅采用 CBAM 模块;(3) ResNet + SK,其中在多个 SOP 特征融合中仅采用 SK 模块;(4) ResNet + CBAM + SK,其中 CBAM 模块用于单个 SOP 特征提取,SK 模块用于多个 SOP 特征融合;(5) ResNet + CBAM + 通道,其中 CBAM 模块用于单个 SOP 特征提取,CBAM 模块中的通道注意力用于多个 SOP 特征融合;(6) KNN,其中选择

最近的 3 个参考点,并将这 3 个参考点位置的平均值作为位置估计值。不同模型的定位误差的累积分布(cumulative distribution function, CDF)如图 7 所示,由图可知,深度学习的方法要优于 KNN。其中本文所提出的模型定位性能最好,89% 的点的定位误差小于 4.00 m。而基于 KNN 的方法,58% 的点的定位误差小于 4.00 m。表 1 给出了不同方法的平均定位误差和标准差。其平均定位误差 *MeanError* 计算如下:

$$MeanError = \frac{1}{N_s} \frac{1}{N_L} \sum_{i=1}^{N_L} \sum_{j=1}^{N_s} error_{ij} \quad (17)$$

本文提出的 SOPLoc 的平均定位误差达到了 2.12 m,标准差为 1.69 m。KNN 定位性能最差,平均定位误差达到了 4.16 m,标准差为 3.30 m。

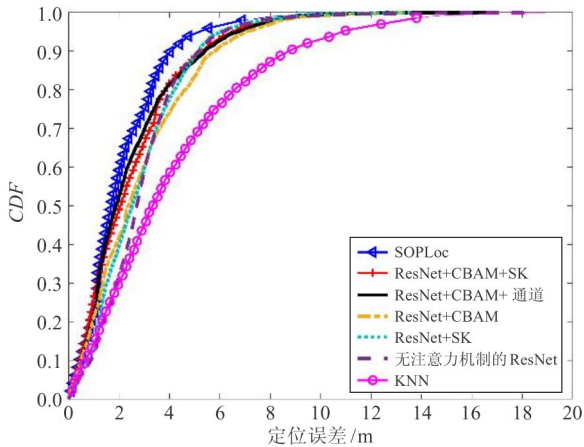


图 7 不同模型的定位误差 CDF

表 1 不同模型的平均定位误差和标准差 m

算法	均值	标准差
SOPLoc	2.12	1.69
ResNet + CBAM + SK	2.52	2.04
ResNet + CBAM + channel	2.45	1.88
ResNet + CBAM	2.86	2.36
ResNet + SK	2.79	2.52
无注意力机制的 ResNet	2.91	2.70
KNN	4.16	3.33

图 8 比较了使用多种 SOP 和使用单个 SOP 的定位误差,单个 SOP 由于不需要多种 SOP 融合,选用的模型为 ResNet + CBAM。基于 4G、FM、WiFi 的定位误差小于 4.00 m 的点所占的比例分别约为 73%、

64%、61%;而多种 SOP 融合的定位误差小于 4.00 m 的点约为 89%,精度提升效果明显,表明了融合多种 SOP 可以有效地提高定位精度。表 2 给出了单个 SOP 和融合多种 SOP 的平均定位误差和标准差。从表中能明显看出,多种 SOP 融合的平均定位误差和标准差小于单个 SOP 的定位误差和标准差,再次表明融合多个 SOP 可以有效地减小定位误差。




图 8 不同 SOP 定位误差 CDF

表 2 不同 SOP 平均定位误差和标准差 m

信号	均值	标准差
FM + 4G + WiFi	2.12	1.69
FM	3.56	3.17
4G	4.15	3.25
WiFi	2.95	2.30

4.3 FedLoc-DIE 的性能评估

为了验证 FedLoc-DIE 的性能,本文基于一楼采集的 4G、5G、FM 指纹数据进行模型训练。将数据样本以 2 种方式分配给不同用户作为用户的本地数据,这 2 种分配方式分别是独立同分布和非独立同分布。本文将 2 种常用的联邦学习算法 Fedavg^[25] 和 Fedprox^[29] 作为对比算法来验证所提联邦学习算法 FedLoc-DIE 的性能。

4.3.1 独立同分布场景

用户之间的数据符合独立同分布,即每个用户在每个参考点都拥有数据,在每个参考点所拥有的样本数保持一致。本文把数据平均分给 6 个用户,每个用户在每个位置点所拥有的样本数量相同。图 9 给出了独立同分布场景下不同联邦学习算法的

损失值随着全局通信轮数的变化曲线,图 10 给出了基于不同联邦学习训练方法和集中式训练后输出的估计位置误差 CDF。从图 10 可以看出,集中式训练出的模型和分布式训练出的模型所得到的定位误差的 CDF 基本上是接近的,说明在用户数据符合独立同分布的情况下,联邦学习训练出的模型性能和集中式训练出模型的性能是接近的,将联邦学习用于用户数据符合独立同分布场景是可行的。其中, FedLoc-DIE 算法在该场景下计算出的权重与 Fedavg 和 Fedprox 计算出的权重是一样的,因此定位误差也基本相同。

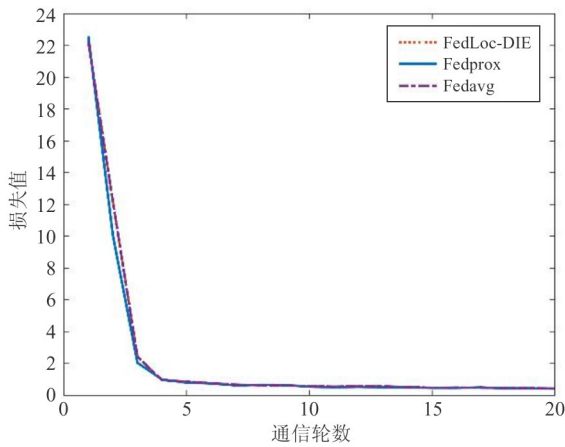


图 9 在独立同分布场景下损失值的变化曲线




图 10 在独立同分布场景下定位误差 CDF

4.3.2 非独立同分布场景

非独立同分布场景下,用户拥有的位置点不存在任何交叉。其中 5 个用户随机分配了 24 个位置点的样本,剩余 1 个用户分配了 23 个位置点样本。同时,为了模拟用户样本分布不平衡,第 1 个用户和

第 2 个用户一半的点有 8 个样本,一半的点有 12 个样本;第 3 个用户和第 4 个用户一半的点有 5 个样本,一半的点有 15 个;第 5 个用户和第 6 个用户一半的点有 2 个样本,一半的点有 18 个点。图 11 是在非独立同分布场景下 Fedavg、Fedprox 和 FedLoc-DIE 随着全局通信轮数增加等的损失值的变化曲线。图 12 是在非独立同分布场景下,测试集输入到分布式训练和集中式训练所得到模型所输出的位置估计误差的 CDF。从图中可知本文提出的 FedLoc-DIE 算法优于 Fedavg 和 Fedprox 算法。

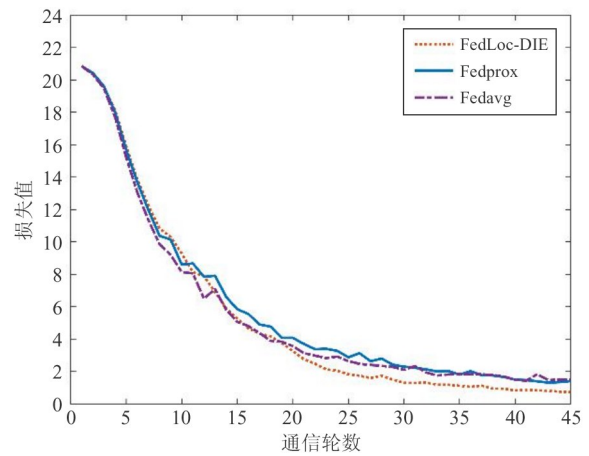


图 11 非独立同分布场景下损失值的变化曲线

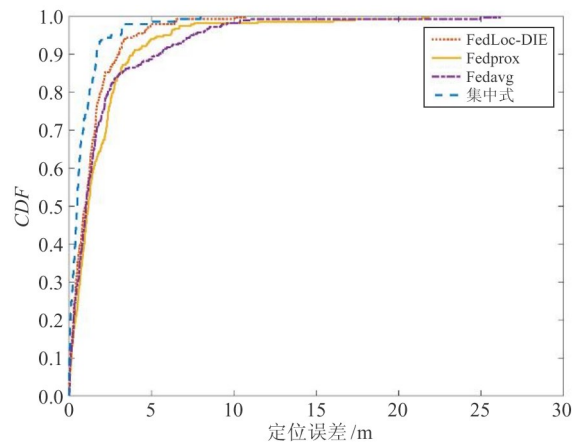


图 12 非独立同分布场景下定位误差 CDF

4.3.3 消融实验

为了进一步评估聚合权重的影响,本节进行了消融实验,分别为:(1)仅用样本信息熵;(2)仅用采样密度;(3)融合信息熵和采样密度,来确定参与模型聚合的权重。不同情况下的定位误差的

CDF,如图 13 所示。从图中可以看出,采样密度对模型性能的影响要大于样本信息熵对模型性能的影响。而融合样本信息熵和采样密度作为聚合权重进行模型训练,其定位性能最好。




图 13 单一指标和多个指标定位误差 CDF

5 结论

多源 SOP 指纹融合可大幅提升单一信号指纹定位的精度。考虑到利用众包来收集指纹,用户的隐私无法得到保护,对此,本文提出了基于联邦学习的多源 SOP 融合指纹定位系统,设计了基于两级注意力机制的融合架构 SOPLoc,将 SOPLoc 模型作为用户本地模型,以联邦学习的范式进行模型训练,在模型聚合过程中引入了采样密度和样本信息熵来确定用户的权重。实验结果表明,本文提出方法的定位精度要优于单一信号指纹定位精度,所提联邦学习算法训练性能要优于对比的传统方法。

参考文献

- [1] MAAREF M, KASSAS Z M. Ground vehicle navigation in GNSS-challenged environments using signals of opportunity and a closed-loop map-matching approach [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(7):2723-2738.
- [2] LI X, GE M, DAI X, et al. Accuracy and reliability of multi-GNSS real-time precise positioning: GPS, GLO-NASS, BeiDou, and Galileo [J]. *Journal of Geodesy*, 2015, 89(6):607-635.
- [3] LIU J, CAI B G, WANG J. Cooperative localization of connected vehicles; integrating GNSS with DSRC using a robust cubature Kalman filter [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 18(8):2111-2125.
- [4] PEI L, ZHANG M, ZOU D, et al. A survey of crowd sensing opportunistic signals for indoor localization [J]. *Mobile Information Systems*, 2016, 2016:1-16.
- [5] YANG C, SOLOVIEV A. Mobile positioning with signals of opportunity in urban and urban canyon environments [C]//2020 IEEE/ION Position, Location and Navigation Symposium. Portland, USA: IEEE, 2020:1043-1059.
- [6] 黄高明,景桐,田威. 机会信号导航综述 [J]. *控制与决策*, 2019, 34(6):1121-1131.
- [7] SHI X, MAO G, YANG Z, et al. Localization algorithm design and performance analysis in probabilistic LOS/NLOS environment [C]//2016 IEEE International Conference on Communications. Kuala Lumpur, Malaysia: IEEE, 2016: 1-6.
- [8] SHI X, MAO G, ANDERSON B D, et al. Robust localization using range measurements with unknown and bounded errors [J]. *IEEE Transactions on Wireless Communications*, 2017, 16(6):4065-4078.
- [9] YANG G, SHI X, FENG L, et al. Cedar: a cost-effective crowdsensing system for detecting and localizing drones [J]. *IEEE Transactions on Mobile Computing*, 2019, 19(9):2028-2043.
- [10] WANG Q, DUAN Z, LI F. Semidefinite programming for wireless cooperative localization using biased RSS measurements [J]. *IEEE Communications Letters*, 2022, 26(6):1278-1282.
- [11] TAO Y, ZHAO L. Fingerprint localization with adaptive area search [J]. *IEEE Communications Letters*, 2020, 24(7):1446-1450.
- [12] LEI J, HUANG J, KONG L, et al. DeFLoc: deep learning assisted indoor vehicle localization atop FM fingerprint map [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(10):19795-19806.
- [13] WU Z, WU X, LONG Y. Multi-level federated graph learning and self-attention based personalized Wi-Fi indoor fingerprint localization [J]. *IEEE Communications Letters*, 2022, 26(8):1794-1798.
- [14] XU Z, HUANG B, JIA B, et al. A boundary aware WiFi localization scheme based on UMAP and KNN [J]. *IEEE Communications Letters*, 2022, 26(8):1789-1793.
- [15] 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.
- [16] PUROHIT J, WANG X, MAO S, et al. Fingerprinting-based indoor and outdoor localization with LoRa and deep learning [C]//2020 IEEE Global Communications Conference. Taipei, China: IEEE, 2020:1-6.
- [17] ABBAS M, ELHAMSHARY M, RIZK H, et al. WiDeep:

- WiFi-based accurate and robust indoor localization system using deep learning [C] // 2019 IEEE International Conference on Pervasive Computing and Communications. Kyoto, Japan: IEEE, 2019:1-10.
- [18] LASHKARI B, REZAZADEH J, FARAHBAKHS R, et al. Crowdsourcing and sensing for indoor localization in IoT: a review [J]. IEEE Sensors Journal, 2018,19(7):2408-2434.
- [19] YANG S, DESSAI P, VERMA M, et al. FreeLoc: calibration-free crowdsourced indoor localization [C] // 2013 Proceedings IEEE INFOCOM. Turin, Italy: IEEE, 2013:2481-2489.
- [20] WU C, YANG Z, LIU Y. Smartphones based crowdsourcing for indoor localization [J]. IEEE Transactions on Mobile Computing, 2014,14(2):444-457.
- [21] CIFTLER B S, ALBASEER A, LASLA N, et al. Federated learning for RSS fingerprint-based localization: a privacy-preserving crowdsourcing method [C] // 2020 International Wireless Communications and Mobile Computing. Limassol, Cyprus: IEEE, 2020:2112-2117.
- [22] LIU Y, LI H, XIAO J, et al. FLoc: fingerprint-based indoor localization system under a federated learning updating framework [C] // 2019 15th International Conference on Mobile Ad-Hoc and Sensor Networks. Shenzhen, China: IEEE, 2019:113-118.
- [23] WU Z, WU X, LONG Y. Prediction based semi-supervised online personalized federated learning for indoor localization [J]. IEEE Sensors Journal, 2022,22(11):10640-10654.
- [24] YIN F, LIN Z, KONG Q, et al. FedLoc: federated learning framework for data-driven cooperative localization and location data processing [J]. IEEE Open Journal of Signal Processing, 2020,1:187-215.
- [25] MCMAHAN B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data [C] // Artificial Intelligence and Statistics. Lauderdale, USA: PMLR, 2017:1273-1282.
- [26] CHENG X, MA C, LI J, et al. Federated learning-based localization with heterogeneous fingerprint database [J]. IEEE Wireless Communications Letters, 2022,11(7):1364-1368.
- [27] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the European conference on computer vision. Munich, Germany: EC-CV, 2018:3-19.
- [28] LI X, WANG W, HU X, et al. Selective kernel networks [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019:510-519.
- [29] LI T, SAHU A K, ZAHEER M, et al. Federated optimization in heterogeneous networks [J]. Proceedings of Machine Learning and Systems, 2020,2:429-450.

Federated learning based fingerprinting localization fusing multiple signals of opportunity

LIU Bin^{*}, LI Chen^{*}, SHI Xiufang^{** ***}

(^{*} College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

(^{**} School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094)

(^{***} Zhejiang Safun Industrial Co., Ltd., Jinhua 321300)

Abstract

Existing researches on federated learning based fingerprinting localization are mainly based on single kind of wireless signal, which have not taken full advantage of the ubiquitous wireless signals. This paper proposes a federated learning based fingerprinting localization system fusing multiple signals of opportunity (SOP). First, a two-level attention based deep learning model is designed to fuse multiple SOP. Specifically, it includes single SOP feature extraction and multiple SOP feature fusion, and this model serves as a local model for users. Then, during the model aggregation process, considering that the heterogeneity of data among users will reduce model training performance, the weight of each local model is determined based on the sampling density and information entropy of the user's local data. Finally, the experimental verification is carried out based on actual collection of data. Extensive experimental results show that the fusion of multiple SOPs can effectively improve the localization accuracy and the proposed federation learning aggregation algorithm outperforms the traditional algorithms in scenarios where the user data are not independent identically distributed.

Key words: fingerprinting localization, signals of opportunity, deep learning, attention, federated learning