

## 基于频率响应的 FTTR WLAN 室内无线定位算法研究

龙智丰<sup>1</sup>, 张靖<sup>1,2</sup>

(1. 华中科技大学电子信息与通信学院, 湖北 武汉 430074;  
2. 华中科技大学绿色通信与网络国际联合研究中心, 湖北 武汉 430074)

**摘要:** 高精度和可靠的室内无线定位服务已经被广泛使用, 为了获得良好的定位精度, 定位算法的设计需要与无线定位设施相匹配。全屋光纤 (FTTR, fiber to the room) 是基于新一代无线局域网 (WLAN, wireless local area network) 标准 IEEE 802.11 ax 所开发的室内接入网络方案。相较于已有的 Wi-Fi 网络, FTTR 可用频带宽度大大增加, 同时 FTTR WLAN 也缺乏支持定位功能的公共有效数据集, 这使得基于 FTTR WLAN 场景的定位研究面临巨大障碍。为了解决上述问题, 首先, 提出基于频率响应的 FTTR WLAN 场景数据集生成方法, 利用已有的 Wi-Fi 定位数据集生成 FTTR 可用频带宽度内的频率响应矩阵; 然后, 提出利用并行路径的主成分分析 (PCA, principal component analysis) 的方法生成分类矩阵, 并利用全连接神经网络对生成的数据集进行训练来提高精度。在真实测量数据集上的实验结果表明, 所提定位算法可以达到误差小于 1 m 的定位精度, 不仅比传统位置估计算法精度更高, 而且基本达到了实际应用的细粒度定位要求。

**关键词:** 全屋光纤; 数据集合成; 主成分分析

**中图分类号:** TN929.5

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2023.00355

## Research on FTTR WLAN indoor wireless location algorithm based on frequency response

LONG Zhifeng<sup>1</sup>, ZHANG Jing<sup>1,2</sup>

1. School of Electronic Information and Communications, Huazhong University of Science and Technology, Wuhan 430074, China  
2. International Joint Research Center of Green Communications and Networking, Huazhong University of Science and Technology, Wuhan 430074, China

**Abstract:** Highly accurate and reliable indoor wireless positioning services have been widely used. In order to obtain good positioning accuracy, the design of positioning algorithms needs to be matched with wireless positioning facilities. fiber to the room (FTTR) is an indoor access network solution based on IEEE 802.11 ax, a new generation of wireless local area network (WLAN) standard. Compared with the existing Wi-Fi networks, FTTR has a much larger available band width. However, FTTR WLAN also lacks of a public valid data set to support localization functions, which makes the localization research based on FTTR scenarios face huge obstacles. In order to solve the above problems, firstly, a frequency response-based FTTR scene dataset generation method was proposed, which uses the existing Wi-Fi localization dataset to generate the frequency response matrix within the available band width of FTTR. Then, the parallel path principal component analysis (PCA) method was used to generate the classification matrix. And the generated dataset was trained using a fully connected neural network to improve the accuracy. The experimental results on the real measurement dataset show that the proposed localization algorithm can achieve a localization accuracy of less than 1 m, which is not

收稿日期: 2023-03-21; 修回日期: 2023-05-29

通信作者: 张靖, zhangjing@hust.edu.cn

基金项目: 国家自然科学基金资助项目 (No.U2001210); 国家重点研发计划 (No.2020YFB1806605); 湖北省重点研发计划 (No.2021BAA009)

**Foundation Items:** The National Natural Science Foundation of China (No.U2001210), The National Key Research and Development Program of China (No.2020YFB1806605), The Key Research and Development Program of Hubei Province (No.2021BAA009)

only more accurate than the traditional location estimation algorithm, but also basically meets the fine-grained localization requirements for practical applications.

**Key words:** FTTR, dataset synthesis, principal component analysis

## 0 引言

随着智能设备和室内应用的快速增长,无线高精度室内定位服务受到越来越多的关注<sup>[1-2]</sup>。各种室内应用,如家庭健康服务和建筑管理等,都需要准确的定位服务。目前,室内广泛部署了无线局域网(WLAN, wireless local area network),这使得基于无线 Wi-Fi 信号的室内定位方案具有低成本和普遍性的优势。然而室内环境通常较复杂,无线 Wi-Fi 信号在传输过程中容易出现散射、绕射和多路径传播现象,往往导致其定位精度不高,因此,提高室内无线定位算法的精度成为了学术界和工业界普遍关心的问题。

下一代 WLAN 开发了一种新颖的方案—全屋光纤(FTTR, fiber to the room),通过无源光网络支持在室内密集部署 Wi-Fi 接入点,为室内用户提供短距离通信服务<sup>[3]</sup>。与传统室内网络相比,FTTR WLAN 能够实现 1~2 个房间部署一个 Wi-Fi 接入点。这种情况下用户更容易满足视距传输条件,能够将传统应用于工业 Wi-Fi 场景中的 5.8 GHz 频段应用于室内 Wi-Fi 通信,工作频带也从原来的 80 MHz 增加到 160 MHz 带宽。因此,FTTR WLAN 能够提供更短的通信距离和更宽的可用频谱,为室内用户提供极高的通信数据速率。然而,FTTR 网络的部署也为基于 FTTR WLAN 场景的定位研究带来了极大的挑战。一方面,高质量的公共数据集是无线定位领域研究的主要驱动力,而 FTTR WLAN 主要是为了满足传统室内 Wi-Fi 网络的通信需求进行升级,其仅有部分通信性能的测试结果,缺乏公开有效的高质量数据集;另一方面,与传统 Wi-Fi 网络已经测量得到的指纹数据集相比,FTTR WLAN 测量得到的指纹数据集将具有显著不同的数据特征。如根据 IEEE 802.11ax 标准,FTTR WLAN 除了能够使用传统 Wi-Fi 网络的 2.4 GHz 频带,还能够使用波长更短的 5 GHz 频带,这导致其信号的穿墙损耗更明显。而以往的 Wi-Fi 网络由于不能使用这部分频带,导致这部分频带的数据特征在以往的 Wi-Fi 指纹数据集中是缺失的。并且由于 FTTR

WLAN 能够使用正交频分多址(OFDMA, orthogonal frequency division multiple access)模式,将 160 MHz 的可用带宽分成多个子载波并允许多个子载波聚合使用。因此,FTTR WLAN 的多个子载波之间可能存在相关性。正是这种数据集的缺乏,数据特征的缺失以及子载波之间的相关性,给 FTTR WLAN 场景下的无线定位的研究带来了极大的困难。

为了应对 FTTR WLAN 场景下的室内无线定位挑战,本文提出了一种频率响应矩阵生成范式。该范式严格按照 FTTR 系统的 IEEE 802.11ax 标准模拟无线链路,包括信号生成、空口设计和链路处理等模块,并利用已有的 Wi-Fi 指纹数据集基于位置相关特征数据合成信道频率响应图像,以适用于 FTTR WLAN 场景的室内无线定位应用。为满足移动终端的轻量化操作需求,本文采用并行路径和主成分分析(PCA, principal component analysis)的方法处理信道频率响应图像以建立 PCA 向量的分层框架,并在在线阶段采用深度神经网络(DNN, deep neural network)进行位置预测。通过大量的定位实验在公开的 Wi-Fi 指纹数据集中进行评估,结果表明所提定位算法的平均误差小于 1 m,达到了实际应用的细粒度定位要求,比使用该数据集进行定位的传统位置估计算法精度更高,且具有较快的收敛速度和更低的时间开销,能够满足移动终端的定位需求。

本文的贡献如下。

1) 提出了一种新型的 FTTR 数据集合成方法,能够利用已有的 2.4 GHz Wi-Fi 指纹数据集构建适用于包含 2.4 GHz 和 5.8 GHz 的 FTTR WLAN 场景信道频率响应图像。该方法完全符合 IEEE 802.11ax 标准,并且数据的生成方式按照真实无线信号传输方法形成,可以为 FTTR WLAN 场景定位的研究提供技术支持。

2) 开发了一种深度学习的定位算法,包括在训练阶段并行路径、PCA 处理和定位阶段的 DNN 反演。PCA 处理能够极大地减少数据处理的计算量,从而满足移动终端需求。DNN 反演可以更高效地提取频域位置相关特征。

## 1 相关工作

本文工作主要是基于信道频率响应 (CFR, channel frequency response) 的室内无线定位方法<sup>[4-7]</sup>。与基于几何的定位算法相比, 指纹定位方法对环境更加敏感并且定位的精度更高, 因此在室内无线定位方面更有吸引力。Song 等<sup>[8]</sup>提出了一种基于窄带物联网系统中单房间的信道状态信息 (CSI, channel state information) 振幅指纹的定位算法。Wang 等<sup>[9]</sup>提出了一个基于深度学习的室内指纹识别系统 Deep Fi, 该系统基于 CSI, 利用指纹训练深度学习网络中各层的所有权重。对于部署在多个房间场景中的多个 Wi-Fi, 接收信号强度指示 (RSSI, received signal strength indication) 指纹被广泛用于运动位置估计。Wang 等<sup>[10]</sup>提出了一种多建筑和多楼层定位方法, 以实现可靠和准确的位置估计。此外, 在自适应指纹映射的基础上, Tao 等<sup>[11]</sup>提出了一种粗粒度和细粒度相结合的两步定位算法以实现室内定位。

虽然, Wi-Fi 指纹定位领域已经有大量公开的数据集, 研究人员基于这些数据集进行了大量工作。然而, FTTR WLAN 在使用环境、工作频带等和定位相关的网络特征方面与传统网络相差甚远。并且 FTTR WLAN 由于方案新颖, 在实际部署场景中往往只测量通信系统性能, 导致目前缺乏公开有效的数据集。因此, 作为替代方案, 本文考虑利用已有的 Wi-Fi 指纹数据集合成 FTTR WLAN 场景的数据集。在合成数据集方面, 中兴通讯和华为等公司使用了一个特殊的无线电地图数据集模拟车联网中的定位场景<sup>[12]</sup>。贝尔实验室提出了一种通用的 5G NR 定位数据合成方法<sup>[13]</sup>。这些合成数据集的应用场景和 FTTR 场景差别较大, 车联网场景中无线信号的直射路径更加丰富, 而 5G NR 数据集的工作频带和 FTTR 系统不同, 这些都将影响 FTTR WLAN 场景定位方案的设计。

本文提出基于信道位置频率响应的方法将已有的 Wi-Fi 指纹数据集合成成为 FTTR WLAN 场景的 CFR 图像。CFR 图像是一种以频率为参数, 反映系统或信号的幅度、相位响应等属性的图像。CFR 通常用于描述信号在一个系统中的传输特性, 以及系统对输入信号的变换效果。CFR 图像是一个与位置相关的细粒度定位度量结果, 在不同位置表现出明显的差异。在频域图像处理 Wi-Fi

指纹定位的应用中, Chen 等<sup>[14]</sup>提出了一种新颖的室内定位系统。在训练阶段, 系统获取不同位置的信道频率响应。在定位阶段, 系统捕获信道频率响应并与训练阶段获得的信道频率响应进行比较, 从而得到室内定位的精度。Elmer 等<sup>[15]</sup>给出了动态环境下使用信道频率响应作为室内位置指纹进行室内定位的实验结果, 实现高精度室内定位。Tseng 等<sup>[16]</sup>首先通过信道测深器收集频率响应数据, 开发了一个射线跟踪信道预测器捕获信道的主要特征, 并提出了一种射线跟踪辅助的指纹定位方法。

综上, FTTR 场景的定位研究还缺乏有效实用的数据集, 因此需要根据 FTTR WLAN 场景下无线信号的传播特征, 设计一种合成 FTTR WLAN 场景数据集的方法, 来保障该方法能够较真实地模拟移动终端在 FTTR WLAN 场景数据收集的过程。本文提出利用基于已有 Wi-Fi 指纹数据集合成 FTTR WLAN 场景 CFR 图像的方法能够极大地提高室内无线定位精度。

## 2 FTTR WLAN 场景数据集合成

为了合成有效实用的 FTTR WLAN 场景数据集, 本文将根据 IEEE 802.11 ax 的标准模拟无线信号的接收过程, 借助射线跟踪法对无线信号进行建模和电磁分析, 从而获取测量点的射线信息, 并在此基础上模拟移动终端接收无线信号的过程。考虑 FTTR WLAN 场景较传统 WLAN 场景新增了 5 GHz 频带范围内的 80 MHz 可用频带, 该频带范围的信号波长仅为原来的 2.4 GHz 频带的一半, 对墙壁的透射能力和绕射能力都将减弱。因此, 本文将在频域生成测试点的 CFR 图像, 从而保障所合成的 FTTR WLAN 场景数据集的真实性。

在物理层, 首先基于射线跟踪模型<sup>[17]</sup>描述信号在接入点和移动终端之间的传播路径, 移动终端接收到的信号功率可表示为

$$P^{3D}(d) = \frac{P_1 \lambda^2}{(4\pi d)^2} \left| \sqrt{G_T(\phi_T, \theta_k) G_R(\phi_R, \theta_k)} \times \right. \\ \left. (\Gamma^{\text{ceiling}}(\theta_k))^{\lfloor \frac{k+1}{2} \rfloor} (\Gamma^{\text{floor}}(\theta_k))^{\lfloor \frac{k}{2} \rfloor} \prod_{i=0}^n |I_i(\theta_k)|^2 \right. \quad (1)$$

$$\theta_k = \arctan \left\{ \frac{2H \left[ \frac{k+1}{2} \right] + (-1)^k h_2 - h_1}{d} \right\} \quad (2)$$

其中,  $P_i$  为接入点发射的信号功率,  $\theta_k$  为第  $k$  射线的仰角,  $H$ 、 $h_1$ 、 $h_2$  分别表示建筑物、发射天线和接收天线的高度,  $G_T(\phi_T, \theta_k)$  和  $G_R(\phi_R, \theta_k)$  分别为发射天线和接收天线的增益,  $\phi_T$  和  $\phi_R$  分别表示为发射天线角度和接收天线角度,  $\lambda$  表示波长,  $d$  为接入点和移动终端经过反射后的传播路径长度,  $\Gamma$  和  $I$  分别为沿路径的反射和相互作用系数,  $P^{3D}(d)$  表示三维空间下移动终端接收到的信号功率。

射线跟踪模型是基本的无线信号传输模型, 同时为了简化数据合成过程, 本文将无线路径的最大反射阶数设置为 2, 即同时只考虑该模型的直射和镜面反射路径。这是因为在室内环境中, 衍射和折射路径对多径叠加的贡献远小于反射路径。

接下来将按照 IEEE 802.11ax 规范, 模拟生成 FTTR 系统的参考信号、多径信道中的信号衰落和移动终端上的 CSI 估计整个流程。

#### 1) 模拟接入点产生参考信号

参考信号是无线通信中设计用于 CSI 测量和接收信号强度估计的关键信号。根据 Wi-Fi 网络的 IEEE 802.11ax 协议要求, 发射机向移动终端发送的每个数据帧前段包含前导符号, 由前导符号完成信道估计、时间同步、自动增益控制等一系列工作。同时新引进了 OFDMA 技术, 将时频资源统一由资源单元 (RU, resource unit) 管理, 并给 RU 分配相应的导频子载波, 用于调整功率和跟踪相位。因此, 前导符号分布在各子载波上<sup>[18]</sup>, 在时隙  $t$  上的信号形式表示为

$$s(t) = \sqrt{E_c} \sum_{k=1}^{L_0 W} d_k p(t - kT_c - i_0 T_c) \quad (3)$$

其中,  $E_c$  表示每个导频的能量,  $W$  表示导频序列个数,  $L_0$  表示导频序列长度, 脉冲函数  $p(t)$  归一化为单位能量,  $T_c$  表示持续时间, 并假设导频开始于离散时间  $i_0$  处。

#### 2) 在移动终端进行信道估计

利用接入点发射的前导信号获取频谱响应信息, 需要执行以下 4 个步骤。

**步骤 1** 考虑直射和反射, 文中对无线传输信道进行建模, 将射线跟踪法传输的多径分量进行叠加。

$$h(\tau) = \sum_{n=1}^N a_n e^{-j\theta_n} \delta(\tau - \tau_n) \quad (4)$$

其中,  $a_n$ 、 $\theta_n$  和  $\tau_n$  分别为第  $n$  个路径上的振幅、相位和时延,  $\delta(\cdot)$  为狄拉克函数,  $N$  表示环境中的路

径总数。此外,  $h(t)$  是该多径信道的信道冲击响应, 它由多条路径上的时延乘以振幅和相位组成。因此, 接收信号频谱  $R_s(f)$  可以表示为发射信号频谱  $T_s(f)$  与信道频率响应  $H(f)$  的乘积, 对应两者在时域的卷积, 即  $R_s(f) = T_s(f) \cdot H(f)$ 。由于信道冲激响应的计算非常重要, 所以本文通过频率乘法估计信道, 然后使用傅里叶逆变换去噪。

**步骤 2** 对接收到的信号进行正交频分复用 (OFDM, orthogonal frequency division multiplexing) 解调和时间偏移校正, 移动终端获得接收到的信道冲激响应。所有子载波的相对频率冲激响应矩阵  $H_r$  可以用  $k$  维列向量的形式表示为

$$H_r = (R_{\text{Grid}})_{k \times 1} / (\text{ref}_{\text{Grid}})_{k \times 1} \quad (5)$$

其中,  $k$  为子载波数,  $R_{\text{Grid}}$  表示各子频带模拟得到的信道频率冲激响应,  $\text{ref}_{\text{Grid}}$  表示各子频带测量得到的信道频率冲激响应。

**步骤 3** 对  $H_r$  用傅里叶逆变换将信息转化为时域的相对信道频率冲激响应进行降噪。那么, 去噪后的相对信道冲激响应可表示为

$$H_n = \mathcal{F}^{-1}(H_r)W \quad (6)$$

其中,  $W$  是用于去噪的时域上升余弦窗口,  $\mathcal{F}^{-1}(\cdot)$  表示傅里叶逆变换。

**步骤 4** 最后通过傅里叶变换得到 CFR 图像  $H$ 。

$$H = \mathcal{F}(H_n) \quad (7)$$

其中,  $\mathcal{F}(\cdot)$  表示傅里叶变换。

在整个移动终端估计过程中, 由于参考了 IEEE 802.11ax 协议前导符号的多径传播过程, 所生成的 CFR 图像与位置相关, 并具有极高的区分度。将 FTTR WLAN 可以使用的 160 MHz 带宽分为 16 个 10 MHz 独立频带, 每个独立频带作为一个通道, 利用每个频带的中心频率对应的波长估计传播路径。同时 FTTR WLAN 分配的子载波方案共 76 组, 每组子载波都可能作为前导符号和分配导频信号, 因此每张 CFR 图像是 76×16 个像素点的。CFR 图像中的每一列像素对应一个通道, 而宽度对应通道数量, 并且 CFR 图像的物理意义主要集中在频率方向 (垂直方向)。来自同一楼层 5 个 Wi-Fi 接入点的单个移动终端在测试点的 CFR 图像如图 1 所示, 所有观测得到的 CFR 图像均显示出良好的分辨力, 表明基于 CFR 图像的方法具有较高的定位精度。




图1 来自同一楼层5个Wi-Fi接入点的单个移动终端在测试点的CFR图像

### 3 FTTR WLAN 场景位置反演

位置反演利用测量结果推断移动终端位置。预处理部分用于提供丰富的定位特征，DNN 训练部分用于特征学习和模型训练。在预处理部分设计了不同卷积核的多路径传输和 PCA 的特征提取。各条路径的不同卷积核能够使每条路径独立确定一个合适的特征提取范围，提供多样化的特征。PCA 的特征提取可以减少需要处理的数据量，保持快速收敛的特性，从而满足移动终端高效快速定位的实际需求。在 DNN 训练部分设计了 3 个隐藏层用于模型的训练。每个隐藏层输入和输出都包含 16 个通道，并且每层之间通过权值矩阵和偏置矩阵进行传播。DNN 的训练可以将特征通过非线性变换得到最终的测量点位置坐标，能够使拟合更加接近。

#### 3.1 基于并行路径 PCA 的预处理

在 PCA 预处理部分首先需要保证特征提取的多样性。因为提取的特征越丰富，越有利于 DNN 在定位过程中提高定位精度。因此，本文采用 3 条不同结构的并行路径提取不同范围的特征。这样，单个输入 CFR 图像可以通过不同大小的卷积核产生图像范围的输出特征。具体来说是在 3 个并行路径上分别使用了一个  $1 \times 1$  滤波器、一个  $3 \times 3$  滤波器和一对  $5 \times 1 + 1 \times 3$  滤波器。这种并行路径使得图像具有自动选择适当大小的卷积核进行特征提取的能力。较小的滤波器能够有效保存原始 CFR 图像信息，而较大的滤波器可以更有效地捕获相邻子载波之间的信道差异，由此揭示隐含在各子载波之间的

位置相关特征。 $n \times 1$  和  $1 \times n$  的滤波器能更好地关注 CFR 图像在子载波间和导频信号间的特征。

具体来说，若输入滤波器的  $76 \times 16$  CFR 图像，第  $r$  行、第  $c$  列矩阵元素对应的像素值为  $f(r, c)$ 。经过  $m \times n$  的滤波器后，将 CFR 图像每个像素的值替换为该像素周围邻域内像素值的加权平均值，权重由一个高斯函数计算得出。经过滤波后，第  $r$  行、第  $c$  列矩阵元素  $f'(r, c)$  可以表示为

$$f'(r, c) = \frac{1}{2\pi\sigma^2} \sum_{i=-\frac{m-1}{2}}^{\frac{m-1}{2}} \sum_{j=-\frac{n-1}{2}}^{\frac{n-1}{2}} f(r+i, c+j) e^{-\frac{i^2+j^2}{2\sigma^2}} \quad (8)$$

其中， $\sigma$  是高斯函数的标准差。

同时，为了减少 DNN 训练的数据量，本文对不同路径卷积核的输出用 PCA 进行降维处理，在有效提取图像特征的同时加快收敛速度。PCA 降维处理的过程包括 4 个步骤。

**步骤 1** 将经过多径处理后的 CFR 图像中每个通道所对应的均值设为 0，目的是防止大变量占主导地位。即对大小为  $N_s \times N_p$  的 CFR 图像矩阵  $H$  的每个通道求取其平均值，用  $A_{1 \times N_p}$  表示，其中  $N_s$  表示子载波的数量， $N_p$  表示通道的数量，并让每个通道的每个载波的值减去平均值得到结果  $H'$

$$H'_{ixj} = H_{ixj} - A_{ixj}, i=1, \dots, N_s, j=1, \dots, N_p \quad (9)$$

**步骤 2** 对处理之后的 CFR 图像矩阵  $H'$  求解特征协方差矩阵  $S$ 。

$$S = \frac{1}{N_p - 1} \sum_{j=1}^{N_p} H'_{N_s \times N_p} (H'_{N_s \times N_p})^T \quad (10)$$

**步骤 3** 根据得到的特征协方差矩阵  $S$ ，求解特征值和特征向量，并将特征值按照降序排列，即  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$ 。将每个特征值对应的特征向量排列成矩阵的形式，如

$$A = (\xi_1, \xi_2, \dots, \xi_k) \quad (11)$$

其中， $\lambda_i$  表示第  $i$  个特征值，用  $\xi_i$  表示第  $i$  个特征向量。

**步骤 4** 从特征向量中选取前  $N$  个向量作为主成分，最终得到降维之后的矩阵为

$$H_{N \times N_p} = (\xi_1, \xi_2, \dots, \xi_N) \cdot H'_{N_s \times N_p} \quad (12)$$

PCA 方法已经在很多工作中被用来处理 RSSI 数据集<sup>[19-20]</sup>。本文利用 PCA 处理并行路径滤波后

的图像，以降低数据维度，合并掉相似的特征从而有利于防止过拟合现象的发生。此外，还能够在有效保留数据主要信息的同时，减少计算和存储资源，有利于算法部署在移动终端中。

### 3.2 DNN 训练

经过 PCA 降维处理后的矩阵将输入 DNN<sup>[21-22]</sup>用来训练权值矩阵  $\mathbf{W}$  和偏置矩阵  $\mathbf{B}$ 。DNN 架构如图 2 所示，包含 1 个输入层、3 个隐藏层、1 个输出层。每个隐藏层输入和输出都包含 16 个通道，因此能够处理的权值矩阵和偏置矩阵是 3 组，大小均为  $16 \times 16$ ，分别为  $\mathbf{W}_1 \sim \mathbf{W}_3$  和  $\mathbf{B}_1 \sim \mathbf{B}_3$ 。此外，输出层的输入包含 16 个通道，但输出层的输出为位置的估计值  $\hat{P} = (\hat{x}, \hat{y})$ ，其对应的权值矩阵  $\mathbf{W}_4$  和偏置矩阵  $\mathbf{B}_4$  大小为  $16 \times 2$ 。利用 DNN 进行数据处理的过程中，每两层之间进行矩阵数据的特征传输包括两个过程。

首先，通过输入和输出之间的权值向量和偏置向量得到中间值。对于第  $i$  个通道的输入  $x_i$ ，经过第  $k$  层的权值矩阵  $\mathbf{W}_k$  和偏置矩阵  $\mathbf{B}_k$  的权值处理，得到的第  $j$  条通道的中间值  $z_j$  可以表示为

$$z_j = \sum_{i=1}^{16} (w_{i,j} x_i + b_{i,j}) \quad (13)$$

其中， $w_{i,j}$  表示权值矩阵  $\mathbf{W}_k$  第  $i$  个输入与第  $j$  个输出之间的线性关系系数， $b_{i,j}$  表示偏置矩阵  $\mathbf{B}_k$  第  $i$  个输入与第  $j$  个输出之间的偏置量。

然后，将得到的中间值通过激活函数得到输出。本文激活函数采用的是  $\tanh$  函数，其表达式为  $\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 。因此，可以得到下一层的结果为

$$f(z_j) = \tanh z_j = \frac{e^z - e^{-z}}{e^z + e^{-z}} = \frac{e^{\sum_{i=1}^{16} (w_{i,j} x_i + b_{i,j})} - e^{-\sum_{i=1}^{16} (w_{i,j} x_i + b_{i,j})}}{e^{\sum_{i=1}^{16} (w_{i,j} x_i + b_{i,j})} + e^{-\sum_{i=1}^{16} (w_{i,j} x_i + b_{i,j})}} \quad (14)$$

令  $f(\mathbf{x}) = \tanh(\mathbf{W}\mathbf{x} + \mathbf{B})$ ，为式(14)处理后的函数，则经过 DNN 的 3 个隐藏层和 1 个输出层处理

后，最终得到的用户位置坐标的估计值为

$$\hat{P} = \mathbf{W}_4 \tanh(\mathbf{W}_3 \tanh(\mathbf{W}_2 \tanh(\mathbf{W}_1 \mathbf{H} + \mathbf{B}_1) + \mathbf{B}_2) + \mathbf{B}_3) + \mathbf{B}_4 \quad (15)$$

在训练 DNN 的过程中，用户位置坐标的估计值与实际值往往存在误差，通过预置的权值向量和偏置向量计算进行一次计算不能得到正确的位置估计，还需要进行 DNN 权值向量和偏置向量的修正。这一过程通常采用反向传播方法。具体来说，DNN 的输出误差通常由损失函数来衡量。损失函数表征了模型预测输出与实际标签之间的差异，通常用来衡量模型的精度。

本文选取均方误差函数作为损失函数，记作  $C_{\text{reg}}$ ，表示为

$$C_{\text{reg}} = \frac{1}{N} \sum_{i=1}^N (P - \hat{P})^2 \quad (16)$$

其中， $P$  表示实际的用户位置坐标。采用梯度下降的方法进行反向传播和线性相关系数  $w_i$  和  $b_i$  的修正，其修改为  $w'_i = w_i - \frac{\partial C_{\text{reg}}}{\partial w_i} \cdot \alpha$  和  $b'_i = b_i - \frac{\partial C_{\text{reg}}}{\partial b_i} \cdot \alpha$ ，

$\alpha$  表示迭代步长。在每次迭代中执行正向和反向传播，直到目标损失函数收敛。在正向传播阶段，每个隐藏层通过将偏差添加到加权输入并将结果传递到激活函数来计算输出。数据从输入层流向输出层得到预测结果，每个隐藏层的输出作为下一个隐藏层的输入。在反向传播阶段，误差以相反的方向从输出层传播到输入层，以计算损失函数相对于模型参数的梯度。输出层的误差项计算为实际输出与期望输出的差值，每个隐藏层的误差项计算为下一层误差的加权和。经过式(16)和反向传播的反复迭代，直到到达最大的迭代次数或者权值的变化小于迭代阈值，则停止迭代。将训练得到的权值向量和偏置向量作为 DNN 的参数，进行后续的在线位置估计。本文将模型中的学习率设定为  $1 \times 10^{-3}$ ，迭代次数为 400 次，正则权重为 0.1，从而提高后续的在线位置估计精度。




图2 DNN 架构

从整个训练和定位的数学过程来看，通过 CFR 图像进行定位，相比于传统的利用 RSSI 定位的方法增加了两个方面的优势。

1) 在 CFR 图像的生成过程中，不同于以往 RSSI 数据集只依赖测量的功率信息，所提算法还考虑了不同角度下发射功率和接收功率之间的关系的影响，因此对于同样的 RSSI 数据集，所提算法考虑了直射和一次反射的影响，较 RSSI 方法基于理论计算式增加了多个空间角度路径的影响，在数据采样点的输入方面比 RSSI 方法增加了更多的采样数据。

2) 在测量点位置训练过程中，本文采用的 DNN 包含 4 层权值和偏置，相对于输入矩阵，DNN 不仅能够训练的权矢量是一维反演的 4 倍，并且最终的输出结果是原始输入函数通过权值矩阵和偏置矩阵处理得到，可以认为是总体上的非线性变换。因此能够做到拟合更加接近。

#### 4 在线位置估计及误差分析

精细定位的目的是为最终的位置计算找到一个最佳的位置回归表达，因此采用 DNN 进行位置估计。这是由于 DNN 能够根据激活函数提供多层非线性变换，并具有特殊的优势。一方面，CFR 图

像与位置点之间的关系复杂，考虑 DNN 具有强大的非线性拟合能力，因此选用 DNN 能够保障位置反演的精确度；另一方面，DNN 具有强大的特征提取能力，能够提取出 CFR 图像中与位置相关的特征，并将其转换成更高层次的抽象表示，有助于所提算法在不同场景下的顺利移植。

#### 4.1 用户位置计算

在计算用户位置阶段，通过用户的发射功率和接收点测量得到的 RSSI 值，可以计算得到信号的路径传输函数  $H_m$ 。若测量点用户的发射功率为  $P_{t,m}$ ，接收点 RSSI 信息为  $P_{r,m}$ ，则信号的路径传输函数为  $H_m = P_{r,m} / P_{t,m}$ 。

将路径传输函数  $H_m$  进行傅里叶变换，即

$$H = \mathcal{F}(H_m) \tag{17}$$

同样将所得到的傅里叶变换结果分配到 FTTR WLAN 使用的 16 个 10 MHz 独立频带上作为 16 个通道。并按照 FTTR WLAN 分配的 76 组子载波方案计算频域传输函数的强度，从而得到测量值对应的  $76 \times 16$  CFR 图像。

FTTR WLAN 室内无线定位流程如图 3 所示，将  $76 \times 16$  CFR 图像经过并行路径滤波处理和 PCA

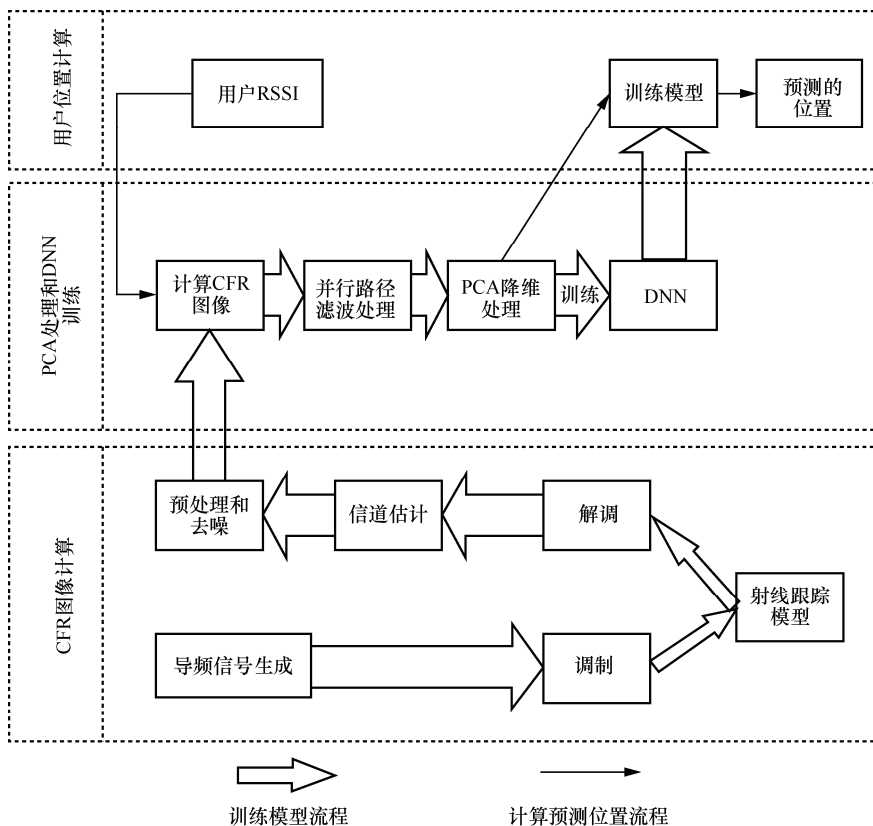


图3 FTTR WLAN 室内无线定位流程

降维处理以后，得到处理后的 CFR 图像  $H_i$ 。将图像输入已经调整了权值的 DNN 中估计位置，即将图像输入 DNN 的输入层中，通过 DNN 中的权值矩阵和偏置矩阵进行处理得到估计位置。在位置估计过程中只进行数据的正向传播过程，如式(15)所示，DNN 的输出结果即为预测的用户位置。

#### 4.2 误差分析

为了评估所提算法的定位精度，本文采用常用的平均误差<sup>[23-24]</sup> ( $\text{Err}_{\text{mean}}$ ) 评估。平均误差定义为

$$\text{Err}_{\text{mean}} = \frac{1}{N_{\text{ue}}} \sum_{i=1}^{N_{\text{ue}}} \|P_i - \hat{P}_i\|_2 \quad (18)$$

其中， $\hat{P}_i = (\hat{x}_i, \hat{y}_i)$  为第  $i$  个移动终端的估计位置， $P_i = (x_i, y_i)$  为第  $i$  个移动终端的实际位置， $N_{\text{ue}}$  为移动终端的个数， $\|\cdot\|_2$  为欧氏距离。其中，第  $i$  个移动终端估计的测量点位置坐标与真实测量点位置坐标之间的误差可以表示为

$$\|P_i - \hat{P}_i\|_2 = \|P_i - W_4 \tanh(W_3 \tanh(W_2 \tanh(W_1 H_i + B_1) + B_2) + B_3) - B_4\|_2 \quad (19)$$

其中， $H_i$  表示根据第  $i$  个移动终端测量的 RSSI 值得到的处理后的 CFR 图像。

所提算法误差包含利用数据集训练 DNN 权值矩阵和偏置矩阵时产生的误差和利用处理后的 CFR 图像进行位置估计时产生的误差，即训练误差和反演误差。训练误差主要由 3 个部分组成：在接入点接收到信号时，分析多径效应形成的误差  $\varepsilon_1$ ；

CFR 图像生成时，截断频谱的傅里叶变换和傅里叶逆变换产生的误差  $\varepsilon_2$ ；进行 CFR 图像的 PCA 处理时产生的截断误差  $\varepsilon_3$ 。因此在训练阶段形成的误差  $E_r$  可以表示为

$$E_r = \sqrt{\varepsilon_1^2 + \varepsilon_2^2 + \varepsilon_3^2} \quad (20)$$

1) 在接入点接收到信号时，由多径效应形成的相对误差为

$$\varepsilon_1^2 = \Delta d/d \quad (21)$$

其中， $d$  表示测量点到接收点之间的距离， $\Delta d$  表示由于多径效应形成的路径之间的最大距离差。

2) 假设信号的傅里叶变换为  $H(\omega)$ ，截断频谱的傅里叶变换为  $H'(\omega)$ ，截断的频域的范围为  $(-N\Delta\omega, N\Delta\omega)$ ，那么可以得到截断频谱的傅里叶变换和傅里叶逆变换产生的误差为

$$\Delta H(\omega) = H(\omega) - H'(\omega) \quad (22)$$

通过帕塞瓦尔定理可以得到

$$\varepsilon_2^2 = \frac{1}{2\pi} \int_{-N\Delta\omega}^{N\Delta\omega} |\Delta H(\omega)|^2 d\omega \quad (23)$$

3) CFR 图像的 PCA 处理产生的截断误差为

$$\varepsilon_3^2 = \frac{1}{M} \sum_{i=1}^M \|n_i - \hat{n}_i\|^2 \quad (24)$$

其中， $M$  表示数据样本数， $n_i$  表示原始数据的第  $i$  个样本， $\hat{n}_i$  表示该样本在 PCA 降维后的重构结果，即通过 PCA 降维后再恢复得到的数据矩阵。

此外，训练误差还包括在 DNN 训练过程中，每层权值和偏置形成的估计误差。

由式(19)可知，Err 的误差值来源于每一层的权值矩阵  $W$  和偏置矩阵  $B$  所产生的影响。而每一层的权值矩阵  $W$  和偏置矩阵  $B$  都由梯度下降算法进行修正，因此，权值矩阵  $W$  和偏置矩阵  $B$  最终由梯度下降算法中的迭代阈值  $w_{\text{max}}$  和  $b_{\text{max}}$  决定。当迭代阈值越小，则表明  $w'_i - w_i$  和  $b'_i - b_i$  越小，即

$\frac{\partial C_{\text{reg}}}{\partial w_i} \cdot \alpha$  和  $\frac{\partial C_{\text{reg}}}{\partial b_i} \cdot \alpha$  越小，因此损失函数  $C_{\text{reg}}$  越小，预测位置坐标与实际的位置坐标越准确，误差越小。假设整个 DNN 的迭代阈值设置为  $W_T$  和  $B_T$ ，则最终得到位置估计的误差大小为

$$\|P_i - \hat{P}_i\|_2 = W_T \tanh(W_T \tanh(W_T \tanh(W_T E_r + B_T) + B_T) + B_T) + B_T \quad (25)$$

考虑本文 DNN 中隐藏层神经元的激活函数采用的是  $\tanh$  函数，其表达式为： $\tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ 。将  $e^x$  泰勒展开后，当  $x$  很小时，有

$$\tanh x \approx x + O(x^3) \quad (26)$$

因此，每个隐藏层形成的误差为  $\tanh(W_T E_r + B_T) \approx W_T E_r + B_T$ ，即每个隐藏层都不会放大误差，整个 DNN 形成的误差小于  $(W_T E_r + B_T)^4$ 。如文献[25]式(5)所示，随着 DNN 中隐藏层数量的增加，所得到的误差值减小。

在 CFR 图像计算部分，符合 IEEE 802.11ax 的导频信号经过调制后输入相应位置的射线跟踪模型，再经过接收链路形成 CFR 图像。在 PCA 处理和 DNN 训练阶段首先通过并行路径提取 CFR 图像的特征，采用 PCA 进行降维，减少需要处理的数据。在位置反演阶段通过 DNN 训练位置估计的模型参数，将测量得到的 RSSI 通过模型参数估计位置信息。

所提算法与传统 DNN 都包括输入层、隐藏层和输出层, 每个神经元的输出会作为下一层的输入, 并通过反向传播算法对权重和偏置进行优化以最小化损失函数。但是所提算法与传统的 DNN 不同点在于: 首先通过 PCA 降维处理, 降低了数据的维度并且保留了大量的特征。此外, 本文隐藏层采用的激活函数为  $\tanh$  函数, 相较于传统的 DNN 采用  $\text{sigmoid}$  函数, 其更加平滑、容易求导, 并且收敛速度更快。所提算法相较于传统的 CNN 来说, 其都可以处理大量的数据并从中学习到输入和输出之间的映射关系。但是 CNN 利用卷积核从图像中提取出特征信息, 而所提算法则没有显式的处理结构, 一般包含多个层级的全连接层。此外, 所提算法具有较强的非线性拟合能力并且通过优化函数进行训练, 具有较高的泛化能力。并且本文数据是基于电磁波传播原理生成的, 保留了一定的传输特征, 具有一定的适应性。

## 5 仿真结果与分析

### 5.1 场景设置

本文使用的数据集来自文献[26]。这些数据是在一栋 3 层的大楼里收集的, 每层楼的尺寸为  $51\text{ m} \times 28\text{ m}$ 。由于一些位置受到限制, 因此数据集覆盖了约 50% 的建筑物范围。Wi-Fi 接入点工作在 2.4 GHz, 带宽为 80 MHz 和发射功率为 5 W。每层楼测量点和接入点位置如图 4 所示。红色标记的位置点表示每层楼进行测量的地方, 每次测量都在唯一的绝对位置进行。Wi-Fi 接入点在 1F、2F 的部署位置, 如黑色标记所示, 其固定在离楼层地板 2.5 m 的地方。模拟时, 随机浮动高度为 0.1 m, 以防止共面性。用户位置点使用三星 Galaxy Young GT-S5360 智能手机作为客户端进行测量。

数据集包含 1 571 条记录, 具有 65 个属性, 并且每个测量值都提供了诸如精确位置、RSSI 读数、时间戳和一些标识符等信息。测量部分包括从磁力计、WLAN 卡和蓝牙接口采集的数据。磁力计返回一个三维实向量。Wi-Fi 网络的 RSSI 值在数据集表格第 11~42 列的位置, 每个位置都有相应的接入点, 其取值范围为  $[-96, -34]$ , 没有测量到信号强度则将值设为 Null。本文选取其中 AP 测量的信号强度属性进行 CFR 图像计算, 即数据集中第 11~42 列共 32 列的数据, 并且采用数据集中所测量的用户相对位置坐标以及 AP 的位置坐标进行相应的射线跟踪模型的计算。

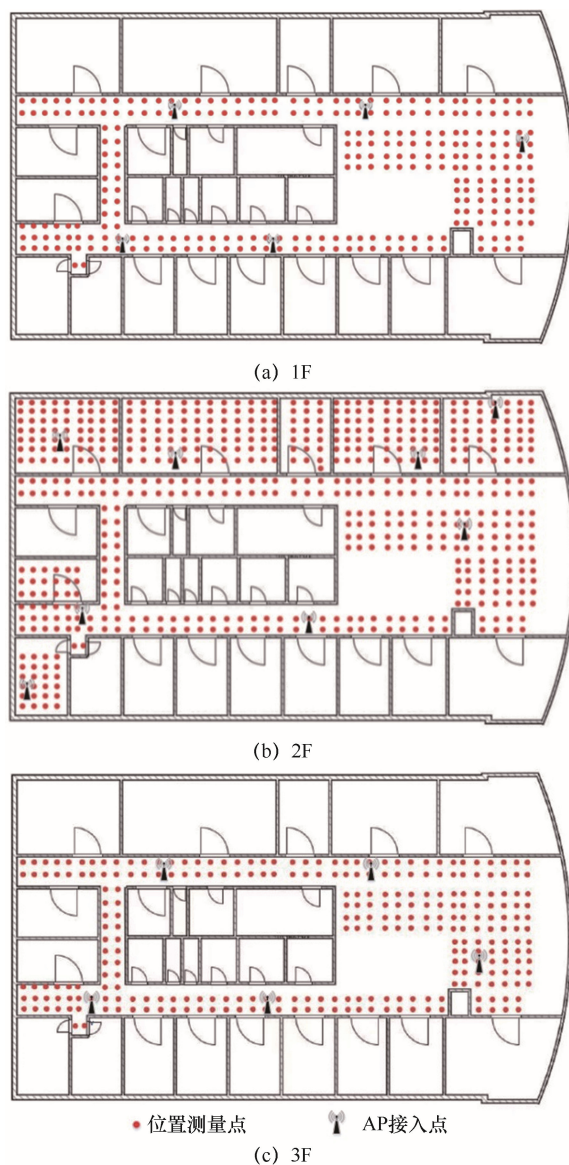


图 4 每层楼测量点和接入点位置

### 5.2 技术指标

为了评估所提算法的定位性能, 采用常用的平均误差<sup>[23-24]</sup> ( $\text{Err}_{\text{mean}}$ ) 评估。平均误差为

$$\text{Err}_{\text{mean}} = \frac{1}{N_{\text{ue}}} \sum_{i=1}^{N_{\text{ue}}} \|P_i - \bar{P}_i\|_2 \quad (27)$$

其中,  $\bar{P}_i$  为第  $i$  个移动终端的估计位置,  $P_i$  为第  $i$  个移动终端的实际位置,  $N_{\text{ue}}$  为移动终端的个数,  $\|\cdot\|_2$  为欧氏距离。

此外, 由于本文利用已有的 Wi-Fi 指纹数据集来合成 FTTR WLAN 场景数据集, 因此需要评估所合成的数据集和测量得到数据集之间的一致性。结构相似性指标 (SSIM, structural similarity) 是比较图像质量的常用指标之一<sup>[27-28]</sup>, 其取值范围为  $0 \sim 1$ ,

表示原始图像和重建图像之间的结构相似度。具体而言, SSIM 可以度量亮度、对比度和结构等方面的相似性。因此, 使用 SSIM 评估生成的 CFR 图像与相应的采样 CFR 图像。SSIM 的定义为

$$SSIM(m, n) = \frac{(2\mu_m\mu_n + C_1)(2\sigma_{mn} + C_2)}{(\mu_m^2 + \mu_n^2 + C_1)(\sigma_m^2 + \sigma_n^2 + C_2)} \quad (28)$$

$$\mu_m = \frac{1}{N} \sum_{i=1}^N m_i \quad (29)$$

其中,  $m$  和  $n$  为两个用于比较的非负图像信号,  $\mu_m$  和  $\mu_n$  为两幅图像的平均亮度,  $C_1$  和  $C_2$  表示用来维持稳定的常数。方差的平方根作为信号对比的估计, 表示为

$$\sigma_m = \left( \frac{1}{N-1} \sum_{i=1}^N (m_i - \mu_m)^2 \right)^{\frac{1}{2}} \quad (30)$$

$$\sigma_{mn} = \frac{1}{N-1} \sum_{i=1}^N (m_i - \mu_m)(n_i - \mu_n) \quad (31)$$

### 5.3 估计精度

为了验证所提算法的定位性能, 将文献[26]中数据集在 1F、2F 测量的数据作为训练样本, 用于训练所提算法中的 DNN, 并利用 DNN 的模型参数预测 3F 的测量点位置。训练样本共 1000 个点, 所预测的测量点位置共 500 个, 测量点的距离误差累积分布函数如图 5 所示。作为对比算法, 文献[29]在处理文献[26]数据集时采用了加权  $K$ -近邻 (WKNN, weighted  $K$ -nearest neighbor) 和长短期记忆网络 (LSTM, long short-term memory) 结合的方法, 并调整 WKNN 算法中的  $k$  ( $k=13$ 、21、35) 获得了不同条件下所估计的平均距离误差。本文采用文献[29]所采用的 WKNN-LSTM 算法作为对比方案。




图5 测量点的距离误差累积分布函数

可以看出, 所提算法对该数据集观测点的位置估计误差均小于 WKNN-LSTM 算法。根据距离误差的累积分布函数, 可以计算得到所提算法在位置估计的平均误差为 0.86 m, 对比算法 WKNN-LSTM  $k=13$  时的位置估计平均误差为 1.83 m,  $k=21$  时的位置估计平均误差为 1.79 m,  $k=35$  时的位置估计平均误差为 1.72 m。因此, 所提算法在位置估计精度上优于 WKNN-LSTM 算法, 并且能够达到位置估计误差小于 0.9 m, 实现了细粒度的位置估计。当距离误差相等时, 随着 SSIM 值的增大, 累积分布函数的值增大。在距离误差为 1 m 的情况下, 当 SSIM 的值从 0.843 6 增大到 0.912 1 时, 距离误差累积分布函数的值提高 0.1, 即小于 1 m 距离误差的位置点更多, 因此定位的精度更高, 平均误差更小。

不同位置密度下的平均误差如图 6 所示。位置密度表示为选取数据所占的面积大小与总面积大小的比值。可以看出, 在相同位置密度的情况下, 所提算法的平均误差相比于使用相同数据集的 WKNN-LSTM 算法的精度更高。并且当位置密度达到 1 时, 即选取全部的数据, 所提算法的平均位置误差为 0.86 m。相较于相同位置密度下 WKNN-LSTM 算法最好的平均误差 1.72 m 更好。

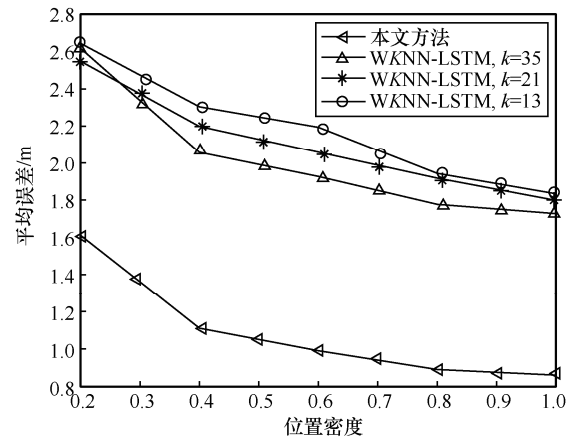


图6 不同位置密度下的平均误差

### 5.4 收敛性分析

收敛性分析是评估 DNN 性能和结构所必须的, 收敛性对比如图 7 所示, 所提算法在训练集和测试集上的损失如图 7(a)所示。在前 25 个训练周期中, 所提算法损失从 763.37 下降到 5.31。同时在整个训练过程中, 测试集上的曲线始终接近训练集上的曲线, 表明没有发生过拟合。此外, 本文还对比了另外两个经典的 DNN 算法, ResNet-18<sup>[30]</sup>和 Xception<sup>[31]</sup>

计算位置平均误差的收敛速度，如图 7(b)所示，可以看出，所提算法的收敛速度较 ResNet-18 和 Xception 更优，这是由于并行路径处理和 PCA 能够大大减少计算工作量。同时所提算法在峰值和波动方面较小，因此在快速收敛稳定性方面也具有优势。

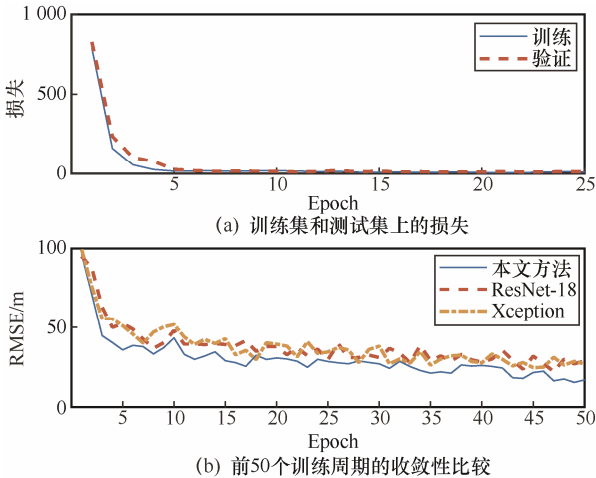


图7 收敛性对比

### 5.5 时间复杂度

不同数据集大小的训练时间开销如图 8 所示，算法设置的迭代次数为 500 次，时间消耗的变化基本上是线性的。当采用 WKNN-LSTM 方法时，1 000 个训练集训练所花费的时间为 60 min。而所提算法可以通过调整 PCA 的降维系数减少训练所花费的时间。可以看出，当降维系数从 0.94 减少为 0.54 时，1 000 个训练集训练花费的时间从 54 min 减少为 36 min。此外，本文测试过位置估计所花费的时间，训练后的 DNN 模型参数，反演数据集 3F 的 470 个测量点的位置花费少于 14 min，即每个测量点的位置反演不超过 1.8 s。这证明所提算法能够用于移动端快速估计测量位置。




图8 不同数据集大小的训练时间开销

### 5.6 相似度分析

由于所提算法利用已有的 Wi-Fi 指纹数据集合成 FTTR WLAN 场景数据集，因此需要验证合成数据集和真实数据集的差异，这种差异通过数据集的结构相似度来估计。为了将合成的 CFR 图像与相应采样得到的 CFR 图像进行比较，10 号测量点和 3 号 Wi-Fi 接入点的位置如图 9 所示，在数据集 3F 的测试点中随机选择 10 号测量点测量 3 号 Wi-Fi 接入点生成的 CFR 图像。合成与采样的 CFR 图像对比如图 10 所示，最左边是实际测量值得到的 CFR 图像，另外两个是分别在 SNR=30 dB 和 10 dB 条件下该测试点合成得到的 CFR 图像，可以看出，合成 CFR 图像中每个像素的亮度与局部相似度与实际测量得到的 CFR 图像相似。为了定量比较合成 CFR 图像和测量 CFR 图像的一致性，可计算得到在 SNR=30 dB 时，平均 SSIM 为 0.912 1，在 SNR=10 dB 时，平均 SSIM 为 0.843 6，理论上测量 CFR 图像的平均 SSIM 为 1，这表明在高信噪比条件下，本文采用的合成 CFR 图像方法能够有效地拟合测量结果。




图9 10号测量点和3号Wi-Fi接入点的位置

### 6 结束语

本文研究了 FTTR WLAN 场景下多个室内 Wi-Fi 接入点的位置估计，并提出了一种利用已有的 2.4 GHz Wi-Fi 指纹数据集合成 FTTR WLAN 场景（包含 2.4 GHz 和 5.8 GHz）CFR 图像的方法。基于 CFR 图像，开发了一种基于深度学习的定位算法，包括在训练阶段并行路径的 PCA 处理和定位阶段的 DNN 反演。模拟实验得到的结果表明，与传统的 DNN 算法相比，基于 CFR 图像的位置反演算法训练时间显著缩短，并且定位精度相比已有算法提高约 15%~29%。因此，所提算法相比其他

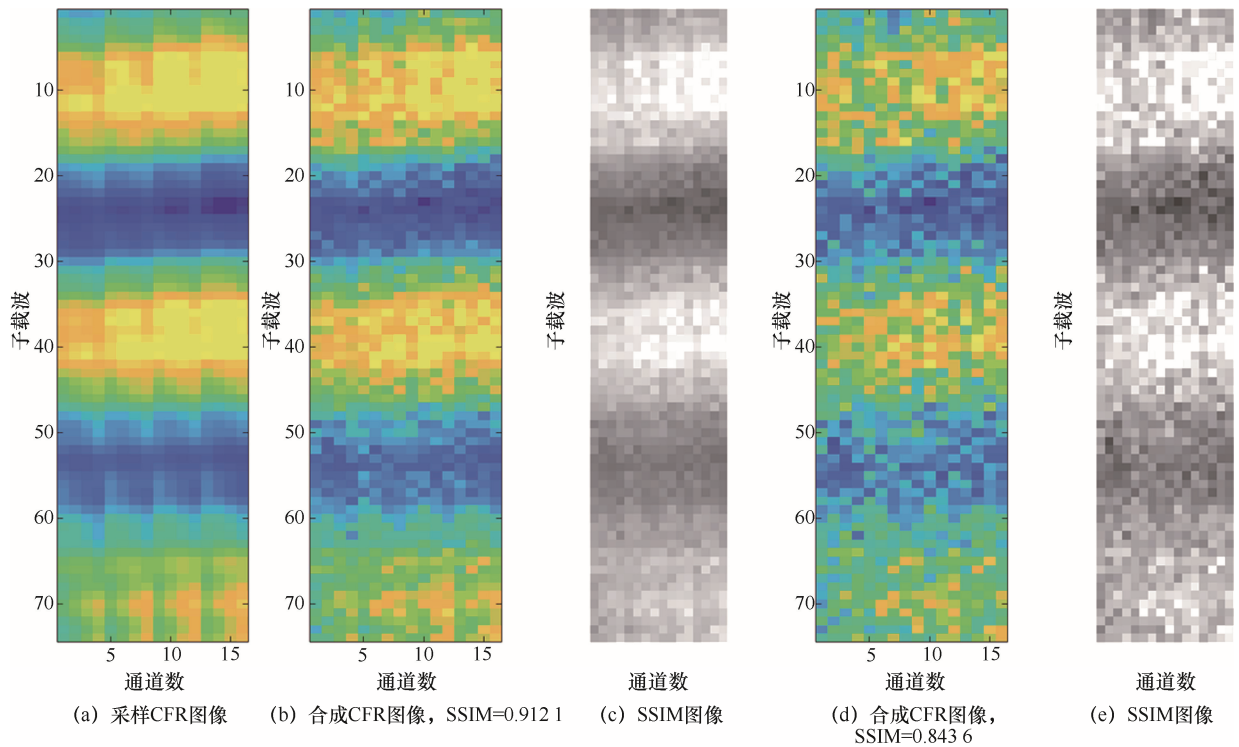


图10 合成与采样的CFR图像对比

先进的方法具有明显的优越性。此外,由于这项工作利用已有的Wi-Fi指纹数据集来合成FTTR WLAN场景数据集,对FTTR接入点和移动终端的距离特征缺乏表征,对环境噪声的适应性研究也亟待处理。在未来的工作中将进一步完善所提算法,提高所设计的定位算法精度。

### 参考文献:

- [1] ZHU X Q, QU W Y, QIU T, et al. Indoor intelligent fingerprint-based localization: principles, approaches and challenges[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(4): 2634-2657.
- [2] ZAFARI F, GKELIAS A, LEUNG K K. A survey of indoor localization systems and technologies[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(3): 2568-2599.
- [3] HE C, LIU Y Q, HUANG Y D, et al. Q-band millimeter wave communication: enabling 10 gb/s home network in fiber-to-the-room scenario[C]//*Proceedings of 2021 IEEE MTT-S International Wireless Symposium (IWS)*. Piscataway: IEEE Press, 2021: 1-3.
- [4] ZHANG Y, QU C, WANG Y J. An indoor positioning method based on CSI by using features optimization mechanism with LSTM[J]. *IEEE Sensors Journal*, 2020, 20(9): 4868-4878.
- [5] ZHANG Y, WU C B, CHEN Y. A low-overhead indoor positioning system using CSI fingerprint based on transfer learning[J]. *IEEE Sensors Journal*, 2021, 21(16): 18156-18165.
- [6] GÖNÜLTAŞ E, LEI E, LANGERMAN J, et al. CSI-based multi-antenna and multi-point indoor positioning using probability fusion[J]. *IEEE Transactions on Wireless Communications*, 2022, 21(4): 2162-2176.
- [7] PINTO B, BARRETO R, SOUTO E, et al. Robust RSSI-based indoor positioning system using K-means clustering and Bayesian estimation[J]. *IEEE Sensors Journal*, 2021, 21(21): 24462-24470.
- [8] SONG Q W, GUO S T, LIU X, et al. CSI amplitude fingerprinting-based NB-IoT indoor localization[J]. *IEEE Internet of Things Journal*, 2018, 5(3): 1494-1504.
- [9] WANG X Y, GAO L J, MAO S W, et al. CSI-based fingerprinting for indoor localization: a deep learning approach[J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(1): 763-776.
- [10] WANG C, LUO J, LIU X, et al. Secure and reliable indoor localization based on multitask collaborative learning for large-scale buildings[J]. *IEEE Internet of Things Journal*, 2022, 9(22): 22291-22303.
- [11] TAO Y, ZHAO L. AIPS: an accurate indoor positioning system with fingerprint map adaptation[J]. *IEEE Internet of Things Journal*, 2022, 9(4): 3062-3073.
- [12] KIM H, GRANSTRÖM K, GAO L, et al. 5G mmWave cooperative positioning and mapping using multi-model PHD filter and map fusion[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(6): 3782-3795.
- [13] BUTT M M, RAO A, YOON D. RF fingerprinting and deep learning assisted UE positioning in 5G[C]//*Proceedings of 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*. Piscataway: IEEE Press, 2020: 1-7.
- [14] CHEN C, CHEN Y, HAN Y, et al. Achieving centimeter-accuracy indoor localization on Wi-Fi platforms: a multi-antenna approach[J]. *IEEE Internet of Things Journal*, 2017, 4(1): 122-134.

- [15] MAGSINO E R, HO I W H, SITU Z H. The effects of dynamic environment on channel frequency response-based indoor positioning[C]//Proceedings of 2017 IEEE 28th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2018: 1-6.
- [16] TSENG P H, CHAN Y C, LIN Y J, et al. Ray-tracing-assisted fingerprinting based on channel impulse response measurement for indoor positioning[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(5): 1032-1045.
- [17] JEON N R, LEE C H, KANG N G, et al. Performance of channel prediction using 3D ray-tracing scheme compared to conventional 2D scheme[C]//Proceedings of 2006 Asia-Pacific Conference on Communications. Piscataway: IEEE Press, 2006: 1-6.
- [18] NAGARAJ S, KHAN S, SCHLEGEL C, et al. Differential preamble detection in packet-based wireless networks[J]. IEEE Transactions on Wireless Communications, 2009, 8(2): 599-607.
- [19] YAN J, QI G W, KANG B, et al. Extreme learning machine for accurate indoor localization using RSSI fingerprints in multi floor environments[J]. IEEE Internet of Things Journal, 2021, 8(19): 14623-14637.
- [20] RAMBHATLA S, LI X G, REN J N, et al. A dictionary-based generalization of robust PCA with applications to target localization in hyper spectral imaging[J]. IEEE Transactions on Signal Processing, 2020, (68): 1760-1775.
- [21] NJIMA W, BAZZI A, CHAFII M. DNN-based indoor localization under limited dataset using GANs and semi-supervised learning[J]. IEEE Access, 2022(10): 69896-69909.
- [22] CHEN C Y, LAI A I C, WU P Y, et al. Optimization and evaluation of multi detector deep neural network for high-accuracy Wi-Fi fingerprint positioning[J]. IEEE Internet of Things Journal, 2022, 9(16): 15204-15214.
- [23] SHI J, WANG G, JIN L P. Least squared relative error estimator for RSS based localization with unknown transmit power[J]. IEEE Signal Processing Letters, 2020(27): 1165-1169.
- [24] WATANABE F. Wireless sensor network localization using AoA measurements with two-step error variance-weighted least squares[J]. IEEE Access, 2021(9): 10820-10828.
- [25] YU X F, HU X, LIU Z J, et al. A method to select optimal deep neural network model for power amplifiers[J]. IEEE Microwave and Wireless Components Letters, 2021, 31(2): 145-148.
- [26] TÓTH Z, TAMÁS J. Miskolc IIS hybrid IPS: dataset for hybrid indoor positioning[C]//Proceedings of 2016 26th International Conference Radioelektronika (RADIOELEKTRONIKA). Piscataway: IEEE Press, 2016: 408-412.
- [27] WEI W, YAN J, WU X F, et al. CSI fingerprinting for device-free localization: phase calibration and SSIM-based augmentation[J]. IEEE Wireless Communications Letters, 2022, 11(6): 1137-1141.
- [28] LI S, LEI W M, ZHANG W, et al. Weighted TSVR based nonlinear channel frequency response estimation for MIMO-OFDM system[J]. IEEE Access, 2020(8): 224283-224291.
- [29] THENUARDI D S, SOEWITO B. Indoor positioning system using WKNN and LSTM combined via ensemble learning[J]. Advances in Science, Technology and Engineering Systems Journal, 2020, 6(1): 242-249.
- [30] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [31] CHOLLET F. Xception: deep learning with depth wise separable convolutions[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 1800-1807.

## [作者简介]



龙智丰（2000- ），男，华中科技大学电子信息与通信学院硕士生，主要研究方向为无线通信、室内定位。



张靖（1975- ），男，博士，华中科技大学电子信息与通信学院副教授，主要研究方向为无线通信、绿色通信、短距接入网络、光网络和无线网络融合、下一代通信网络等。