

DOI: 10.19650/j.cnki.cjsi.J2412878

# 基于多通道图像的 ECA-CNN WiFi FTM 室内定位算法\*

刘 林<sup>1,2</sup>, 廖子阳<sup>2</sup>

(1. 极端环境岩土和隧道工程智能建养全国重点实验室(中铁一院) 西安 710043; 2. 西南交通大学信息编码与传输四川省重点实验室 成都 611756)

**摘要:** IEEE 802.11-2016 定义了精细时间测量 (FTM) 协议, 利用信号往返时间 (RTT) 实现 WiFi 室内定位, 以期达到米级定位精度。但在非视距或多径环境下, RTT 测距精度下降, 严重影响定位性能。因此, 为了提高 RTT 定位精度, 提出了一种将多个无线接入点 (AP) 测得的 WiFi RTT 测距序列转换为多通道图像的方法, 基于多通道图像采用有效通道注意力机制卷积神经网络 (ECA-CNN) 学习测距数据与目标位置之间的关系, 实现位置估计。实验结果表明, 提出的定位模型与常规深度神经网络 (DNN) 定位模型、基于单通道图像的卷积神经网络 (SCI-CNN) 定位模型和基于单通道图像的有效通道注意力机制卷积神经网络 (SCI-ECA-CNN) 定位模型相比, 模型的平均定位误差约为 1 m, 分别比上述模型降低了 31.03%、16.78% 和 10.68%。

**关键词:** 室内定位; 注意力机制; 卷积神经网络; 精细时间测量

中图分类号: TH89 文献标识码: A 国家标准学科分类代码: 510.40

## An ECA-CNN algorithm based on multi-channel image for WiFi FTM indoor positioning

Liu Lin<sup>1,2</sup>, Liao Ziyang<sup>2</sup>

(1. State Key Laboratory of Intelligent Construction and Maintenance for Geotechnical and Tunnel Engineering under Extreme Environments (FSDI), Xi'an 710043, China; 2. Provincial Key Lab of Information Coding and Transmission, Southwest Jiaotong University, Chengdu 611756, China)

**Abstract:** IEEE 802.11-2016 defines the fine time measurement protocol, which uses signal round trip time (RTT) to achieve indoor WiFi positioning accuracy at the meter level. However, in non line of sight or multipath environments, the accuracy of RTT ranging decreases, which seriously affects the positioning performance. To improve the accuracy of RTT positioning, this article proposes a method to convert the WiFi RTT ranging sequences measured by multiple access points into the multi-channel image, and uses an efficient channel attention-convolutional neural network to learn the relationship between the ranging data and the target position based on the multi-channel image. The experiments show that the positioning error of the proposed model is about 1 m, and 31.03%, 16.78%, and 10.68% less than the conventional deep neural networks positioning, the single-channel-image-based CNN positioning, and the single-channel-image-based ECA-CNN positioning, respectively.

**Keywords:** indoor positioning; attention mechanism; convolutional neural network; fine time measurement

## 0 引 言

随着 5G 通信技术的发展, 智慧安防、智慧医院、智慧城市等对基于位置的服务需求越来越迫切。由于 WiFi 部署广泛且成本低, 信号容易获取, 迅速成为室内定位的主流技术。WiFi 定位技术通常采用信号指纹 (received signal strength, RSS) 定位<sup>[1-3]</sup> 以及 RSS 与其他

定位技术的融合定位<sup>[4-6]</sup>。RSS 对环境比较敏感, 定位精度受环境因素影响比较大。因此, 2016 年 IEEE 提出了基于精细时间测量 (fine time measurement, FTM) 协议的 WiFi 定位。

根据目前关于 WiFi FTM 定位的研究可知, 在视距 (line of sight, LOS) 环境下, 利用 WiFi 信号往返时间 (round trip time, RTT) 的测距结果与实际距离之间存在着稳定偏差<sup>[7-8]</sup>, 在经过误差校准后, 能够提供精度为米

收稿日期: 2024-05-23 Received Date: 2024-05-23

\* 基金项目: 国家自然科学基金高铁联合基金 (U2268201) 项目资助

级的测距结果<sup>[9-10]</sup>。但在室内非视距 (none line of sight, NLOS) 环境中, 信号通过物体的反射、折射等进行传播, 存在比较严重的多径效应, 使得 WiFi FTM 定位系统难以准确判断测距信号到达时间, 导致测距结果通常远大于真实距离<sup>[9,11]</sup>。室内复杂环境下 NLOS 对 WiFi RTT 定位的影响仍是 WiFi FTM 定位技术面临的一大挑战。

为了降低非视距环境对 RTT 测距的影响, Sun 等<sup>[12]</sup>通过对实际测距误差的分析, 建立了非视距测距误差补偿模型。论文采用增强遗传算法 (enhanced genetic algorithm, EGA) 同时寻找最佳位置和误差补偿项, 一定程度上减轻了非视距误差对定位精度的影响, 定位误差为 2 m 左右。Gentner 等<sup>[13]</sup>提出一种利用混合高斯距离估计误差模型校准 WiFi RTT 测量距离的方法, 一定程度上可以提高定位精度。唐翔宇等<sup>[14]</sup>提出利用核密度估计法 (kernel density estimation, KDE) 从原始测距数据集中估计测距结果, 通过最小二乘法求解粗定位结果, 然后利用贝叶斯优化算法对粗定位结果进行若干次迭代, 得到最终的预测位置。该文献的定位算法建立在大量采集 WiFi RTT 测距数据的基础上, 实现一次定位需要采样 100 次, 而 Google 推荐产品的采样间隔不低于 200 ms<sup>[15]</sup>, 这意味着在 Google Pixel 手机上运行该算法实现一次定位的用时将超过 20 s, 低实时性使得该算法的实用性不高。Yu 等<sup>[16]</sup>提出了一种 WiFi RTT 结合行人航位推算 (pedestrian dead reckoning, PDR) 的无迹卡尔曼滤波定位算法, 该算法具有较好的稳定性, 实时性较高, 但定位误差较大, 在 2 m 左右。Si 等<sup>[17]</sup>利用 RTT 和接收信号强度指示 (received signal strength indicator, RSSI) 的分布特征建立区分 LOS 和 NLOS 的方法, 通过剔除 NLOS 的接入点 (access point, AP) 来提升定位精度, 但该算法难以提升 NLOS 比较严重的环境下的定位精度。以上各种定位算法在不同室内环境下性能差异较大, 难以适用所有场景。为此, 研究者开始利用机器学习、神经网络等方法进行 WiFi RTT 定位研究, 以期减少多径和非视距对定位精度的影响。Feng 等<sup>[18]</sup>提出了利用机器学习选择定位模型, 实现不同环境动态采用 RSS、RTT 或 RSS/RTT 混合的定位模型, 测试结果显示定位误差 1.8 m。Eberechukwu 等<sup>[19]</sup>将 DNN (deep neural networks, DNN) 与 WiFi FTM 结合, 研发出比传统无迹卡尔曼滤波和加权 K 近邻算法 (weighted K-nearest neighbors, WKNN) 精度更高的室内定位模型, 平均定位误差在 1 m 以内, 但其所采用 DNN 网络规模较大。Feng 团队<sup>[20]</sup>的实验表明, 基于 WiFi RTT 指纹的 K 均值聚类算法 (K-means clustering algorithm, K-means)、K 邻近算法 (K-nearest neighbor, KNN)、随机森林 (random forest, RF) 等机器学习算法的定位精度均好于基于几何测量的定位精度, 在网格大小为 12 ~ 60 cm, 连续采集几天的数据进行网络训练时, 定

位误差可以达到 1 m 以内<sup>[20-22]</sup>。但当网格尺寸较大时, 定位误差在 2 m 左右。该结论在 Omar Hashem 等<sup>[23]</sup>的研究中得到了佐证。Cao 等<sup>[24]</sup>利用支持向量机算法, 基于所提出的分类特征, 构建了一个识别 NLOS 和 LOS 距离的实时模型。结合 NLOS 和 LOS 识别、LOS 补偿和可信 NLOS 识别, WiFi RTT 定位的平均绝对误差为 1.082 m, 均方根误差为 1.355 m。该算法依赖于建立的路径损耗模型, 难以适用各种不同的应用场景。

虽然深度学习已经被应用于 WIFI 定位领域中, 但还存在网络规模大、需要采集的训练数据量大、不同环境下算法性能差异大等问题, 还没有一个公认能够实现基于 WiFi FTM 协议的精确室内定位深度学习模型, 深度学习在解决精确室内定位问题上的潜力还有待发掘。本文提出了一种将多个 AP 测量的 WiFi RTT 测距序列转换为多通道图像的方法, 降低了对采集训练数据的要求。基于多通道图像设计了有效通道注意力机制卷积神经网络 (efficient channel attention-convolutional neural network, ECA-CNN) 位置估计模型, 提高了 WIFI RTT 定位精度。

## 1 WiFi RTT 多通道测距图像构建

设实验场地有  $n$  个支持 WiFi FTM 协议的 AP, 在某位置点待定位终端对  $n$  个 AP 发起 FTM 请求并进行  $m$  次测距, 则终端对编号为  $i$  的 AP 的测距数据可表示为一个  $m$  维的行向量  $\mathbf{d}_i$ 。

$$\mathbf{d}_i = [d_i^1, d_i^2, \dots, d_i^j, \dots, d_i^{m-1}, d_i^m] \quad (1)$$

其中, 元素  $d_j^i$  表示终端设备对编号为  $i$  ( $1 \leq i \leq n$ ) 的 AP 进行第  $j$  ( $1 \leq j \leq m$ ) 次测距得到的 WiFi RTT 测距数据。每个 AP 的测距序列均可表示为式 (1) 的  $m$  维行向量。

将行向量  $\mathbf{d}_1, \dots, \mathbf{d}_n$  转置得到  $n$  个列向量  $\mathbf{d}_1^T, \dots, \mathbf{d}_n^T$ , 将  $n$  个列向量按 AP 编号排列可形成  $m$  行  $n$  列的矩阵  $\mathbf{A}_{m \times n}$ :

$$\mathbf{A}_m^n = [\mathbf{d}_1^T \quad \mathbf{d}_2^T \quad \dots \quad \mathbf{d}_n^T] = \begin{bmatrix} d_1^1 & d_1^2 & \dots & d_1^{m-1} & d_1^m \\ d_2^1 & d_2^2 & \dots & d_2^{m-1} & d_2^m \\ \vdots & \vdots & \dots & \vdots & \vdots \\ d_{m-1}^1 & d_{m-1}^2 & \dots & d_{m-1}^{m-1} & d_{m-1}^m \\ d_m^1 & d_m^2 & \dots & d_m^{m-1} & d_m^m \end{bmatrix} \quad (2)$$

$\mathbf{A}_{m \times n}$  矩阵第  $k$  行代表终端对所有 AP 进行第  $k$  次测距得到的结果, 第  $p$  列代表终端对第  $p$  个 AP 进行  $m$  次测距后得到的测距序列。

设有一个宽度为  $n$ 、长度为  $seq\_len$  ( $1 < seq\_len < m$ ) 的滑动窗口在  $\mathbf{A}_{m \times n}$  矩阵中自上而下地滑动, 如图 1 所示。每次滑动窗口内部的数据为  $seq\_len \times n$  大小的矩阵, 因此可将滑动窗口内数据视为一张尺寸为  $seq\_len \times n$  的单通道图像。

随着窗口滑动到不同位置,窗口中的数据不断更新,从而可以获得不同的图像。窗口滑动  $C-1$  次之后,可得到  $C$  张单通道图像。若将  $C$  张单通道图像按顺序堆叠在一起,则形成一张尺寸为  $seq\_len \times n \times C$  的多通道图像。

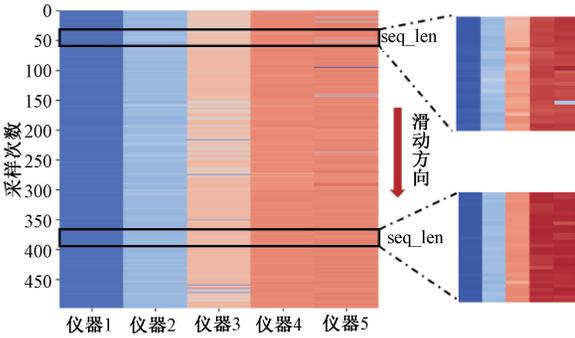
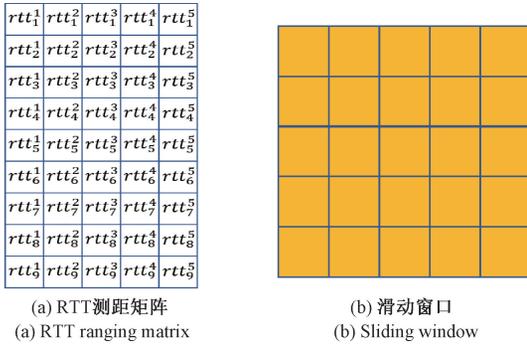


图 1 WiFi RTT 测距矩阵与滑动窗口

Fig. 1 WiFi RTT ranging matrix and sliding window

图 2 展示了长和宽均为 5 的滑动窗口自上往下滑动形成一张 3 通道图像的过程。图 2(a) 表示终端对 5 个 AP 进行 9 次测距所形成的 WiFi RTT 测距矩阵,图 2(b)



(c) 利用滑动窗口形成多通道图像

(c) Using sliding window to form multi-channel image

图 2 多通道图像的形成过程

Fig. 2 Construction process of multi-channel image

表示长宽均为 5 的滑动窗口,图 2(c) 表示滑动窗口在测距矩阵中以步长 1 向下滑动 2 次,然后将滑动窗口中的数据堆叠形成了一张尺寸为  $5 \times 5 \times 3$  的多通道图像。

## 2 ECA-CNN 定位算法

利用多通道图像,可以挖掘测量数据在时间和空间上的相关性,抑制非视距误差的影响。结合有效通道注意力机制(efficient channel attention, ECA)和卷积神经网络(convolutional neural network, CNN),构建了基于多通道图像(multiple channel image, MCI)的 MCI-ECA-CNN 定位算法,如图 3 所示。

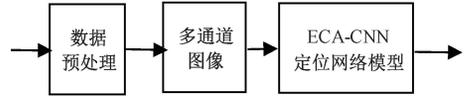


图 3 MCI-ECA-CNN 定位方案

Fig. 3 MCI-ECA-CNN positioning scheme

图 3 中,数据预处理模块针对测距实验中测距失败导致的数据缺失问题,采用线性插值对数据进行填充。设测距序列的长度为  $N$ ,测距结果编号为  $0 \sim N-1$ 。若此序列中第  $i$  个测距值  $d_i$  缺失,则当  $i=0$  时,插入的值为:

$$d_i = 2d_{i+2} - d_{i+1} \quad (3)$$

当  $0 < i < N-1$  时,插入的值为:

$$d_i = \frac{d_{i-1} + d_{i+1}}{2} \quad (4)$$

当  $i=N-1$  时,插入的值为:

$$d_i = 2d_{i-1} - d_{i-2} \quad (5)$$

补全缺失数据后再对数据进行卡尔曼滤波处理。卡尔曼滤波的状态方程为:

$$d(t/t-1) = d(t-1/t-1) \quad (6)$$

观测方程可直接由传感器的返回值  $d'(t)$  表示,状态协方差可表示为:

$$P(t/t-1) = P(t-1/t-1) + Q \quad (7)$$

系统噪声方差  $Q$  可根据实际情况进行估计。卡尔曼增益为:

$$K(t) = \frac{P(t/t-1)}{P(t/t-1) + R} \quad (8)$$

其中,  $R$  为待滤波数据的方差。

$t$  时刻的滤波结果为:

$$d(t/t) = d(t/t-1) + K(t)[d'(t) - d(t/t-1)] \quad (9)$$

状态协方差的更新方式如下:

$$P(t/t) = [1 - K(t)]P(t/t-1) \quad (10)$$

卡尔曼滤波后的数据作为 ECA-CNN 定位网络模型的输入。

ECA-CNN 定位网络模型如图 4 所示。模型主要包括:输入模块、注意力机制模块、特征提取模块、输出模块。

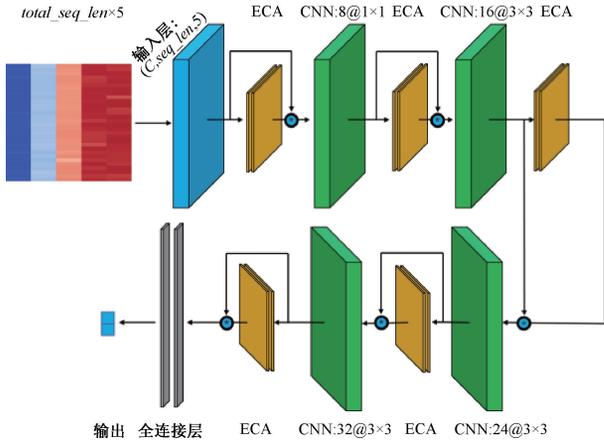


图 4 MCI-ECA-CNN 网络模型

Fig. 4 MCI-ECA-CNN network model

输入模块完成单通道图像到多通道图像再到三维张量的变换。单通道图像由多个 AP 的 WiFi RTT 测距序列构成,图像的长度表示测距总次数 ( $total\_seq\_len$ ),宽度表示 AP 数量 ( $n$ )。在定位实验中,AP 的数量为 5,故单通道图像大小为  $total\_seq\_len \times 5$ 。使用宽为 5、长为  $seq\_len$  ( $1 < seq\_len < total\_seq\_len$ ) 的滑动窗口在图像中向下滑动,滑动  $C-1$  次可得到  $C$  张单通道图像,将滑动窗口中的数据堆叠起来,则形成一张尺寸为  $seq\_len \times 5 \times C$  的多通道图像。

输入层生成的多通道图像首先采用 ECA 注意力机制<sup>[25]</sup>调整图像各通道之间的权重,如图 5 所示。

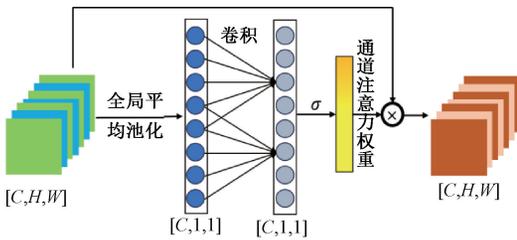


图 5 ECA 注意力机制

Fig. 5 ECA attention mechanism

ECA 模块的核心思想是通过一维卷积来捕捉通道间的依赖关系。具体来说,ECA 模块首先根据通道数自适应计算卷积核大小  $k$ 。核大小的计算公式为:

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (11)$$

式中: $C$  表示通道数;  $\lfloor t \rfloor_{\text{odd}}$  表示卷积核大小只能取奇数;系数  $\gamma$  和  $b$  是超参数,用于控制卷积核大小与通道数之

间的比例。在提出 ECA 注意力机制的论文<sup>[23]</sup>中, $\gamma$  和  $b$  分别设置为 2 和 1。ECA 网络在全局平均池化之后,使用一维卷积计算通道权重,如式 (12) 所示:

$$\omega_i = \sigma \left( \sum_{j=1}^k \alpha^j y_i^j \right), y_i^j \in \Omega_i^k \quad (12)$$

式中: $\omega_i$  表示第  $i$  个通道的权重; $\sigma$  表示 Sigmoid 激活函数; $\alpha^j$  表示卷积核的第  $j$  个权重; $y_i^j$  表示全局平均池化后的第  $i$  个值  $y_i$  的第  $j$  个相邻通道的值; $\Omega_i^k$  表示了与  $y_i$  相邻的  $k$  个池化值的集合。

特征提取模块采用卷积神经网络。为了更好地实现特征提取,本文采用多个 ECA-CNN 模块级联,具体参数如表 1 所示。第 1 个卷积层中卷积核的维度等于输入特征图的通道数  $C$ ,该卷积层使用  $1 \times 1$  卷积,在不改变特征图大小的情况下引入了非线性变化,增强网络的表征能力。后 3 个卷积层的卷积核尺寸均为  $3 \times 3$ 。为了保证特征图维持原来的大小,将边缘填充设置为 1。

表 1 网络参数设置

Table 1 Network parameter settings

网络结构	参数类型	参数值
输入层	张量大小	$seq\_len \times 5 \times C$
ECA1	卷积核大小	$\left\lfloor \frac{\log_2(C) + 1}{2} \right\rfloor$
	卷积核大小	$1 \times 1$
卷积层 1	卷积核数量	8
	边缘填充	0
ECA2	卷积核大小	3
	卷积核大小	$3 \times 3$
卷积层 2	卷积核数量	16
	边缘填充	1
ECA3	卷积核大小	3
	卷积核大小	$3 \times 3$
卷积层 3	卷积核数量	24
	边缘填充	1
ECA4	卷积核大小	3
	卷积核大小	$3 \times 3$
卷积层 4	卷积核数量	32
	边缘填充	1
ECA5	卷积核大小	3
张量扁平化	张量大小	$seq\_len \times 5 \times 32$
丢弃层	丢弃率	0.2
全连接层 1	节点数	200
全连接层 2	节点数	200
输出层	张量大小	$1 \times 2$

输出模块使用 2 个全连接层整合 ECA-CNN 级联结构的输出。由于多通道图像在经过多个卷积层的处理之后输出尺寸为  $(32, seq\_len, 5)$  的三维张量,因此,在将数据送入全连接层之前需对张量进行扁平化处理,使其从多维张量转化成 1 个尺寸为  $seq\_len \times 5 \times 32$  的一维张量,然后通过全连接层将这些特征映射到输出位置坐标。

### 3 定位实验与结果分析

#### 3.1 实验环境

实验地点为学校 3 号教学楼负一楼大厅。实验环境平面图、AP 部署位置与测试点位置如图 6 所示,实验场地的实景图如图 7 所示。实验场地大小约  $316 \text{ m}^2$ ,图 6 中 127 个圆点表示训练集的测试点,在每个测试点进行 250 次采样;36 个矩形表示测试集的测试点,在每个测试点进行 150 次采样;采样间隔  $100 \text{ ms}$ 。5 个菱形表示 AP 的摆放位置,AP 与待定位终端设备均水平放置在高约  $1.8 \text{ m}$  的三角支架上。在定位实验过程中,终端设备分别在每个测试点同时采集 5 个 AP 的测距数据。

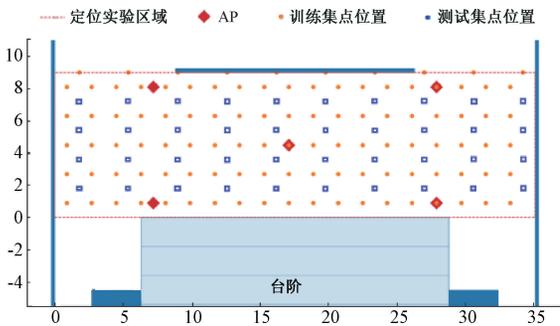


图 6 实验场景平面图

Fig. 6 Experimental site plan



图 7 实验场景实况

Fig. 7 Live map of the experimental site

由于实验场地为公共区域,因此,在实验过程中,不时有学生、教师、工作人员随机出现在测试场地中(近似服从泊松分布),人员在场地中停留时间长短和位置随机。测试场地内人员流动会造成 WiFi 信号的直线传播

路径被遮挡,形成 NLOS 环境。停留时间越长,NLOS 问题越严重。

#### 3.2 参数设置

本文使用的深度学习框架是 Pytorch,它提供了灵活的张量计算功能和深度学习构建模块,使得用户能够自由地创建、训练和调试深度学习模型。对模型涉及的学习率、批量大小、迭代次数等超参数进行了测试,基于多通道图像的 ECA-CNN 在不同参数下网络的定位误差均值与标准差如表 2 所示。

表 2 超参数对定位性能的影响

Table 2 Influence of hyper parameters on positioning performance (m)

参数	误差均值	误差标准差
学习率	0.01	1.100
	0.001	0.987
	0.0005	0.991
批量大小	32	1.046
	64	0.987
	80	1.065
迭代次数	200	1.001
	300	0.987
	400	0.986

从表 2 可以看出,学习率为 0.001,批量大小为 64,迭代次数为 300 时,定位误差均值和标准差最小,因此,本文后续利用该参数进行模型训练和测试验证,详细参数如表 3 所示。

表 3 通用参数

Table 3 General parameters

参数类型	参数值
学习率	0.001
优化器	Adam
批量大小	64
迭代次数	300
损失函数	均方误差损失函数 MSE

在模型迭代的过程中,保存验证集上损失函数最小的模型,然后在测试集上测试该模型的定位效果,统计并分析定位误差的分布特性。

#### 3.3 性能分析

为了验证基于多通道图像的 ECA-CNN 定位模型相比于其他定位算法的优势,本小节使用基于无图像的

DNN 定位模型<sup>[17]</sup>、基于单通道图像 (single channel image, SCI) 的 CNN 定位模型 (SCI-CNN)、基于单通道图像 ECA-CNN 定位模型 (SCI-ECA-CNN) 进行对比分析。其中,基于单通道图像的 CNN 定位模型结构如图 8 所示。

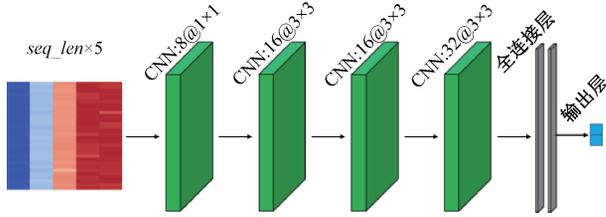


图 8 基于单通道图像的 CNN 定位模型

Fig. 8 CNN positioning model based on single channel image

该定位模型以尺寸为  $seq\_len \times 5$  的单通道图像作为输入,使用 4 层 CNN 结构提取图像特征,2 层全连接结构整合 CNN 输出特征,将特征映射到平面位置坐标。在本模型中, CNN 层和全连接层的参数与本文提出的 MCI-ECA-CNN 定位模型中的 CNN 层和全连接层参数相同,详见于表 1 网络参数设置。

基于单通道图像的 ECA-CNN 定位模型结构如图 9 所示。

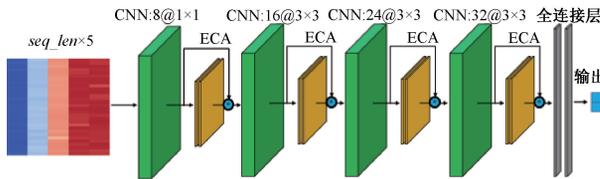


图 9 基于单通道图像的 ECA-CNN 定位模型

Fig. 9 ECA-CNN positioning model based on single channel image

该模型相比于本文提出的定位模型(图 4)的不同之处是该模型在第 1 个 CNN 层前没有引入 ECA 通道注意力机制,原因是该模型输入图像数据不存在多个通道之间的权重问题。该模型的其他结构与本文提出的定位模型完全相同, CNN 层与全连接层的详细参数见表 1。

本文对各种算法定位精度进行评估时,性能评价指标采用平均定位误差、误差标准差和误差累积分布函数。

平均定位误差是估计坐标与真实值之间的平均偏差。如式(13):

$$\mu_{error} = \frac{1}{M} \sum_{j=1}^M \sqrt{(x_0 - x_j)^2 + (y_0 - y_j)^2} \quad (13)$$

误差标准差表示定位结果相对于定位均值的偏离程度,如式(14)所示,误差标准差越小表明定位模型越稳定。

$$\sigma_{error} = \sqrt{\frac{1}{M} \sum_{j=1}^M \left| \sqrt{(x_0 - x_j)^2 + (y_0 - y_j)^2} - \mu_{error} \right|^2} \quad (14)$$

式(13)和(14)中:  $(x_0, y_0)$  是终端真实位置坐标;  $(x_j, y_j)$  是终端第  $j$  次定位的位置估计坐标,  $M$  为定位次数。

定位误差累积分布函数 (cumulative distribution function, CDF) 指定位误差小于某一个值的概率,即

$$P_{CDF}(\varepsilon) = P(\varepsilon \leq \varepsilon_{error}) \quad (15)$$

其中,  $\varepsilon$  代表定位误差大小,  $P(\varepsilon \leq \varepsilon_{error})$  代表  $M$  次定位结果中定位误差  $\varepsilon$  不大于误差门限  $\varepsilon_{error}$  的次数占  $M$  次定位结果的百分比。

表 4 展示了基于多通道图像的 ECA-CNN 模型在图像尺寸不同时对应的定位误差统计结果与模型参数量。

表 4 不同尺寸图像的定位误差统计特性

Table 4 Statistical characteristics of positioning error for different size image

图像尺寸	均值/m	误差标准差/m	CDF=67%/m	模型参数量
10×5×2	1.067	0.872	1.106	332 231
10×5×4	1.044	0.778	1.092	332 247
10×5×6	1.085	0.796	1.064	332 263
15×5×2	1.053	0.83	1.095	492 231
15×5×4	0.987	<b>0.633</b>	<b>1.044</b>	<b>492 247</b>
15×5×6	0.983	0.734	1.087	492 263
20×5×2	0.995	0.644	1.095	652 231
20×5×4	<b>0.978</b>	0.702	1.058	652 247
20×5×6	1.009	0.702	1.177	652 263

由表 4 可知,尺寸为 20×5×4 的图像的定位误差均值最小,尺寸为 15×5×4 的图像误差标准差和 67% 累积误差最小,误差均值为 0.987 m,与最小值仅相差 0.009 m,但后者对应定位模型的参数量仅为前者对应定位模型参数量的 75.47%。综上所述,输入图像大小为 15×5×4 对应的定位模型综合性能最好。因此,后续将以 15×5×4 的图像大小为标准进行算法对比分析。对应于 15×5×4 图像大小的 4 种模型的定位误差统计特性如表 5 所示。

表 5 不同定位模型的定位误差

Table 5 Positioning error of different positioning models

模型	图像尺寸	均值 /m	标准差 /m	CDF 67%/m	CDF 95%/m
DNN([13])	75	1.431	1.567	1.477	3.004
SCI-CNN	15×5	1.186	0.814	1.240	2.878
SCI-ECA-CNN	15×5	1.105	0.776	1.228	2.519
MCI-ECA-CNN	15×5×4	<b>0.987</b>	<b>0.633</b>	<b>1.044</b>	<b>2.185</b>

由表 5 可知,本文提出的基于多通道图像的 ECA-CNN 定位模型拥有相对优越的定位性能,在定位精度和定位结果的稳定性上均优于其他定位模型。其平均定位误差比基于无图像的 DNN 定位模型减小了 31.03%,比基于单通道图像的 CNN 定位模型减小了 16.78%,比基于单通道图像的 ECA-CNN 定位模型减小了 10.68%;其误差方差比基于无图像的 DNN 定位模型减小了 83.67%,比基于单通道图像的 CNN 定位模型减小了 39.52%,比基于单通道图像的 ECA-CNN 定位模型减小了 33.39%。

4 种模型的定位误差累积分布如图 10 所示。

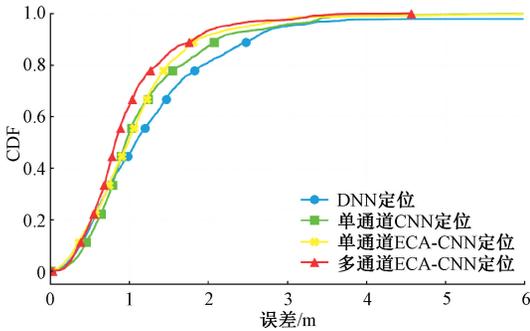


图 10 定位误差的 CDF

Fig. 10 CDF of positioning error

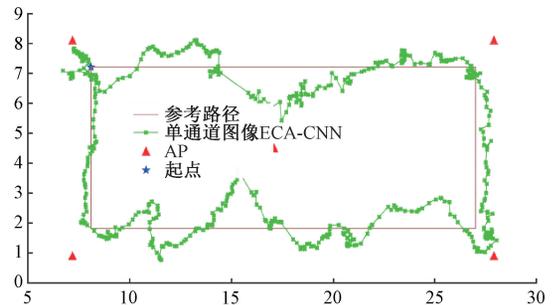
由图 10 可知,多通道 ECA-CNN 定位模型的累积误差分布曲线位于其他定位模型累积误差分布曲线的左上方,表明该模型的定位误差更小、性能更优。在 CDF 为 95% 时,本文提出的模型相比 DNN,精度提高了 1 m。

将终端设备沿着参考路径逆时针移动,终端设备在运动状态下对 WiFi RTT 测距数据进行采集,并使用相关定位模型计算定位结果。4 种定位模型输出轨迹如图 11 所示,误差 CDF 如图 12 所示,误差均值和标准差如表 6 所示。由于实验条件限值,运动状态下无法标定采样时刻终端真实坐标,因此,运动状态下定位误差的计算方法是定位输出位置和参考轨迹之间的距离。



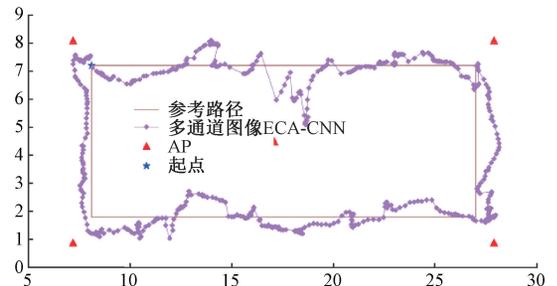
(b) SCI-CNN定位轨迹

(b) SCI-CNN positioning trajectory



(c) SCI-ECA-CNN定位轨迹

(c) SCI-ECA-CNN positioning trajectory



(d) MCI-ECA-CNN定位轨迹

(d) MCI-ECA-CNN positioning trajectory

图 11 动态定位轨迹

Fig. 11 Dynamic positioning trajectory

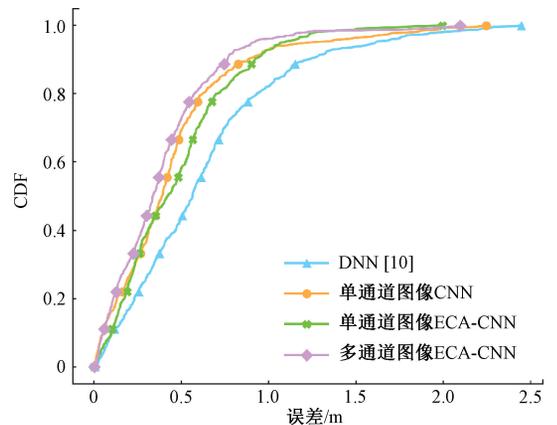
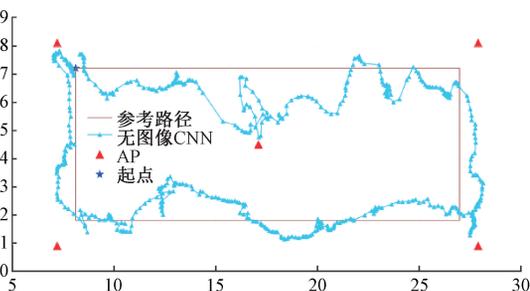


图 12 动态定位 CDF

Fig. 12 CDF of dynamic positioning



(a) DNN定位轨迹

(a) DNN positioning trajectory

表6 不同定位模型动态定位误差

Table 6 Dynamic positioning error of different positioning models (m)

模型	均值	标准差	CDF67%	CDF95%
DNN([13])	0.631	0.467	0.717	1.616
SCI-CNN	0.450	0.392	0.490	1.270
SCI-ECA-CNN	0.469	0.338	0.569	1.100
MCI-ECA-CNN	<b>0.388</b>	<b>0.324</b>	<b>0.451</b>	<b>0.923</b>

由图 11 可知,SCI-ECA-CNN 定位模型的预测轨迹最贴近参考路径;且图 12 中 SCI-ECA-CNN 累积误差分布曲线位于其他定位模型累积误差分布曲线的左上方,误差最小。表 6 中 MCI-ECA-CNN 误差均值、误差标准差等也都是最小。因此,使用 SCI-ECA-CNN 定位模型追踪运动情况下的终端设备时,定位精度最高。

由此可以看出,本文通过构造多通道图像,充分利用测距信息的时空约束关系,可以降低非视距误差的影响,提高定位精度。

为了评估本文算法的普适性,本文对 AP 数量对算法定位性能的影响以及算法实时性进行了测试。

图 13 和表 7 所示为不同 AP 数量下本文定位算法的定位误差。从图 13 和表 7 的结果可以看出,AP 数量增加,性能略有增加,但增加幅度不大,因此,本文算法既适用 AP 密集部署场景,也适用于 AP 数量较少的环境。

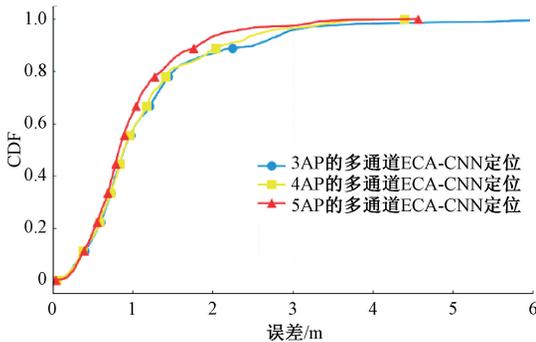


图 13 AP 数量对定位误差的影响

Fig. 13 The influence of AP quantity on positioning error

表7 不同 AP 数目下 MCI-ECA-CNN 定位性能

Table 7 MCI-ECA-CNN positioning performance under different number of APs (m)

AP 数量	均值	标准差	CDF=67%	CDF=95%
3	1.170	0.937	1.216	2.923
4	1.098	0.741	1.177	2.659
5	<b>0.987</b>	<b>0.633</b>	<b>1.044</b>	<b>2.185</b>

在测试集相同(36 个测试点,每个测试点采样 150 次)的情况下,4 种模型的运行时间如表 8 所示。

表8 不同定位模型的运行时间

Table 8 Running time of different positioning models

模型	运行时间/s
DNN([10])	1.691
SCI-CNN	3.132
SCI-ECA-CNN	6.034
MCI-ECA-CNN	6.552

由表 8 可知,本文提出的定位模型在测试集上总的运行时间相对较长,但整个测试集有 4 788 个定位结果,输出 1 个定位结果耗时约为 1.37 ms,响应速度也可以满足各种应用场景对实时性的需求。

## 4 结 论

在室内情况下,非视距以及室内物体反射信号所引起的多径效应严重影响信号传播时间的测量精度,对室内定位精度的提高提出了严峻挑战。本文提出使用滑动窗口将从多个 AP 测得的 WiFi RTT 测距序列转化为多通道图像,利用多通道图像时间空间上的相关性以及冗余特性,使用卷积神经网络提取数据特征,并利用 ECA 机制调整不同通道权重,有效降低了 NLOS 的影响以及对环境的依赖性,实现了定位精度的提升,相比其他几种算法,定位精度最高,具有较高的环境适应性。本文提出的 MCI-ECA-CNN 算法虽然单次定位时间为毫秒级,能够满足实时性的要求,但相对于其他算法,定位时间更长,因此,后续可以进一步优化算法,提高响应速度。

## 参考文献

- [1] 卢海钊,彭慧豪,唐滔,等.基于 KNN 和 XGBoost 的室内指纹定位算法[J].电子测量技术,2023,46(2):81-86.  
LU H ZH, PENG H H, TANG T, et al. Indoor fingerprint localization algorithm based on KNN and XGBoost[J]. Electronic Measurement Technology, 2023, 46(2): 81-86.
- [2] 郑安琪,秦宁宁.空间指纹测量特征双精简下的室内定位算法[J].仪器仪表学报,2023,44(10):80-89.  
ZHENG AN Q, QIN N N. Indoor localization algorithm with dual refinement of spatial fingerprint measurement features[J]. Chinese Journal of Scientific Instrument,

- 2023,44(10):80-89.
- [ 3 ] 汪杰,宋书林,秦宁宇. 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.
- [ 4 ] 罗日,李燕君,金志昂. 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 ANG. An indoor positioning method integrating WiFi and wearable inertial navigation module [ J ]. Chinese Journal of Scientific Instrument, 2022,43(3):267-276.
- [ 5 ] 陈潇,秦宁宇,宋书林. 双源信号下多元尺度融合室内位置测算方法[J]. 仪器仪表学报, 2024,45(1):311-320.
- CHEN X, QIN N N, SONG SH L. Indoor position estimation method with multi-scale fusion under dual-source signals [ J ]. Chinese Journal of Scientific Instrument, 2024,45(1):311-320.
- [ 6 ] 刘水清. 基于图像匹配与 WiFi 信号匹配的室内 PDR 定位方法[J]. 电子测量技术, 2023,46(1):154-159.
- LIU SH Q. PDR indoor positioning method based on image matching and WiFi fingerprinting [ J ]. Electronic Measurement Technology, 2023,46(1):154-159.
- [ 7 ] MARTIN-ESCALONA I, ZOLA E. Ranging estimation error in WiFi devices running IEEE 802.11mc [ C ]. 2020 IEEE Global Communications Conference, 2020: 5163-5169.
- [ 8 ] FENG X, NGUYEN K A, LUO ZH Y. WiFi round-trip time (RTT) fingerprinting: An analysis of the properties and the performance in non-line-of-sight environments [ J ]. Journal of Location Based Services, 2023, 17(4):307-339.
- [ 9 ] IBRAHIM M, LIU H S, JAWAHAR A, et al. Verification: Accuracy evaluation of WiFi fine time measurements on an open platform [ C ]. Proceedings of the 24th Annual International Conference on Mobile Computing and Networking, New York, 2018: 417-427.
- [ 10 ] MA CH Q, WU B, POSLAD S, et al. WiFi RTT ranging performance characterization and positioning system design [ J ]. IEEE Transactions on Mobile Computing, 2022, 21(2): 740-756.
- [ 11 ] HAN K, YU S M, KIM S L, et al. Exploiting user mobility for WiFi RTT positioning: A geometric approach [ J ]. IEEE Internet of Things Journal, 2021, 8(19): 14589-14606.
- [ 12 ] SUN M, WANG Y J, HUANG L. Simultaneous WiFi ranging compensation and localization for indoor NLOS environments [ J ]. IEEE Communicatons Lettes, 2022, 26(9):2052-2056.
- [ 13 ] GENTNER C, ULMSCHNEIDER M, KUEHNER I, et al. WiFi RTT indoor positioning [ C ]. 2020 IEEE/ION Position, Location and Navigation Symposium (PLANS), 2020: 1029-1035.
- [ 14 ] 唐翔宇,张千里,王继龙,等. 基于精确时间测量的无线网络室内定位系统研究 [ J ]. 计算机学报, 2022, 45(3):567-584.
- TANG X Y, ZHANG Q L, WANG J L, et al. Research on indoor positioning system based on wireless network fine time measurement technology [ J ]. Chinese Journal of Computers, 2022, 45(3):567-584.
- [ 15 ] DONG Y H, ARSLAN T, YANG Y J. Real-time nlos/los identification for smartphone-based indoor positioning systems using wifi RTT and RSS [ J ]. IEEE Sensors Journal, 2021, 22(6): 5199-5209.
- [ 16 ] YU Y, CHEN R ZH, CHEN L, et al. A robust dead reckoning algorithm based on WiFi FTM and multiple sensors [ J ]. Remote Sensing, 2019,11(5): 504.
- [ 17 ] SI M H, WANG Y J, XU SH L, et al. A WiFi FTM-based indoor positioning method with LOS/NLOS identification [ J ]. Applied Sciences, 2020, 10 ( 3 ): 956.
- [ 18 ] FENG X, NGUYEN K A, LUO ZH Y. A WiFi RSS-RTT indoor positioning model based on dynamic model switching algorithm [ J ]. IEEE Journal of Indoor and Seamless Positioning and Navigation, 2024,2:151-165.
- [ 19 ] EBERECHUKWU P, PARK H, LAOUDIAS C, et al. DNN-based indoor fingerprinting localization with WiFi FTM [ C ]. 2022 23rd IEEE International Conference on Mobile Data Management (MDM), 2022: 367-371.
- [ 20 ] FENG X, NGUYEN K A, LUO ZH Y. An analysis of the properties and the performance of wifi RTT for indoor

- positioning in non-line-of-sight environments [C]. 17th International Conference on Location Based Services, Munich, Germany, 2022:12-24.
- [21] 蒲巧林,陈有坤,周牧,等. 基于改进对比学习和并行融合神经网络的室内 WiFi 定位算法[J]. 仪器仪表学报, 2024,44(1):101-110.
- PU Q L, CHEN Y K, ZHOU M, et al. Indoor WiFi localization algorithm based on the improved contrastive learning and parallel fusion neural network [J]. Chinese Journal of Scientific Instrument, 2024,44(1):101-110.
- [22] CHEN ZH H, ALHAJRI M I, WU M, et al. A novel real-time deep learning approach for indoor localization based on RF environment identification[J]. IEEE Sensors Letters, 2020, 4(6): 1-4.
- [23] HASHEM O, YOUSSEF M, HARRAS K A. WiNar: RTT-based sub-meter indoor localization using commercial devices[C]. 2020 IEEE International Conference on Pervasive Computing and Communications (PerCom), 2020: 1-10.
- [24] CAO H J, WANG Y J, BI J X, et al. LOS compensation and trusted NLOS recognition assisted WiFi RTT indoor positioning algorithm[J]. Expert Systems with Applications, 2024,243:122867.
- [25] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural

networks[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.

## 作者简介



**刘林** (通信作者), 1997 年于西南交通大学获得学士学位, 2000 年于西南交通大学获得硕士学位, 2007 年于西南交通大学获得博士学位, 现为西南交通大学副教授, 主要研究方向为无线定位技术、无线资源管理、认知无线网络、专用移动通信技术、通信对抗。

E-mail: lliu@swjtu.edu.cn

**Liu Lin** (Corresponding author) received her B. Sc. degree, M. Sc. degree, and Ph. D. degree all from Southwest Jiaotong University in 1997, 2000, and 2007, respectively. She is currently an associate professor at Southwest Jiaotong University. Her main research interests include Wireless positioning technology, wireless resource management, cognitive radio network, dedicated mobile communication technology, and communication countermeasures.



**廖子阳**, 2024 年于西南交通大学获得硕士学位, 主要研究方向为无线室内定位。

E-mail: 799378475@qq.com

**Liao Ziyang** received his M. Sc. degree from Southwest Jiaotong University in 2024. His main research interest is wireless positioning technology.