

# 基于 LTE 网络的室外指纹定位

李 达 雷迎科 张海川

国防科技大学电子对抗学院 合肥 230000

(gfkdlida@163.com)

**摘 要** 由于在复杂环境中可以取得良好的定位效果,基于指纹的定位技术一直是研究的热点。通过利用长期演进(Long Term Evolution,LTE)网络,一种基于深度学习的指纹定位方法被提出用来构建良好的定位系统。受到计算机视觉技术的启发,带有地理位置标记的信号指纹被转化为灰度图片然后进行定位,并以最终构建好的灰度图片数据集的分类准确率来表示定位的准确率。文中采用了一种两级分步训练的方法来实现深度神经网络(Deep Neural Network,DNN)的分类识别。首先,利用深度残差网络(Deep Residual Network,Resnet)对指纹库进行预训练并得到粗糙定位模型,然后利用基于反向传播神经网络(Back Propagation Neural Network,BPNN)的迁移学习算法进一步提取信号特征并得到精确定位模型。实验在真实室外环境下进行,且实验结果表明提出的定位系统可以在室外环境下取得较高精度的定位效果。

**关键词:** 室外定位;指纹定位;深度学习;LTE 网络;迁移学习

**中图分类号** TP391.4

## Outdoor Fingerprint Positioning Based on LTE Networks

LI Da, LEI Ying-ke and ZHANG Hai-chuan

College of Electronic Engineering, National University of Defense Technology, Hefei 230000, China

**Abstract** Owing to the satisfactory positioning accuracy in complex environments, fingerprint-based positioning technology has always been a hot topic of research. By leveraging long term evolution (LTE) signals, a deep learning based outdoor fingerprint positioning method is proposed to construct a positioning system. Inspiring by the computer vision technology, the geo-tag signals are converted into gray scale images for positioning. The positioning accuracy is expressed by the classification accuracy of the constructed gray image dataset. In this paper, a two-level training architecture is developed to realize the classification of deep neural network (DNN). First, a deep residual network (Resnet) is used to pre-train the fingerprint database and obtain a rough positioning model. Then, a transfer learning algorithm based on back propagation neural network (BPNN) is used to further extract signal features and obtain an accurate positioning model. The experiment is conducted in a real outdoor environment, and the experiment results show that the proposed positioning system can achieve a satisfactory positioning accuracy in complex environments.

**Keywords** Outdoor positioning, Fingerprint positioning, Deep learning, LTE signal, Transfer learning

### 1 引言

近年来随着用户手机中传感器的增多以及各种定位技术的发展,基于智能手机进行定位的技术越来越受到人们的重视<sup>[1]</sup>。卫星导航定位(如北斗导航定位)的成功应用使得人们可以在全世界各地自由出行,然而在拥挤的城市或者较差的气象条件下其往往不能提供一个令人满意的定位效果。当卫星导航信号经历非视距传播(如信号被房屋或者树木遮挡)时,其定位能力往往会严重下降,并且卫星导航定位技术能耗较高<sup>[2]</sup>。

随着长期演进(Long Term Evolution,LTE)信号和智能手机的普及,利用 LTE 信号和智能手机进行定位成为可能<sup>[3]</sup>。不同地理位置有不同的地理特征,不同环境也具有独特的信号特征。指纹定位可以通过利用环境独特的信号特征与预定义的地理标记相匹配来实现<sup>[4]</sup>。

传统基于 LTE 信号定位的方法利用信号到达角度 (An-

gle of arrival, AOA)、信号到达时间 (Time of arrival, TOA)、信号时间到达时间差 (Time difference of arrival, TDOA),或者利用如 TOA/AOA 和 TDOA/AOA 等混合方法进行定位<sup>[5-6]</sup>。然而这些传统的定位技术要求具有特殊的设备,且对用户设备与基站的同步性要求较高,这些定位方式在信号非视距传播时定位精度较低。基于智能手机的指纹定位技术有很多优点,首先,智能手机中接收 LTE 信号的芯片具有低功耗电量,即使在手机不断接收信号的情况下,其耗电量仍然很低。大多数基于智能手机的信号指纹定位技术不需要额外的硬件或者基础设施进行辅助,因此其相比于其他定位方式,可以很大程度地节省成本<sup>[7]</sup>。此外即使信号处于非视距传播,指纹定位技术仍然能取得较高的定位精度<sup>[8]</sup>。

在我们周围环境中有很多复杂的特征,指纹定位的目的就是找到这些特征并与相应的地理位置相匹配来确定用户设备的位置<sup>[9]</sup>。由于智能手机设备传感器众多,其定位技术种类也较多,其中基于指纹定位主要有 3 种方式,分别是基于视

觉指纹的定位、基于动作的指纹定位以及基于信号指纹定位<sup>[4]</sup>。随着图片处理技术的快速发展,各种各样的图片特征被提取出来与地理位置相匹配进行定位。谷歌提出了图像搜索技术对用户设备进行定位<sup>[10]</sup>,在定位时,该技术通过提取新输入的图片特征与图片特征库相匹配来识别用户位置<sup>[11]</sup>。然而,由于在收集视觉指纹工作量和在定位阶段搜索量巨大,因此基于视觉定位的方法难以进行大规模的室外定位。随着加速度计和电子罗盘等移动传感器的增多,我们可以利用这些传感器来进行动作识别。基于运动指纹定位的基本思想是构建一个指纹数据集,该数据集将运动传感器的特征与地理位置结合在一起,然后在定位阶段将传感器的特征与位置进行匹配。由于其定位信息有限,通常利用运动指纹作为辅助定位的手段<sup>[12-13]</sup>。近些年随着智能手机和 LTE 基站的广泛普及,为室外定位提供了新的方法手段。基于信号指纹技术的基本思想是找到地理标记信号特征,例如信道状态信息(Channel State Information, CSI)、接收信号强度指示(Received Signal Strength Indication, RSSI)、参考信号接收功率(Reference Signal Receiving Power, RSRP)和参考信号接收质量(Reference Signal Receiving Quality, RSRQ)等,然后将它们与预定义的带有地理标记的信号指纹数据库进行匹配以找到用户设备的位置<sup>[14-16]</sup>。一些研究利用 LTE 基站与用户设备之间的 CSI 进行定位,然而这种方式需要昂贵的信号采集器和巨大的采集工作量,因此这种定位技术代价较大。

近些年,深度学习在各个领域都取得了长足的发展,并在特征提取、图片识别等方面有着十分优越的表现<sup>[17]</sup>。因此,本文利用深度残差网络(Deep Residual Network, Resnet)和迁移学习方法提供了一个低成本、高精度的室外复杂环境下的定位方法。由于深度学习在图片识别的成功应用,在本文利用 RSSI, RSRP 和 RSRQ 构建了一种新型图片指纹进行定位。在应用指纹定位技术进行定位时,最大的阻碍是 LTE 信号的不稳定。因此本文首先用 Resnet 进行粗糙定位,在取得最好的定位效果后,冻结 Resnet 的参数。然后利用基于 BPNN 的迁移学习的方法继续学习图片指纹特征以进一步提高对位置指纹的识别率。为了进一步提高定位精度,我们使用了一些数据增强的方法。首先我们将指纹图片扩展为  $224 \times 224$  大小,这可以使得 Resnet 更好地进行图片特征的学习。此外,为了增强指纹库的多样性,我们将指纹图片随机旋转  $15^\circ$ ,并将指纹图片尺寸扩大为原图片的 1.25 倍。在神经网络训练时,我们将惯量项加入批量正规化中以加速网络收敛速度和减少训练误差的波动。为了增加 Resnet 的特征学习能力,我们在 Resnet 后加入了线性网络层,并对比了不同层数和神经元数对 Resnet 定位的影响。在定位阶段,我们提出了一种基于概率的用户位置预测方法。

本文主要贡献总结如下:1)相比于其他传统指纹定位方法,本文提出了利用计算机视觉的方式进行信号指纹库的构建;2)本文提出了利用基于 Resnet 和迁移学习的两级分层训练方式来充分提取指纹特征,所提出的定位系统可以有效提升指纹识别能力;3)由于采集数据量有限,栅格分类较多,因此我们采用了几种数据增强的方式以增加指纹库的多样性,这在一定程度上可以缓解采集信号指纹的工作量;4)为检验本文提出方法的可行性,我们在室外真实环境下进行了测试。实验结果表明,本文提出的定位系统可以在复杂环境下取得

了令人满意的定位效果。

## 2 系统结构

如图 1 所示,我们提出的指纹定位系统由以下 5 个模块构成,分别是:LTE 信号预处理、指纹划分、指纹图片构造、DNN 训练和 DNN 定位。其中用于定位的信息包括 LTE 信号特征和相应的地理位置标签。在 DNN 训练完成后,DNN 模型库储存了 Resnet 和迁移学习的模型用以定位。本文定位使用的 LTE 信号数据包括 RSSI, RSRP 和 RSRQ。

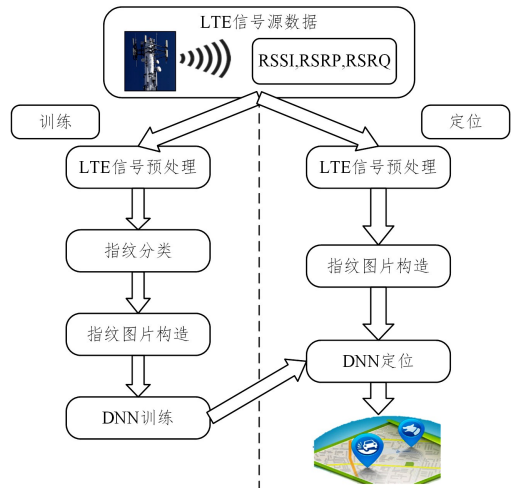


图 1 室外定位系统结构示意图

Fig. 1 Structure diagram of outdoor positioning system

### 2.1 LTE 信号预处理模块

接收基站的原始信号 RSSI 和 RSRP 的值在  $-40$  dBm 到  $-140$  dBm 之间。信号预处理的目的是可以使信号数值符合红绿蓝(Red, Green and Blue, RGB)图片三通道矩阵数值的要求。而 RGB 图片三通道矩阵中的数值在  $0 \sim 255$  之间,因此我们将信号做如下处理:

$$v_i = (RSSI + 150) \quad (1)$$

$$v_p = (RSRP + 150) \quad (2)$$

$$v_q = \sqrt{\frac{1}{N} \sum_{i=1}^N (RSRQ - \overline{RSRQ})^2} \quad (3)$$

其中,  $v_i$ ,  $v_p$  和  $v_q$  分别为 RSSI, RSRP 和 RSRQ 经数据预处理后的值,且  $\overline{RSRQ} = \frac{1}{N} \sum_{i=1}^N RSRQ_i$ 。

### 2.2 指纹划分模块

为了构建与环境相匹配的信号指纹地图,用户手持设备在真实环境中收集信号。在收集完成后,指纹分类模块将收集信号的区域均等地分为几十个栅格,每个栅格表示一类信号。在用概率方式进行定位时,栅格的大小在一定程度上决定了定位的精度,本文将栅格划分为  $20 \text{ m} \times 20 \text{ m}$ 。

### 2.3 DNN 训练模块

由于带有标记的指纹较少,并需要较高的定位精度,因此,我们利用了几种数据增强的方式并采用 DNN 两级分层训练的方式来充分学习信号特征。

DNN 的训练有两个步骤,首先我们利用 Resnet 对指纹图片进行预训练,在得到 Resnet 定位模型后,保留 Resnet 预训练模型参数;然后利用基于 BPNN 的迁移学习进一步提取信号指纹特征。

## 2.4 DNN 定位模块

定位阶段包括了 Resnet 的粗糙定位和基于迁移学习的精确定位。我们利用 Resnet 对构建好信号指纹图片特征学习并进行粗糙定位。在进行精确定位时,基于 BPNN 的迁移学习模型通过利用 Resnet 模型的先验信息来进行更精确的定位。DNN 输出的结果为预测正确栅格的概率。在实验阶段本文对比了基于 Resnet 的粗糙定位器与基于迁移学习的精确定位器之间定位精度的差别。

## 3 指纹图片的构建

传统信号指纹定位方法通常利用信号原始数据进行指纹库的构建,本文提出了一种新型的基于计算机视觉的方法来构建信号指纹库。通常一个普通的 RGB 图片包括分别为红绿蓝三通道的矩阵,若这 3 个通道的矩阵数值都相同,则该图片即为灰度图片。我们将收集好的信号转换为灰度图片进行指纹库的构建。

在收集好 LTE 信号后,我们使用由 RSSI, RSRP 和 RSRQ 信息组成的 3 个列向量来形成一个灰度图像。为了使用图片进行输入,图像的尺寸必须归一化为相同的大小。在每个栅格中,我们将收集好的信号数据分为多个子数据集,并利用子数据集来构建指纹图片。以 R 通道为例,部分指纹图片可以表示如下:

$$\boldsymbol{\varphi} = [v_{i1}, v_{i2}, \dots, v_{in0}]^T \quad (4)$$

$$\boldsymbol{\psi} = [v_{p1}, v_{p2}, \dots, v_{pn0}]^T \quad (5)$$

$$\boldsymbol{\gamma} = [v_q, v_q, \dots, v_q]^T \quad (6)$$

$$\mathbf{F} = [\boldsymbol{\varphi}, \boldsymbol{\psi}, \boldsymbol{\gamma}] \quad (7)$$

其中,  $n$  表示子数据集的长度,  $\mathbf{F}$  为 R 通道的矩阵表示。在构建好 R 通道后, G 和 B 通道和 R 通道构建方式相同,即  $\mathbf{F} = \mathbf{R} = \mathbf{G} = \mathbf{B}$ 。至此通过构建 RGB 三通道矩阵即可得到一张信号指纹灰度图片。

## 4 DNN 训练模块

定位精度会由于训练方式的变化而发生很大变化。为了取得高精度的定位效果,应充分提取特征和训练网络。在本文中 DNN 模型包括 Resnet 模型和迁移学习模型,我们将它们分开来训练。

DNN 的训练次数会极大地影响 DNN 的表现,低次数的训练会导致 DNN 不能充分地学习指纹特征,最终导致低精度的定位。然而,过高次数的训练会导致 DNN 出现过拟合的问题<sup>[18-19]</sup>。我们将数据集分为 60% 的训练集、20% 的验证集和 20% 的测试集。在每一次训练完成后,我们对测试集进行测试,并保留精度最好的模型作为最终定位模型。图 2 表示随着训练次数的增多 DNN 模型不断地学习数据集的特征,测试集精度先上升,在出现过拟合问题后,测试集的精度开始下降。

为了更充分地学习信号特征,我们采用了几种数据增强的方式。首先将构建好的指纹图片标准化为  $224 \times 224$  大小,这使得 DNN 能够更好地提取特征。然后,我们在训练集中将图片将部分图片扩大为 1.25 倍,并随机旋转  $15^\circ$ 。此外,在 DNN 中加入了动量项以加快网络的收敛速度并提升网络表现。

迁移学习有很多优点:第一,它可以很大程度上减少训练成本;第二,迁移学习对于小数据集的识别效果提升明显<sup>[20]</sup>。在本文中,转移学习的基本思想体现在将训练好的 Resnet 模型参数进行保留,然后将 Resnet 的先验知识应用于对 BPNN 模型的训练从而完成对指纹库特征的学习。




图 2 DNN 精度随训练次数变化的示意图

Fig. 2 Structure diagram of DNN accuracy changes with training epochs

## 5 DNN 定位模块

本文首先用由若干个残差模块、一个池化层、Flatten 层和一个 BPNN 组成的 Resnet 进行粗糙定位;然后利用训练好 Resnet 模型的先验知识,使用基于 BPNN 的迁移学习进行更加精确的定位。本节将介绍 DNN 算法和定位模块的相关理论。

### 5.1 深度残差网络介绍

随着神经网络的层数加深,网络会具有更强的学些能力。然而,由于梯度弥散和梯度爆炸等问题的存在,很多时候更深层的网络学习能力不如浅层网络。为了解决这些问题,He 等<sup>[21]</sup>提出了残差学习的概念。假设神经网络的子模块需要学习的函数为  $H(x)$ ,然而这个函数对于神经网络子模块可能过于复杂而难以学习。我们让这个子模块学习残差:  $F(x) = H(x) - x$ ,因此原目标映射就变为  $F(x) + x$ ,子模块由两部分组成:一部分为  $x \rightarrow x$  的线性直接映射,另一部分为  $F(x)$  的非线性映射。如果线性映射  $x \rightarrow x$  取得的效果最佳,网络就会将非线性映射  $F(x)$  变为 0。深度残差网络由多个这样的残差学习模块组成。残差学习模块如图 3 所示。




图 3 Resnet 残差单元

Fig. 3 Resnet residual unit

图 4 为本文提出的 Resnet 结构示意图。其包含了 1 个基本模块 1, 4 个基本模块 2 和 3 个基本模块 3。每一个基本模块均为残差模块,在进行训练发生梯度弥散等问题时,网络会自动跳过残差模块并继续进行训练。网络参数传递至平均池化层时,其对训练参数进行降维从而加速网络训练速度并防止网络过拟合。Flatten 层的目的是将多维输入转化为一维输入,从而可以更好地实现从平均池化层到全连接层的链接。

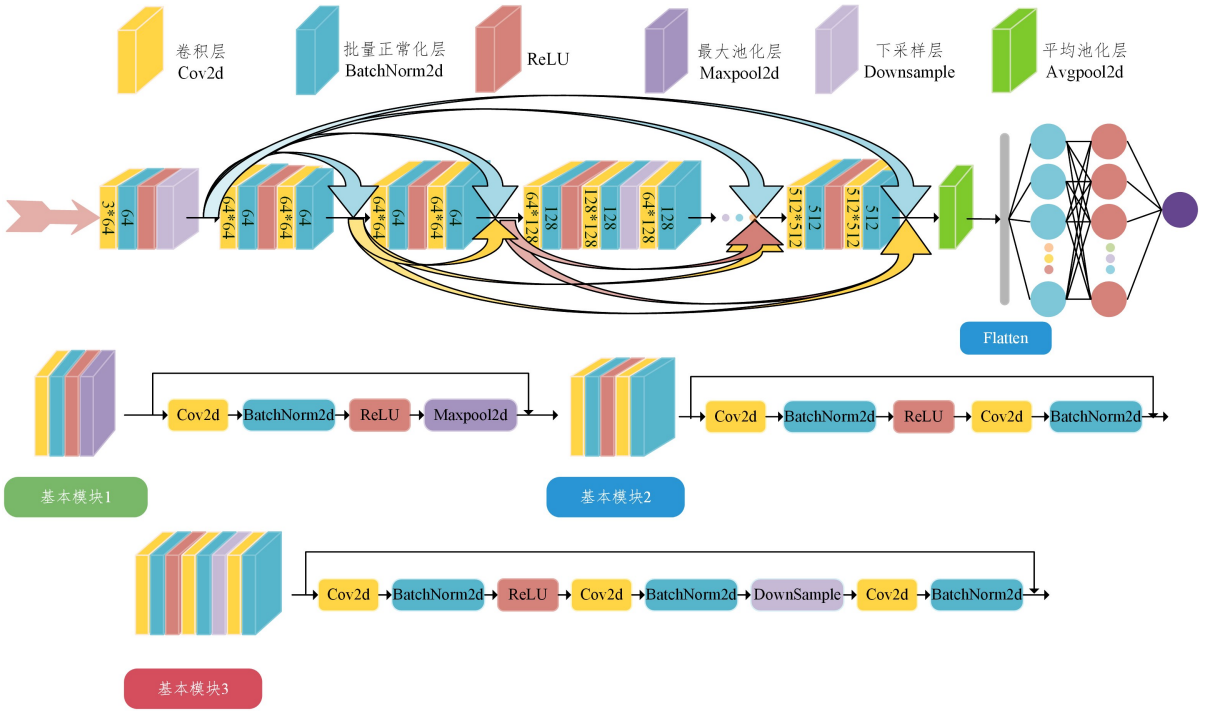


图 4 Resnet 整体结构

Fig. 4 Resnet overall structure

最后我们用基于全连接层的 BPNN 来进一步提取指纹图片特征。全连接层的输出可以通过对输入进行加权求和并传递激活函数得到。在误差反向传播阶段,系统通过最小化交叉熵并利用自适应矩估计 (Adaptive moment estimation, Adam) 算法来更新权重。网络每一层具体计算过程可参考文献[17,19]。

最终,我们用 Softmax 和 argmax 函数来估计提取的特征并给出最终概率估计位置结果。然后利用 argmax 函数来提取概率最高的栅格位置作为最终位置。

### 5.2 迁移学习介绍

在训练好 Resnet 后,利用基于 BPNN 的迁移学习模型来进一步提高定位精度。迁移学习的方法可以分为两步:首先,将训练好 Resnet 的参数进行冻结;接下来,将 BPNN 加入到 Resnet 后再次训练网络。图 5 为本文提出 DNN 的整体结构。




图 5 DNN 整体结构

Fig. 5 DNN overall structure

在训练迁移学习模型时,Resnet 的网络参数保持不变,仅仅改变新加入 BPNN 的模型参数。在训练时同样使用交叉熵损失和 Adam 算法来调整更新模型参数。


## 6 实验与结果

如图 6 所示,本次实验在室外环境下进行,红色线表示信号采集地点示意图。值得注意的是本次实验的绝大多数场景

都存在信号非视距传播情况,这在一定程度上加大了定位的难度。在收集数据时,用户手持智能手机从 LTE 基站中接收信号。在划分栅格时,我们将栅格的大小定为  $20\text{ m} \times 20\text{ m}$ 。我们在每个栅格中随机选取 3 到 5 个位置进行信号收集。



(a)室外定位卫星图



(b)室外定位实景图



(c)室外定位实景图

图 6 室外定位场景(电子版为彩色)

Fig. 6 Scenario of outdoor positioning

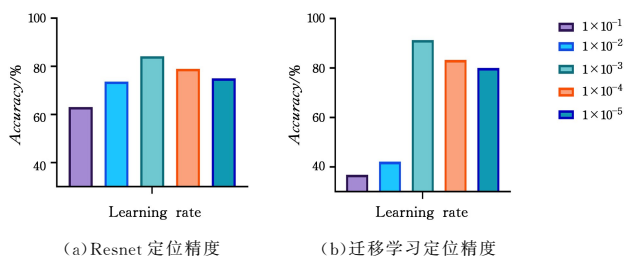


图 7 定位准确率随 Lr 的变化

Fig. 7 Positioning accuracy with respect to Lr

学习速率(Learning rate, Lr)是深度学习中重要的超参数,它决定了网络收敛的速度和目标函数能否收敛到全局最小值。如图7所示,当Lr减少时,测试集准确率先增加然后减少。在进行网络训练时,我们发现当Lr过大时,网络训练误差在最小值附近剧烈震动,难以收敛。当Lr设置得过小时,网络收敛速度变得非常慢,这极大地增加了网络训练时间,且由于网络没有收敛与全局最小解的位置,使得测试集精度不高。如图7所示,我们选择 $1 \times 10^{-3}$ 作为网络的Lr。

在利用Adam算法进行网络微调时,不同训练批次(batch size, BS)大小会对定位精度产生不同的影响。较小的BS会导致网络训练误差震荡,导致网络不稳定;较大的BS会导致网络泛化能力变差。图8和图9分别为Resnet粗糙定位和经过迁移学习改善后的定位准确率随训练集大小和BS大小的变化。 $\gamma$ 为训练集占数据集的比例, $\eta$ 表示BS大小。从图7和图8中可以发现,迁移学习对整体定位精度提升效果十分明显,在 $\gamma$ 为80%, $\eta$ 为16时取得最大定位精度。因此,我们选择这两个参数作为本文DNN的参数。




图8 Resnet室外定位准确率随 $\gamma$ 和 $\eta$ 的变化

Fig. 8 Outdoor positioning accuracy of transfer learning with respect to  $\gamma$  and  $\eta$




图9 迁移学习室外定位准确率随 $\gamma$ 和 $\eta$ 的变化

Fig. 9 Outdoor positioning accuracy of transfer learning with respect to  $\gamma$  and  $\eta$

神经网络隐含层的层数和神经元个数会对神经网络的表现产生重要影响。图10为Resnet粗糙定位的定位效果,我们对比了不同层数和不同神经元个数的Resnet对定位精度的影响。 $\mu$ 表示隐含层的层数, $\lambda$ 为每个隐含层神经元的数量。如图10所示,随着隐含层层数或神经元个数的增加,定位准确率都是先增加后减少。原因可能在于,随着Resnet后MLP层的隐含层层数或神经元个数增加,网络学习能力变强,但随着网络进一步加深出现了过拟合现象,导致定位精度下降。

本文研究了迁移学习对Resnet精度的提升,图11为经过迁移学习后DNN的定位精度。从图10与图11中可以发现,迁移学习对Resnet的定位精度提升2.8%到30.3%不等,这说明迁移学习对整体的定位效果提升十分明显。我们

选择含有2层隐含层MLP的Resnet和基于BPNN的迁移学习作为本文的最终DNN模型。经过迁移学习对Resnet网络的改良,本文DNN模型在 $20\text{m} \times 20\text{m}$ 的栅格条件下最大定位精度概率达到了91.7%。




图10 Resnet室外定位准确率随隐含层层数 $\mu$ 与神经元数量 $\lambda$ 的变化

Fig. 10 Outdoor positioning accuracy of Resnet with respect to  $\mu$  and  $\lambda$




图11 迁移学习室外定位准确率随隐含层层数 $\mu$ 与神经元数量 $\lambda$ 的变化

Fig. 11 Outdoor positioning accuracy of transfer learning with respect to  $\mu$  and  $\lambda$




图12 不同学习算法的定位准确率

Fig. 12 Positioning accuracy with different learning algorithms

本文选取了多个经典信号指纹定位方案进行定位精度比较,包括利用信号原始数据进行定位的多层感知机算法(Multilayer Perceptron, MLP)、最近邻算法(k-Nearest Neighbor, KNN)、利用指纹图片进行定位的卷积神经网络(Convolution Neural Network, CNN)算法。其中多层感知机含有3个全连接层,每个全连接层含有200个神经元。卷积神经网络含有3个卷积层、3个批量正常化层以及3个激活函数层。实验结果可以看出,在本文实验场景下,本文算法的定位精度最高,达到了91.7%。这证明了本文采用的信号图片指纹库的有效性,并且本文提出的神经网络模型学习能力更强、定位准确率更高。

**结束语** 本文在现有信号指纹定位技术的基础上提出了一种基于深度学习的信号指纹图片定位系统。无须用户携带专用设备,仅依赖智能手机即可实现对自身进行定位,这在降低成本的同时提高了普适性。本文将LTE信号转换为灰度图片进行指纹库的构建。在进行深度学习网络训练时,本文

采用了一种分层的训练方法使得 DNN 可以充分地有限的指纹图片进行特征学习。首先利用 Resnet 对信号指纹库进行预训练,通过保留 Resnet 预训练模型,然后利用 BPNN 对 Resnet 的先验知识进行迁移学习,以进一步提高定位精度。同时本文采用了几种数据增强方法来增加指纹库的多样性,这在一定程度上可以克服 LTE 信号不稳定的问题。实验结果表明,本文提出的系统可以在较为复杂环境中发挥出高精度的定位效果。接下来的工作中,我们会在改进算法提高定位准确率的同时继续探索其他指纹定位方案,为研究轨迹跟踪提供一定基础。

### 参 考 文 献

- [1] LIU J, CHEN R, LING P, et al. A Hybrid Smartphone Indoor Positioning Solution for Mobile LBS[J]. *Sensors*, 2012, 12(12): 17208-17233.
- [2] DEDES G, DEMPSTER A G. Indoor GPS positioning-challenges and opportunities[C]// *IEEE Vehicular Technology Conference*. 2005.
- [3] LI J, WANG X, FENG D, et al. Share in the Commons; Coexistence between LTE Unlicensed and Wi-Fi[J]. *IEEE Wireless Communications*, 2016, 23(6): 16-23.
- [4] VO Q D, DE P. A Survey of Fingerprint based Outdoor Localization[J]. *IEEE Communications Surveys & Tutorials*, 2015, 18(1): 491-506.
- [5] SHAOCHUAN W, YUZE W, WEN C. A Gossip-based AOA Distributed Localization Algorithm for Wireless Sensor Networks[C]// *International Symposium on Instrumentation & Measurement*. IEEE, 2014.
- [6] WANG Y, HO V. An Asymptotically Efficient Estimator in Closed-Form for 3D AOA Localization Using a Sensor Network[J]. *IEEE Transactions on Wireless Communications*, 2015, 14(12): 6524-6535.
- [7] LI J, JU H, LONG Y, et al. Exploiting multiple access points diversity gain in the multi-access wireless network[C]// *2013 IEEE 24th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications(PIMRC)*. IEEE, 2013: 1710-1714.
- [8] ZHANG W, LIU K, ZHANG W, et al. Deep Neural Networks for Wireless Localization in Indoor and Outdoor Environments[J]. *Neurocomputing*, 2016, 194: 279-287.
- [9] SHAO W, LUO H, ZHAO F, et al. Indoor positioning based on fingerprint-image and deep learning[J]. *IEEE Access*, 2018, 6: 74699-74712.
- [10] "Google Goggles." [OL]. Available; <http://www.google.com/mobile/goggles/>.
- [11] SCHROTH G, HUITL R, CHEN D, et al. Mobile Visual Location Recognition[J]. *IEEE Signal Processing Magazine*, 2011, 28(4): 77-89.
- [12] ZHU X, LI Q, CHEN G. APT: Accurate outdoor pedestrian tracking with smartphones[C]// *INFOCOM, 2013 Proceedings IEEE*. IEEE, 2013.
- [13] BELMONTE-HERNANDEZ A, HERNANDEZ-PENALOZA G, GUTIERREZ D M, et al. SWiBluX: Multi-Sensor Deep Learning Fingerprint for precise real-time indoor tracking[J]. *IEEE Sensors Journal*, 2019, 19(9): 3473-3486.
- [14] YE X, YIN X, CAI X, et al. Neural-network-assisted UE Localization Using Radio-channel Fingerprints in LTE Networks[J]. *IEEE Access*, 2017, 5: 12071-12087.
- [15] YIU S, DASHTI M, CLAUSSEN H, et al. Wireless RSSI fingerprinting localization[J]. *Signal Processing*, 2016, 131: 235-244.
- [16] 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.
- [17] XING H, ZHANG G, SHANG M. Deep Learning[J]. *International Journal of Semantic Computing*, 2016, 10(3): 417-439.
- [18] ZHONG J, YANG B, LI Y, et al. Image Fusion and Super-Resolution with Convolutional Neural Network[C]// *Chinese Conference on Pattern Recognition*. Springer, Singapore, 2016: 78-88.
- [19] JÜRGEN S. Deep learning in neural networks: An overview[J]. *Neural Networks*, 2015, 61: 85-117.
- [20] LU J, BEHBOOD V N, HAO P, et al. Transfer learning using computational intelligence: A survey[J]. *Knowledge-Based Systems*, 2015, 80: 14-23.
- [21] HE K, ZHANG X, REN S, et al. Identity Mappings in Deep Residual Networks[C]// *European Conference on Computer Vision*. Cham; Springer, 2016: 630-645.



**LI Da**, Ph.D. His main research interests include signal processing, neural networks, and machine learning.



**LEI Ying-ke**, Ph.D professor. His main research interests include neural network, location-based services, and communication radiation source identification.