基于联邦学习的分层三维室内定位

Yaya Etiabi[1], Wafa Njima[2],和 El Mehdi Amhoud[1]

[1]计算机科学学院，穆罕默德六世理工大学，本盖里尔，摩洛哥[2]ISEP，巴黎高等电子学院，75006 巴黎，法国 电子邮箱： {yaya.etiabi, elmehdi.amhoud}@um6p.ma, wafa.njima@isep.fr

arXiv:2303.00450v1 [eess.SP] 1 Mar 2023

摘要——**室内环境中互联设备的激增，为大量室内应用提供了发展空间，而定位服务是其中的关键支撑。然而，随着隐私问题和资源约束的出现，设计大多数应用所需的高准确率定位系统变得更具挑战性。为应对上述挑战，本文提出了一种利用深度神经网络进行分层三维室内定位的联邦学习（FL）框架。首先，我们强调在多建筑多楼层室内环境中利用楼层与建筑物之间层级关系的重要性。随后，我们提出一种联邦学习框架，用于训练所设计的分层模型。性能评估表明，采用分层学习方案后，与非分层方法相比，定位准确率最高可提升24.06%。此外，建筑物和楼层预测准确率分别达到99.90%和94.87%。借助所提出的联邦学习框架，我们能够实现与集中式训练近似的性能特征，而定位误差仅增加7.69%。此外，所开展的可扩展性研究表明，随着更多设备加入训练，联邦学习系统的准确率会得到提升。**

关键词—**联邦学习、层次学习、室内定位、RSSI指纹定位、无线网络。**

I. 引言

基于位置的服务（LBS）是物联网（IoT）应用的关键组成部分，因为大多数物联网设备都依赖位置依赖数据运行。事实上，应急服务、资产跟踪、物流规划、电子营销和社交网络等大多数物联网应用，都高度依赖位置信息才能正常运行。随着物联网网络以前所未有的速度扩展，我们需要投入更多精力，设计合适且准确的定位系统，利用新一代通信系统带来的新机遇，以弥补全球定位系统（GPS）的不足。全球定位系统不仅能耗高、部署成本高，还面临环境方面的挑战，尤其是在室内环境中。与室外定位相比， [1], 室内定位确实是最具挑战性的定位问题，通常通过到达时间（ToA）、到达时间差（TDoA）、到达角（AoA）和接收信号强度指示（RSSI）等无线信号参数进行处理 [2]。由于成本低且易于获取，RSSI是室内外定位中应用最广泛的信号属性，正如 [3]所指出的。传统的室内定位系统基于几何方法（即三边测量法、多边测量法和三角测量法）以及基于指纹的方法。然而，几何方法容易受到多径传播效应的严重影响，而RSSI指纹定位则存在固有问题，这是由室内环境动态多变以及无线设备不稳定所导致的。这会使定位准确率随时间推移而急剧下降，因此指纹采集需要大量校准工作量 [4]。此外，随着互联设备数量增加，指纹定位方法会受到诸多信道损伤的影响，例如信号间干扰，以及室内环境中大量反射表面造成的非视距（NLOS）传播，进而导致较大的定位误差。

由于难以开发出能够捕捉这些室内信道损伤的鲁棒模型，研究人员正转向采用机器学习（ML）技术实现基于数据的定位。这类方法不需要经验模型，而是依赖于离线构建的数据集，以捕捉室内环境中的变化。事实上，正如 [5],[6],所展示的那样，机器学习算法，尤其是深度神经网络（DNN），被用于解决传统方法的上述缺陷。研究结果表明，机器学习是实现物联网定位的一项极具前景的技术，因为它能够构建鲁棒、可扩展的定位系统，在提高准确率的同时保持较低的在线复杂度 [7]。然而，前述研究提出的深度神经网络架构并未考虑多建筑多楼层室内环境中定位任务的层次结构特性，而本文将对此进行探讨。 [8] 和 [9] 的作者已指出，在采用深度神经网络算法执行室内定位任务时，考虑其层次性十分重要。

然而，基于机器学习的定位解决方案需要将物联网设备中的数据收集到中央服务器，这会导致与服务器进行大量数据交换、引发隐私问题，并且高度依赖服务器。需要注意的是，除了带宽需求高之外，这种方法还假设服务器值得信任。在实际应用中，数据分散在各个物联网设备上，且目标是保护隐私，因此这可能会带来问题。为此，人们开发了联邦学习（FL），以节省带宽并保护用户数据的隐私。事实上，凭借默认保护隐私和优化带宽的显著优势，联邦学习在定位问题中正变得越来越受青睐。

尤其是在涉及资源受限的物联网设备的无线通信中，这种优势更为突出。在 [10], 中，作者展示了使用此类算法进行室内定位的突出优势，但迄今为止，真正解决这一问题的研究工作仍然寥寥无几。[11] 中的作者利用一种通信效率更高的联邦学习方案——联邦蒸馏，解决了室内定位问题。在这种方案中，只交换模型输出，而其维度通常远小于模型大小。不过，所提出的方法仅限于位置估计，并未提供有关建筑物或楼层的信息。

本工作的主要重点是首先设计一种分层学习方案，用于在多建筑物多楼层室内环境中联合预测建筑物、楼层和精确的二维坐标。随后，考虑到物联网设备的资源约束，我们提出了一种联邦学习框架来训练所提出的分层模型，从而实现一种通信高效、协作式且保护隐私的室内定位方案。本工作的主要贡献可概括如下：

- 我们开发了一种新颖的三维室内定位系统，采用全新的 DNN 架构，将多建筑多楼层室内环境中室内定位任务的层次结构特性纳入其中。我们提出了一个单一的分层 DNN 模型，用于联合预测建筑物、楼层以及用户的精确二维坐标。随后，我们使用公开的实验性室内定位数据集验证了结果，使我们的方案更适用于室内物联网应用。
- 我们提出对所提出的架构进行联邦训练，以保护物联网设备的位置数据隐私，并节省无线基础设施的带宽。因此，我们为物联网应用提供了一种协作式、带宽优化且保护隐私的室内定位方案。
- 鉴于物联网网络呈指数级增长，我们研究所提出的联邦学习框架的可扩展性，并分析整体学习过程中涉及的不同无线传输。

本文其余部分安排如下：第二节介绍针对定位问题的层次化学习方案，第三节介绍所提出的联邦学习框架。第四节对框架进行性能评估与分析，最后在第五节总结全文。

II. 系统模型与问题表述

在多建筑多楼层室内环境中，目标的位置可以通过分层方式递归确定：首先识别建筑物，然后识别楼层，最后确定目标的精细位置。因此，我们可以更精确地确定目标的位置。设 $\mathcal{B} = \{b\}_{b=1,\ 2,\ 3,\ ...,\ \mathcal{N}_b}$，$\mathcal{F} = \{f\}_{f=1,\ 2,\ 3,\ ...,\ \mathcal{N}_f}$，以及 $\mathcal{L} = \{(x_l,\ y_l)\}_{x_0,\ y_0 \le x_l,\ y_l \le x_0+L,\ y_0+W}$ 分别为构成室内环境的建筑物集合、楼层集合和位置集合。L 和 W 分别对应楼层的最大长度和最大宽度。请注意，位置集合 $\mathcal{L}$ 构成连续空间，其中包含 $x_0 < x_l < x_0+L$ 和 $y_0 < y_l < y_0+W$，$(x_0,\ y_0)$ 为参考坐标。设 $\mathcal{R}_l$ 为在位置 l 处从检测到的接入点（AP）集合接收的 RSSI 集合，记为 AP_l。$\mathcal{R}_f$ 为在楼层 f 检测到的接入点接收的 RSSI 集合，记为 AP_f。$\mathcal{R}_b$ 为在建筑物 b 内部检测到的接入点接收的 RSSI 集合，记为 AP_b。上述参数定义如下：

$$\begin{cases} \mathcal{R}_l = \{RSSI_n^l\}, & AP_l = \{AP_n\}, & n = 1,2,3,...,M_l \\ \mathcal{R}_f = \bigcup_l \mathcal{R}_l, & AP_f = \bigcup_l AP_l, & (x_l,y_l) \in \mathcal{F}_f \\ \mathcal{R}_b = \bigcup_f \mathcal{R}_f, & AP_b = \bigcup_f AP_f, & f \in \mathcal{B}_b \end{cases}, \quad (1)$$

其中，M_l 表示在位置 l检测到的接入点数量。室内环境的层次结构特性可用于缩小目标定位过程中的搜索空间。为确定目标的位置 θ，将采集 RSSI 测量值，$\theta = (b^*,\ f^*,\ l^* = [x_\theta, y_\theta])$。该位置接收到的 RSSI 集合为 $\mathcal{R}_\theta$，相应的集合为 AP_θ。

由于 $\mathcal{R}_\theta$ 与各建筑物（$\mathcal{R}_b,\ b \in \mathcal{B}$）的相似度能够更清晰地区分不同建筑物，因此我们可以根据最佳相似度度量，从整个室内环境切换到选定的某栋建筑物，从而缩小搜索空间。具体而言，为了评估相似度，我们采用欧几里得距离，并据此将 $d(\mathcal{R}_\theta,\ \mathcal{B}_b)$记为 $\mathcal{R}_\theta$ 中的测量值与所有测量值 $\mathcal{R}_b \in \mathcal{B}_b$ 之间的平均距离，其定义如下：

$$d(\mathcal{R}_\theta, \mathcal{B}_b) = \frac{1}{|\mathcal{R}_b|} \sum_{n=1}^{|\mathcal{R}_b|} \|\mathcal{R}_\theta - \mathcal{R}_b^n\|_2 . \quad (2)$$

基于计算得到的距离，相应的建筑物由 $b^* = \arg\min_b \{d(\mathcal{R}_\theta,\ \mathcal{B}_b)\}$ 给出。下一步的搜索空间缩减是楼层识别。类似地，目标所在的楼层由以下方程确定：

$$f^* = \arg\min_f \frac{1}{|\mathcal{R}_f|} \sum_{n=1}^{|\mathcal{R}_f|} \left\|\mathcal{R}_\theta - \mathcal{R}_f^n\right\|_2, \text{subject to } \mathcal{R}_f \in \mathcal{R}_{b^*} \quad (3)$$

在此阶段，已估计出目标所在的建筑物和楼层，因此我们可以继续预测其精细位置（$x_\theta,\ y_\theta$）。我们考虑使用一个回归模型，将给定建筑物中给定楼层的 RSSI 测量值拟合到相应的位置，如下所示：$\mathbf{l} = \mathbf{X}_{(b,f)}\beta_{(b,f)} + \epsilon_{(b,f)}$，其中 $\mathbf{l} = (x_l,\ y_l)$，$\mathbf{X}_{(b,f)} = \mathcal{R}_f \in \mathcal{R}_b$ 为属于建筑物 b 的楼层 f 上的 RSSI观测值，$\beta_{(b,f)}$和 $\epsilon_{(b,f)}$ 为相应的回归模型参数。随后，预测的目标位置 $\mathbf{l}^*$ 由$\mathbf{l}^* = \mathcal{R}_\theta\beta_{(b^*,f^*)} + \epsilon_{(b^*,f^*)}$. 确定。最后，我们得到目标的完整位置估计 $\theta^* = (b^*,\ f^*,\ \mathbf{l}^* = [x_{\theta^*}, y_{\theta^*}])$。

可以看出，这种分层方法过于复杂，难以通过经验方法实现，因为除了需要依次采用两种类 KNN 方法进行建筑物和楼层识别外，还需要为每层建立一个线性回归模型，从而导致解决方案高度复杂。

由于会遭遇维度灾难，因此需要数据驱动的神经网络逼近器。为此，我们设计了一种深度神经网络（DNN），旨在自动提取 RSSI 数据集中的分层特性，并一次性预测室内环境中任意目标设备的三维定位。此外，考虑到隐私问题以及众包收集 RSSI 数据所带来的带宽限制，我们提出了一种联邦学习框架，利用分布在物联网设备上的 RSSI 数据协作训练所设计的 DNN。

III. 用于室内定位的联邦学习框架

A. 数据预处理

我们使用文献 [12]中介绍的数据集，该数据集由部署在校园室内环境中的不同接入点采集的 RSSI 测量值构成。由于测量期间并非所有接入点都在覆盖范围内，因此将缺失的 RSSI 读数设为 100 dBm。在预处理过程中，我们首先删除了在整个测量活动期间均未被采集到的所有接入点，即所有值均缺失的列。这样一来，指纹维度减少至 465 个接入点，而原始数据集包含 520 个接入点。为进一步降低指纹维度，我们设定了接入点的可见性阈值 $\tau = 0.98$，即若某个接入点在超过 98% 的测量中未被采集到，则其对数据集丰富度的贡献并不显著，因此可以将其删除。此步骤完成后，我们仅保留 248 个接入点。

选定接入点后，我们通过将缺失的 RSSI 替换为一个更合适的值来处理缺失数据。该值取为整体最小 RSSI 读数减去 1 dBm，记作min_{RSSI}，得到 min_{RSSI}=-105 dBm（即 -104 dBm - 1 dBm）。随后，我们采用文献 [13],中详述的方法，将 RSSI 测量值转换为幂表示，定义如下：

$$powed\,(RSSI_i) = \left(\frac{RSSI_i - min_{RSSI}}{-min_{RSSI}} \right)^{\beta}, \qquad (4)$$

其中，β 设置为数学指数 e。此步骤得到数据的正值归一化表示，有利于提升深度神经网络的性能。

B. 所提出的 DNN 架构与联邦训练

如图 1a 所示，我们设计了一种深度学习模型，即多层感知机（MLP），以接收信号强度指示作为单一输入，并输出完整坐标，即建筑物、楼层和细粒度二维位置，同时利用室内定位的层次结构特性。我们将该模型命名为 H-MLP，即层次化 MLP。需要注意的是，这个单一网络被配置为多任务网络，因为它同时执行两个分类任务（建筑物识别和楼层识别）以及一个回归任务（位置坐标估计）。深度神经网络可表示为由表示网络权重的$\mathbf{W}$参数化的逼近函数 $F_{\mathbf{W}}(\cdot)$。因此，任何位置 $\hat{}\theta$ 都可以通过 $\theta = F_{\mathbf{W}}(\mathcal{R}_\theta)$ 估计。该模型的训练

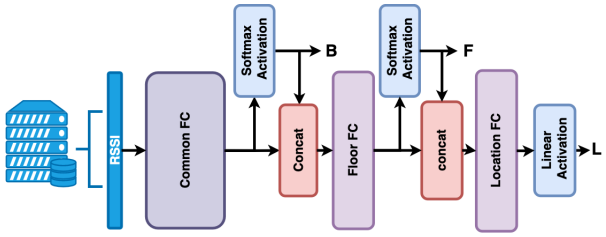

（a）所提出的分层 MLP 模型（H-MLP）

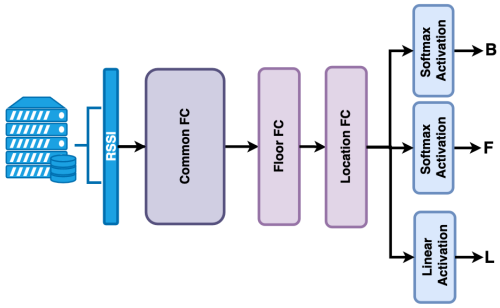

（b）紧凑基准 MLP 模型

图 1：三维室内定位系统模型。

旨在确定最优权重$\mathbf{W}^*$，通过最小化全局损失来完成。该全局损失包含分别对应三个任务的损失。因此，全局损失可表示为：

$$L_{\mathbf{W}}(\hat{\theta}, \theta) = \frac{1}{\sum_{u \in \{b,f,l\}} \alpha_u} \sum_{u \in \{b,f,l\}} \alpha_u L^u_{\mathbf{W}}(\hat{\theta}_u, \theta_u), \qquad (5)$$

其中，α_u 是表示每个损失对全局损失贡献的权重。

为展示室内定位的层次结构特性及利用这一特性的重要性，我们设计了第二种 DNN 架构，通过压缩所有层，直接预测由建筑物 ID、楼层 ID 和二维位置 (x,y) 组成的所有输出，如图 1b 所示。

我们的目标是使用部署在无线网络中的物联网设备采集的不同接收信号强度指示数据，训练前文定义的深度神经网络模型。在不与中央服务器共享数据以保护隐私并节省带宽的情况下，我们采用一种称为联邦学习的迭代式协作训练过程：每个物联网设备使用其本地数据集参与全局模型的训练，整个协作过程由参数服务器统筹。具体而言，参数服务器负责定义全局模型，并在每次训练迭代或通信轮次中选择参与者（也称为客户端）。整个联邦模型训练过程可由算法 1 描述。

C. 无线通信网络

在这一部分，我们重点关注联邦学习系统的通信方面。关于客户端与服务器之间交换的性质，下行传输和上行传输将分别讨论。

算法 1： 用于定位的联邦学习

输入： $\{\mathcal{D}_c\}$； /* 客户端的 RSSI数据集 */
输入： $\{\alpha_u\}$； /* 输出的 权重 */
输出： $\{W\}$; /* 已训练 模型 参数 */

服务器初始化()
  设置 W_0，以及 $r \leftarrow 0$；
当 未收敛且满足 $r < max\ com\ \underline{r}ounds$ 时
  服务器广播 W_r；
  对于每个 客户端 $c \in \{1, 2, \ldots, C\}$ 执行
    /* 并行执行 */
    客户端本地训练 $(\mathcal{D}_c, \alpha_u, W_r)$
      使用 W_r 更新本地模型；
      使用以下内容训练本地模型
      $\mathbf{W}^c_{r,k+1} = \mathbf{W}^c_{r,k} - \mu \nabla F_{\mathbf{W}^c_{r,k}}(\mathcal{B}_c)$;
      客户端上传 W^c_r；
  end
  服务器全局更新 $(\{W^c_r, |\mathcal{D}_c|\})$
    使用以下内容更新全局模型
    $\mathbf{W}_{r+1} = \frac{1}{\sum_c |\mathcal{D}_c|} \sum_c |\mathcal{D}_c| \mathbf{W}^c_r$；
  $r \leftarrow r + 1$；
结束

1）下行通信：在下行链路中，服务器将全局模型广播给所有客户端，因此与上行链路相比，通信受到的限制较少。实际上，在第 r^{th} 个通信轮次中，服务器通过下行链路向所有客户端广播，因此客户端c从服务器接收到的信号为$\mathbf{y}^c_r = \mathbf{g}^c_r \mathbf{x}_r + \mathbf{z}^c_r$，其中$\mathbf{x}_r$是服务器发送的信号，$T_D$为使用的下行信道数量；$\mathbf{g}^c_r$是服务器到客户端 c 的准静态衰落信道；$\mathbf{z}^c_r$是一个由独立同分布（i.i.d.）高斯分量构成的噪声向量。注意，服务器受到功率约束$E\left[\|\mathbf{x}_r\|_2^2\right]/T_D \leq \mathcal{P}_D$ [14]。基于这些假设，并依据香农容量，服务器在下行链路中采用数字传输时，在 r^{th} 个通信轮次内向所有客户端广播的比特数为$B_{D,r} = \min_c \left(T_D \log_2\left(1 + |\mathbf{g}^c_r|^2 \mathcal{P}_D\right)\right)$，其中 $|\mathbf{g}^c_r|^2$ 是服务器到客户端的信道增益，并假设服务器已知信道$\mathbf{g}^c_r$。因此，服务器无法向客户端传输参数比特大小超过此下行链路容量$B_{D,r}$的模型，至少在不采用任何压缩方案的情况下是如此。

2）上行通信：在上行链路中，联邦学习客户端共享一个高斯多址信道，其方程表示为 $\mathbf{y}_r = \sum_{c=1}^{C} \mathbf{h}^c_r \mathbf{x}^c_r + \mathbf{z}_r$，其中，$\mathbf{y}_r$ 是服务器接收到的信号，$\mathbf{x}^c_r$ 是客户端 c 向服务器传输的 $T_U \times 1$ 信号，T_U 表示所使用的上行信道数量；$\mathbf{h}^c_r$ 是从客户端 c 到服务器的准静态衰落信道；$\mathbf{z}_r$是 $T_U \times 1$ 噪声向量，其元素独立同分布，服从 (0，1) 分布。注意，联邦学习客户端各自受到功率

表 I：图 1 所示配置下的全局模型参数。

公共层		构建层	
隐藏层	256-128		
丢弃层	0.3	输出激活函数	Softmax
激活函数	ReLU	输出权重 α_b	0.1
批归一化层			
底层		**位置层**	
隐藏层	128	隐藏层	128
丢弃层	0.1	丢弃层	0.1
批归一化层		批归一化层	
输出激活函数	Softmax	输出激活函数	线性
输出权重α_f	0.3	输出权重 α_l	0.6

约束 $E\left[\|\mathbf{x}^c_r\|_2^2\right]/T_U \leq \mathcal{P}_U$。在如 [14], 所示的传统数字系统中，上行链路容量由各客户端平均共享，导致带宽限制，从而限制每个客户端可传输的比特数。事实上，根据香农容量[15], ，任意客户端 c 每次传输的最大比特数由 $B^c_{U,\ r} = {}^{T_U}_{C} \log_2(1 + C\,|\mathbf{h}^c_r|^2\,\mathcal{P}_U)$ 给出，其中，$|\mathbf{h}^c_r|^2$ 是客户端 c 到服务器的信道增益。

IV. 性能评估

我们使用 [12] 中报告的 UJIIndoorLoc 数据库来评估我们的模型性能。UJIIndoorLoc 数据库包含两个数据集：一个包含 19937 条 RSSI 记录的训练集，以及一个包含 1111 条记录的验证集，这些记录采集于训练集采集 4 个月后，以模拟真实世界的使用场景。为了与使用相同数据库的最先进算法进行公平比较，我们按照 90:10 的比例将训练数据划分为训练集和测试集，用于训练和测试我们的模型，并使用验证集结合基准分析来衡量模型性能。我们通过建筑物预测准确率（B-ACC）、楼层预测准确率（F-ACC）、也称为总体准确率（ACC）的成功率，以及平均距离误差（MDE）来评估模型性能。在评估中，我们可以区分两种 MDE：二维平均距离误差（2D-MDE）是指在建筑物和楼层均预测正确时的平均定位误差，其定义如下：

$$\text{2D-MDE} = \frac{1}{N}\sum_{i=1}^{N}\left[\delta\left(\mathcal{B}_i, \hat{\mathcal{B}}_i\right) \cdot \delta\left(\mathcal{F}_i, \hat{\mathcal{F}}_i\right) \cdot \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2}\right], \quad (6)$$

其中，当 $a = b$ 时为 $\delta(a, b) = 1$，否则为 0。三维MDE 是常用的 MDE，用于表示全局定位误差，其定义如下：

$$\text{3D-MDE} = \frac{1}{N}\sum_{i=1}^{N}\sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2}, \quad (7)$$

其中，(x, y) 和 $(\hat{x}, \hat{y})$ 分别是真实值和预测坐标。

A. H-MLP 模型的评估

我们的模型全局配置如表 I 所示。请注意，为了进行公平比较，我们对 H-MLP 和 MLP 模型采用相同的配置。我们使用批量大小为

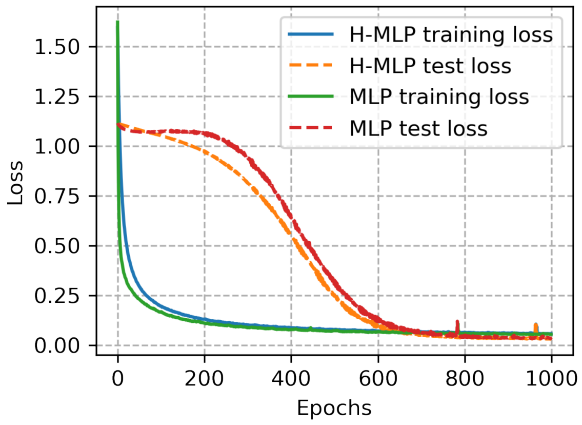

图2：模型训练性能。

表II：分层模型性能评估。

模型	B-ACC	F-ACC	ACC	二维平均距离误差	三维MDE
H-MLP	99.85%	99.55%	99.55%	5.84米	6.20米
MLP	99.85%	99.55%	99.40%	7.69米	8.12米

表 III：UJIndoorLoc 验证数据上的基准测试。

模型	B-ACC(%)	F-ACC(%)	二维平均距离误差(m)
所提出的 H-多层感知机	99.90	94.87	8.80
HADNN[9]	100	93.15	14.93
CNNLoc[16]	99.27	96.03	18.10
可扩展深度神经网络[7]	99.82	91.21	9.29

64，采用 *Adam* 优化器，学习率为 5×10^{-4}，结果如图2所示。我们可以观察到，所提出的架构（H-MLP）和基线模型（MLP）在训练接近 600 个训练轮次时均已收敛，而评估结果表明，H-MLP 提升了定位系统的性能。如表II所示，与基线 MLP 模型相比，H-MLP 将定位准确率最高提升了 24.06%。

此外，我们使用表 III 中所示的相同数据集，将模型与最先进的深度学习方法进行比较，从而对模型进行了基准分析。可以看出，我们的方法在建筑物预测准确率、楼层预测准确率和定位误差之间实现了更好的权衡。我们的方法优于包括可扩展深度神经网络[7]和 CNNLoc[16]在内的最先进方法。

B. 联邦学习框架的评估

在本部分中，我们以联邦方式训练前文定义的模型（H-MLP）。为此，我们保持模型配置不变，并搭建了一个联邦学习系统，其配置如表 IV 所示。联邦学习系统的学习曲线和准确率分别如图 3a 和图 3b 所示，可以看出，模型在 20 个通信轮次后开始收敛。因此，如图 3c 所示，联邦学习客户端能够协作训练出一个统一模型，其性能与集中式训练相近；例如，定位

表 IV：联邦学习仿真设置。

参数	**描述**	**值**
优化器	模型优化器	Adam
η	学习率	0.0005
β_1, β_2	指数衰减率	0。1、0。99
$\mathcal{C}$	客户端数量	5
B	批量大小	64
E	每次本地迭代的轮数	10
$\mathcal{R}$	通信轮次	100

误差仅增加了 7.69%。此外，我们研究了所提出的联邦学习框架的可扩展性，以及通信预算，重点关注上行链路。请注意，联邦学习框架的通信资源优化和客户端选择策略不在本文讨论范围内，将留待未来研究。为此，图4展示了参与联邦训练的客户端数量不断增加时的定位性能。可以观察到，随着客户端数量增加，成功率有所提高，定位误差也有所改善。事实上，参与的客户端越多，模型接触到的数据就越多，因此性能会持续提升。

然而，定位性能的这些提升是以通信负载增加为代价的，尤其是在上行传输方面。如图5所示，我们考虑了比特分辨率 R=32，因此单个设备传输的比特数为 $W \times R$，其中 W 为模型参数总数。事实上，无论参与的客户端数量如何，下行链路基本保持不变，因为每次广播的都是同一个模型。另一方面，在上行链路中，均分频谱的参与者越多，所需的带宽就越大。

V. 结论

在本文中，我们首先指出了利用室内定位层次化特性的优势，随后提出了一个用于实现所提模型的联邦学习框架。性能分析表明，我们提出的模型能够改善定位误差，降幅最高达24.06%；此外，在建筑物和楼层命中率方面也实现了良好的折中，其结果分别为99.90%和94.87%。此外，我们还证明，虽然通信负载会增加，但随着参与者数量的增加，基于联邦学习的定位系统性能会得到提升。然而，鉴于参与训练的物联网设备通信资源有限，可通过无线网络传输的深度神经网络架构以及参与者数量都存在一定限制。因此，未来有必要进一步研究联邦学习环境下的通信资源管理问题。

参考文献

[1] Y. Etiabi、M. Jouhari 和 E.-M.Amhoud，“用于 LoRa 网络定位的扩频因子和接收信号强度指示：一种深度强化学习方法”，*ArXiv*，第 abs/2205.11428 卷，2022 年。

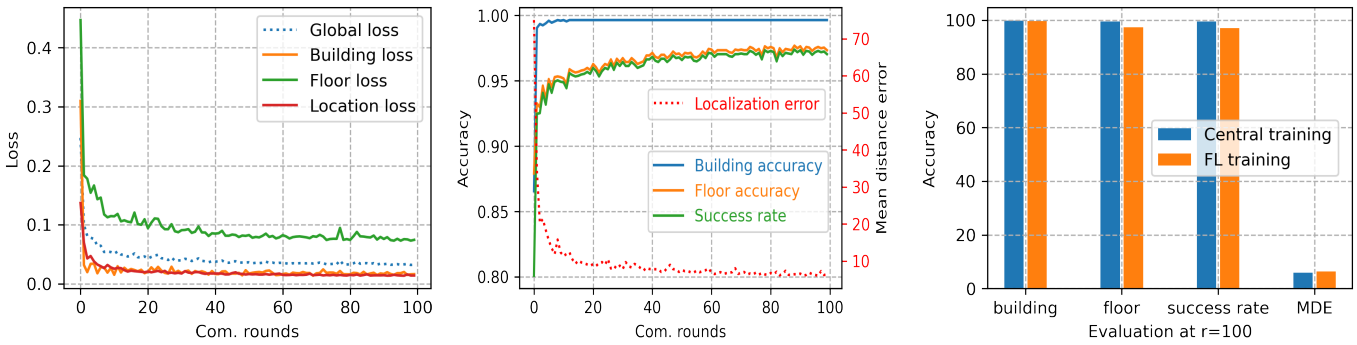

(a) 联邦训练性能。 (b) 联邦学习系统评估。 (c) 与集中式学习的比较。

图3：联邦学习框架性能评估。

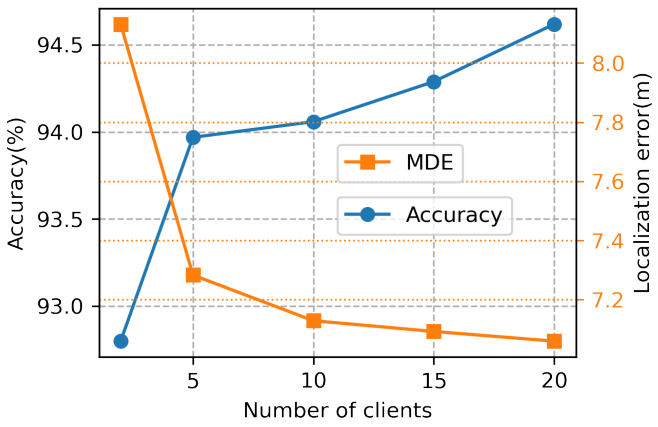

图4：参与者数量增加时的训练性能。

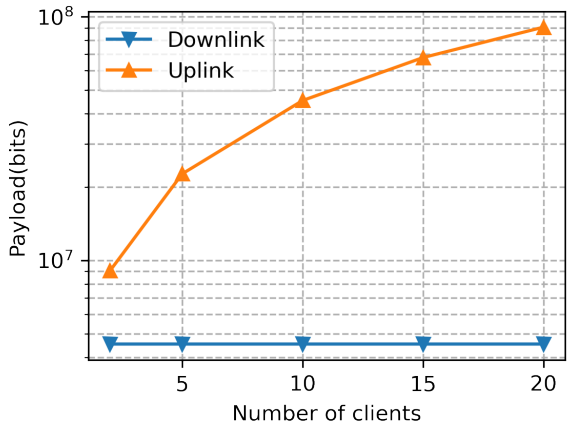

图5：通信负载与参与者数量的关系。

[2] Y. Etiabi、E. M. Amhoud 和 E. Sabir，“一种适用于物联网环境的分布式协作定位算法”，第*18*届移动计算与多媒体进展国际会议论文集，第114–118页，2020年。[3] M. Jouhari、E.-M. Amhoud、N. Saeed 和 M.-S. Alouini，“面向大规模物联网的可扩展LoRaWAN综述：最新进展、潜力与挑战”，*ArXiv*，第 abs/2202.11082 卷，2022年。

[4] W. Njima、M. Chafii、A. Nimr 和 G. Fettweis，“用于定位的数据恢复深度学习方法”，*IEEE Access*，第 8 卷，第 175 741– 175 752 页，2020 年。[5] M. I. AlHajri、R. M. Shubair 和 M. Chafii，“测量有限条件下的室内定位：跨环境联合半监督与迁移学习方法”，*IEEE第22*届无线通信信号处理进展国际研讨会（*SPAWC*），第 266–270 页，2021 年。[6] W. Njima、M. Chafii、A. Nimr 和 G. Fettweis，“基于卷积神经网络的室内定位去噪方法”，*IEEE第93*届车辆技术会议（*VTC2021-Spring*），第 1–6 页，2021 年。[7] K. S. Kim、S. Lee 和 K. Huang，“基于 Wi-Fi 指纹的多建筑多楼层室内定位可扩展深度神经网络架构”，大数据分析，第 3 卷，17，2017 1页。 –。[8] A. E. Ahmed Elesawi 和 K. S. Kim，“基于循环神经网络的分层多建筑多楼层室内定位”，第九届计算与网络国际研讨会工作坊（*CANDARW*），第 193–196 页，2021 年。[9] J. Cha 和 E. Lim，“基于 Wi-Fi 指纹的大规模室内定位分层辅助深度神经网络架构”，《应用软计算》，第 120 卷，第 108624 页，2022 年。[10] F. Yin、Z. Lin、Y. Xu、Q. Kong、D. Li、S. Theodoridis 和 Shuguang，“FedLoc：用于数据驱动协作定位和位置数据处理的联邦学习框架”，*IEEE*开放信号处理期刊，第 1 卷，第 187–215 页，2020 年。[11] Y. Etiabi 、 M. Chafii 和 E.-M. Amhoud，“基于联邦蒸馏的物联网网络室内定位”，*ArXiv*，第 abs/2205 11440 卷，2022 年。 .[12] J. Torres-Sospedra、R. Montoliu、A. M. Us´o、J. P. Avariento、T. J. Arnau、M. Benedito-Bordonau 和 J. Huerta，“UJIIndoorLoc：一个用于基于 WLAN 指纹的室内定位问题的多建筑多楼层新数据库”，室内定位与室内导航国际会议（*IPIN*），第 261–270 页，2014 年。[13] J. Torres-Sospedra、R. Montoliu、S. Trilles、O. Belmonte 和 J. Huerta，“Wi-Fi 指纹室内定位系统中距离与相似性度量的全面分析”，《专家系统与应用》，第 42 卷，第 23 期，第 9263–9278 页，2015 年 12 月。[14] J.-H. Ahn、O. Simeone 和 J. Kang，“衰落信道上的联邦蒸馏协作学习”，*IEEE*声学、语音与信号处理国际会议（*ICASSP*），第 8856–8860 页，2020 年。[15] T. M. Cover 和 J. A. Thomas，信息论基础。John Wiley & Sons, Ltd，2005 年 4 月，第 9 章，第 261–299 页。[16] X. Song、X. Fan、C. Xiang、Q. Ye、L. Liu、Z. Wang、X. He、N. Yang 和 G. Fang，“一种基于卷积神经网络和 WiFi 指纹的新型室内定位框架”，*IEEE Access*，第 7 卷，第 110 698–110 709 页，2019 年。