

# 基于卷积神经网络的室内可见光指纹定位方法

许浩, 王旭东\*, 吴楠

大连海事大学信息科学技术学院, 辽宁 大连 116026

**摘要** 为进一步提高室内可见光定位系统性能,提出了一种基于卷积神经网络(CNN)的可见光指纹定位方法。该方法利用参考节点LED的光强信号作为特征,构建指纹数据库,将接收器坐标作为训练标签,引入一维CNN学习模型进行训练,建立基于光强信息的定位模型。CNN的应用,较好地解决了全连接前馈神经网络定位精度低、稳定性差的问题。在室内 $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ 的定位场景下,利用所提定位方法可以获得平均定位误差为 $4.44\text{ cm}$ 的定位精度。通过仿真实验,对比分析了不同室内可见光定位方法的性能,验证了所提方法的技术优势。

**关键词** 光通信; 室内定位; 卷积神经网络; 指纹定位; 接收信号强度

中图分类号 TN929.1

文献标志码 A

doi: 10.3788/LOP202158.1706008

## Indoor Visible Light Fingerprint Positioning Scheme Based on Convolution Neural Network

Xu Hao, Wang Xudong\*, Wu Nan

Information Science Technology College, Dalian Maritime University, Dalian, Liaoning 116026, China

**Abstract** This paper proposes a visible light fingerprint positioning scheme based on a convolutional neural network (CNN) to improve the performance of indoor visible light positioning systems. In the proposed scheme, optical intensity signals are employed as the features of the reference node LED, and receiver coordinates are employed as training labels to construct fingerprint database. In addition, a positioning model based on light intensity information is constructed, and a one-dimensional CNN learning model is adopted for training. CNN application solves the problems of low-positioning accuracy and poor stability of the fully-connected feedforward neural network method. In an indoor-positioning scene (size:  $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ ), the proposed positioning scheme obtained high positioning accuracy with an average positioning error of  $4.44\text{ cm}$ . In addition, the performance of several different indoor visible light positioning methods was compared and analyzed in simulation experiments, and the results verified the technical advantages of the proposed scheme.

**Key words** optical communications; indoor positioning; convolutional neural network; fingerprint positioning; received signal strength

**OCIS codes** 060.4510; 230.3670; 230.5160

## 1 引言

随着互联网的发展和智能终端设备的日益普

及,基于定位的服务(LBS)<sup>[1]</sup>逐渐受到人们的关注。为了实现室内的精确定位,近年出现了一些通过增加其他的外部硬件或设施来提高室内定位精度的

收稿日期: 2020-11-18; 修回日期: 2020-12-09; 录用日期: 2020-12-14

基金项目: 国家自然科学基金(61371091)

通信作者: \*wxd@dlnu.edu.cn

方法,例如超宽带定位、蓝牙定位、射频识别定位和无线 Wi-Fi 定位系统等<sup>[2-5]</sup>,但却存在增加定位辅助设施困难、硬件安装成本较高且不易扩展、严重的多径效应及电磁干扰等诸多问题。随着可见光通信(VLC)技术<sup>[6]</sup>的不断发展,可见光定位(VLP)<sup>[7-8]</sup>以定位成本低、不受电磁干扰和多径效应影响、定位安全性高等特点获得学术界和业界的高度关注。

目前,可见光室内定位技术得到了迅速发展。传统的可见光室内方法主要有到达时间法(TOA)、到达时间差法(TDOA)<sup>[9]</sup>、到达角度法(AOA)<sup>[10]</sup>、接收信号强度法(RSS)<sup>[11]</sup>和指纹匹配法<sup>[12-13]</sup>等。此外,还可以用数码相机代替光电检测(PD)器件,直接根据捕获的图像来获取坐标位置<sup>[14]</sup>。随着定位技术的深入研究,逐渐衍生和发展出了各种具有更高复杂度的室内可见光定位方法,例如混合定位方法和基于机器学习的定位方法等。文献[15]提出了一种RSS/AOA混合可见光定位方法,该方法利用最小二乘法建立混合目标函数,将目标函数转换成广义信赖域子问题,求解位置坐标,获得了在 $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ 定位场景下的 $8.7\text{ cm}$ 的平均精度。文献[16]提出了一种基于k-means聚类的无监督LED定位方法,首次将机器学习方法引入到可见光室内定位系统中。该方法使用两个LED组成的发射端,接收端则通过测量不同位置的光强度来构建稀疏网络,最后计算得出信号强度,最终在 $4.3\text{ m}\times 4\text{ m}\times 4\text{ m}$ 的场景中接收器的平均定位误差可达 $0.31\text{ m}$ 。k-means聚类方法对 $k$ 值的选取敏感,很难确定分成几类是最佳的。同时,噪声的存在会影响类的选取,难以实现高精度定位。文献[17]将支持向量机(SVM)引入到室内可见光定位方法中,主要从机器学习角度研究指纹定位方法,并结合机器学习架构来解决指纹定位中出现的问题,与传统的指纹定位方法相比,平均定位精度提高了40%。基于SVM的方法在大规模训练样本中难以实施,选取的定位点增多,定位精度显著下降。同时,SVM对参数跟核函数选择敏感,核函数的选取问题尚未得到解决。文献[18]在传统的指纹定位的基础上引入了人工神经网络,用训练过的神经网络进行定位,可在散射信道环境下实现精确定位,在 $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ 的场景中测量平均定位误差达到了 $6.39\text{ cm}$ 。全连接神经网络中神经元全部连接,会使参数增多并容易引入误差量,导致定位精度下降。

为进一步提高基于可见光信号强度信息的指纹定位方法的性能,本文提出了一种基于卷积神经网络(CNN)的室内可见光指纹定位方法。构建以4个LED发射器作为定位参考节点,接收端采用PD作为接收器,来接收光功率的定位系统结构;离线阶段,通过在接收平面随机选取多个采样点来训练一维卷积神经网络(conv 1D),实现基于光强指纹的定位模型构建;在线阶段,将测量的信号强度RSS数据输入到CNN模型定位中,实现高精度位置估计。利用仿真实验,在 $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ 的室内环境下,通过对比分析,验证了所提方法的可行性和提高定位精度的有效性,及所具备的良好收敛性和泛在性。

## 2 定位模型和定位过程

### 2.1 系统模型

设定室内定位场所为 $5\text{ m}\times 5\text{ m}\times 3\text{ m}$ 的实验区域,系统模型如图1所示。接收端采用光电检测器件接收光强信号,定位时,接收端根据接收到的信号强度信息进行位置估计。将作为发射端的照明设备LED安装于房间的天花板处,这样来自不同LED光照形成的辐射区能彼此重叠,以此来确保平面内的任意一个定位点都能够同时接收到不同LED所发出的光照信息。考虑到室内LED的实际布置情况,采用4个LED作为发射端,选择正方形拓扑。设定发射端LED编号为 $T_{xi}(i=1, \dots, 4)$ , $T_{xi}=(x_i, y_i, z_i)$ ,各LED坐标为 $T_{x1}(1.25, 1.25, H)$ 、 $T_{x2}(1.25, 3.75, H)$ 、 $T_{x3}(3.75, 1.25, H)$ 、 $T_{x4}(3.75, 3.75, H)$ ;H为天花板到接收平面的垂直高度。只考虑二维空间定位,待定位点可位于地面上的任意位置,坐标为 $\mathbf{x}(\mathbf{x}\in\mathbf{R}^2)$ , $\mathbf{x}=(x, y)$ 。




图1 可见光定位系统模型

Fig. 1 Visible light positioning system model

## 2.2 信道模型

可见光定位系统选取 LED 作为信号发射源,引

入 Lambertian 辐射模型,直射链路(LOS)信道的直流增益可表示为

$$H(0) = \frac{(m+1)}{2\pi d^2} A \cos^m(\phi) T_s(\psi) g(\psi) \cos(\psi), \quad 0 \leq \psi \leq \psi_{FOV}, \quad (1)$$

式中:朗伯系数  $m = -\ln 2 / \ln(\cos \phi_{1/2})$ ,  $\phi_{1/2}$  是 LED 的半功率角;  $d$  为发射端 LED 到接收端 PD 的距离;  $A$  为 PD 的接收面积;  $\phi$  为发射端的辐射角;  $\psi$  为接收端的入射角;  $g(\psi)$  为聚光器增益;  $T_s(\psi)$  为光滤波器增益;  $\psi_{FOV}$  为聚光器的视场角。

在 VLP 系统中,LED 发出光信号,通过 LOS 信道到达接收端的信号可表示为

$$y(t) = H(0) \cdot x(t) + n(t), \quad (2)$$

式中:  $n(t)$  为接收到的噪声,通常建模为热噪声和散粒噪声。假设不考虑 LOS 信道中码间干扰的影响,  $N_{noise}$  为噪声方差总和,可表示为

$$N_{noise} = \sigma_{shot}^2 + \sigma_{thermal}^2 \quad (3)$$

散粒噪声方差可表示为

$$\sigma_{shot}^2 = 2qRP_{rSignal}B + 2qI_{bg}I_2B, \quad (4)$$

式中:  $R$  表示光电转换系数;  $P_{rSignal}$  表示信号功率;  $q$  表示电子电荷量;  $I_{bg}$  表示背景光产生的暗电流;  $I_2$  表示噪声带宽系数;  $B$  表示等效噪声带宽。

热噪声方差表示为

$$\sigma_{thermal}^2 = \frac{8\pi k T_k}{G} C_{pd} A I_2 B^2 + \frac{16\pi^2 k T_k \Gamma}{g_m} C_{pd}^2 A^2 I_3 B^3, \quad (5)$$

式中:  $T_k$  为热力学温度;  $k$  为玻尔兹曼常数;  $C_{pd}$  为光电检测器单位面积电容;  $G$  为开环电压增益;  $g_m$  为跨导系数;  $\Gamma$  为场效应管信道噪声系数。

第  $i_{oc}$  个测量位置接收到的 4 个 LED 灯发出的光功率可表示为

$$\mathbf{P}_{i_{oc}} = [p_{i_{oc}1}, p_{i_{oc}2}, p_{i_{oc}3}, p_{i_{oc}4}] \quad (6)$$

## 2.3 指纹库构建

离线阶段构建指纹数据库,在接收平面上每隔  $u$  采样,将接收平面划分为  $N$  个  $u \times u$  的网格。记录每个网格的位置坐标作为标签向量,位置坐标可表示为  $(x_{i_{oc}}, y_{i_{oc}})$ ,  $i_{oc} = 1, \dots, N$ 。通过采集每个网格点上接收到的来自不同 LED 的 RSS 信息来构成指纹库的特征向量,接收信号强度向量可表示为  $\mathbf{P}_{i_{oc}} = [p_{i_{oc}1}, p_{i_{oc}2}, p_{i_{oc}3}, p_{i_{oc}4}]$ 。这样每一个位置坐标都有一组对应的接收信号强度向量,以此来形成一条指纹数据,构建指纹库,如表 1 所示。

表 1 指纹数据库

Table 1 Fingerprint database

Reference point	Coordinate		Received signal strength			
1	$x_1$	$y_1$	$p_{11}$	$p_{12}$	$p_{13}$	$p_{14}$
2	$x_2$	$y_2$	$p_{21}$	$p_{22}$	$p_{23}$	$p_{24}$
3	$x_3$	$y_3$	$p_{31}$	$p_{32}$	$p_{33}$	$p_{34}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$N$	$x_N$	$y_N$	$p_{N1}$	$p_{N2}$	$p_{N3}$	$p_{N4}$

## 2.4 定位过程

所提基于 CNN 的定位方法分为两个阶段:离线阶段和在线阶段。离线阶段,在定位区域内均匀选取若干个参考点,记录每个参考点的 RSS 和对应的位置坐标来构建指纹库,将 RSS 作为特征输入、位置坐标作为标签,来训练 CNN 模型;在线阶段,测量待测位置的 RSS 值,并输入到训练好的 CNN 中,计算输出待测点位置坐标。

## 3 基于 CNN 的指纹定位方法

### 3.1 数据归一化

在所提方法中,输入数据是来自不同 LED 的接收强度信息。为了更好地训练数据并加速 CNN 收敛,对输入数据进行均值归一化处理,对原始数据的均值和标准差进行数据的标准化。经过处理的数据符合均值为 0,标准差为 1 的标准正态分布。转换函数为

$$P_u' = \frac{P_u - \mu}{\sigma}, \quad (7)$$

式中:所有样本数据的均值  $\mu = \frac{1}{U} \sum_{u=1}^U P_u$ ,  $U$  为样本数总数;  $P_u$  为接收光功率;所有样本数据的标准差  $\sigma = \frac{1}{U} \sum_{u=1}^U (P_u - \mu)^2$ ;  $P_u'$  是归一化样本数据,可以作输入数据输入到 CNN 中。

### 3.2 卷积神经网络结构

所提方法采用一维 CNN,网络结构如图 2 所示,由卷积层、池化层、平坦层及全连接层 4 个部分组成。

卷积层:使用随机初始化滤波器来提取输入数据的特征。随着 CNN 的卷积层数增多,会有梯度






图 2 CNN 模型

Fig. 2 CNN model

消失和梯度爆炸的风险。为了将输入数据的所有特征全部提取出来,经过多次仿真实验调试,发现使用 3 个卷积层足以保证网络的学习能力。第 1 个卷积层使用 128 个滤波器,卷积核大小为 2,步长设置为 1;第 2 个和第 3 个卷积层分别使用 64 和 32 个滤波器,卷积核大小和步长与第 1 层卷积层的相同。此外,为了保持从输入数据中提取的局部特征的大小不变,每个卷积层都采用零填充。

**池化层:**对从卷积层输出的特征进行压缩,起到子采样的作用。采用最大池化法,提取滑动窗口中的最大值进行子采样。池化层窗口大小为 2,步长为 2,在这种情况下,输出维数减小为原来的 1/2,既减小了时间复杂度又防止了过拟合的出现。

**平坦层:**将多维的输入一维化,用在池化层和全连接层之间进行过渡,将池化层的  $32 \times 2$  个输出转换为 64 个输出,以便与全连接层相连。

**全连接层:**对卷积层和池化层输出的特征进行非线性组合,用于预测最终位置。

CNN 的输入是 PD 接收到的来自 4 个 LED 的光功率向量,输出为 PD 所对应的位置坐标。则卷积层第  $l$  层的第  $o$  ( $1 \leq o \leq O$ ) 个特征输出可以表示为

$$Z^{(l,o)} = f[W^{(l,o)} \otimes P^{(l-1)} + b^{(l,o)}], \quad (8)$$

式中:  $W^{(l,o)}$  和  $b^{(l,o)}$  为卷积核和偏置;  $P^{(l-1)}$  为上一层的输入。第  $l$  层中共有  $O$  个卷积核和  $O$  个偏置。

池化层对卷积层的输出  $Z_s$  的  $K$  个区域进行子采样,得到池化层的输出为  $Y = \{y_k\}$ , 其中

$$y_k = \max_{s=K_k} \{Z_s\}. \quad (9)$$

设每个全连接层的权重和偏置分别为  $W^{(l,t,j)}$  和  $b^{(l,j)}$ , 设第  $l-1$  层全连接层的神经元个数为  $q$ , 则当前全连接层第  $l$  层中第  $j$  个神经元的输出为

$$X^{(l,j)} = f\left[\sum_{t=1}^q W^{(l,t,j)} Y^{(l-1,t)} + b^{(l,j)}\right]. \quad (10)$$

常见的激活函数主要有 Relu、tanh、sigmoid 函数。其中 tanh 和 sigmoid 函数两端饱和,容易出现神经网络梯度消失的问题,并且权重更新缓慢。而 Relu 函数的神经元只需要进行加、乘和比较的操作,能够减少计算量,并且避免发生梯度消失的问题。同时,Relu 函数能加快网络收敛,提高效率。所提 CNN 结构中,每个神经元的激活函数都使用 Relu, 即有

$$R_{\text{Relu}}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (11)$$

为了解决 CNN 过拟合的问题,增加了 dropout 层。过拟合是一种样本数据训练得太准确而导致实际使用中精度太低的情况。在每个全连接层之后都使用了 dropout 层。dropout 率设置为 0.2, 即从全连接网络中随机舍弃掉 20% 的神经元,来防止出现过拟合,提高预测精度。

为了训练 CNN,使其产生更准确的预测值,引入损失函数。损失函数通常作为学习准则,即通过最小化损失函数求解和评估 CNN 模型。而回归问题最常用的损失函数是均方误差 (MSE), 数学表达式为

$$E_{\text{MSE}}(y, \hat{y}) = \frac{\sum_{v=1}^{n'} (y_v - \hat{y}_v)^2}{n'}, \quad (12)$$

式中:  $y_v$  为一个 batch 中第  $v$  个数据的位置坐标;  $\hat{y}_v$  为神经网络给出的预测值。

## 4 定位仿真结果和分析

### 4.1 优化方法

根据所提定位模型,在  $5 \text{ m} \times 5 \text{ m} \times 3 \text{ m}$  的室内场景中进行仿真。信道仿真参数如表 2 所示。先将定位区域划分为 676 个  $0.2 \text{ m} \times 0.2 \text{ m}$  的网格,然后收集该区域内每个网格接收到的来自 4 个 LED 的接收信号强度和每个网格对应的位置坐标作为指纹来建立指纹数据库。为了评估定位模型的性能,定义均方根误差 (RMSE) 函数为

表 2 信道仿真参数

Table 2 Parameters used in channel simulation

Parameter	Value	Parameter	Value
Transmitted optical power ( $P_1$ ) / W	1	Absolute temperature ( $T_K$ ) / K	300
Field of view (FOV) / ( $^\circ$ )	60	Dark current ( $I_{bg}$ ) / $\mu$ A	5100
Semi-angle at half power ( $\varphi_{1/2}$ ) / ( $^\circ$ )	70	Open-circuit voltage gain ( $G$ )	10
Refractive index	1.5	FET transconductance ( $g_m$ ) / mS	30
Wall reflectivity ( $\rho$ ) / %	80	Noise bandwidth factor ( $I_2$ )	0.562
Gain of optical filter	1	Noise bandwidth factor ( $I_3$ )	0.0868
Modulation bandwidth ( $B$ ) / MHz	100	Noise factor ( $\Gamma$ )	1.5

$$R_{RMSE} = \sqrt{E[(x - \hat{x})^2 + (y - \hat{y})^2]}, \quad (13)$$

式中： $E[\cdot]$ 为统计平均运算符；在二维平面内对定位方法进行误差分析，不考虑定位点高度，则 $(x, y)$ 为定位点的真实坐标； $(\hat{x}, \hat{y})$ 为定位点的估计坐标。

此外，利用计算机（GPU 为 GTX1660Ti）对所提定位方法进行仿真验证，并使用 Python-3.6.6 在 Keras-2.3.1（Tensorflow-gpu-2.1.0）上训练深度学习模型。

为了优化网络模型，提升定位性能，选取不同的优化方法作比较。在仿真实验中，在定位区域内均匀选取 2601 个  $0.1 \text{ m} \times 0.1 \text{ m}$  的参考点，对每个点进行位置估计。使用多种优化方法并改变学习率来优化网络结构，包括 Adam、SGD、RMSprop。不同优化方法的实验结果如图 3 所示。可以看出：使用不同优化器和学习率对定位性能影响很大；大多数优化器可以将定位误差降至 6 cm 以内；而当 Adam 优化方法的学习率为 0.001 时，位置估计误差最小；Adam 优化方法提供了快速而可靠的学习收敛，比同类优化方法（SGD、RMSprop）要快得多。故选取 Adam 优化方法来训练卷积神经网络，学习

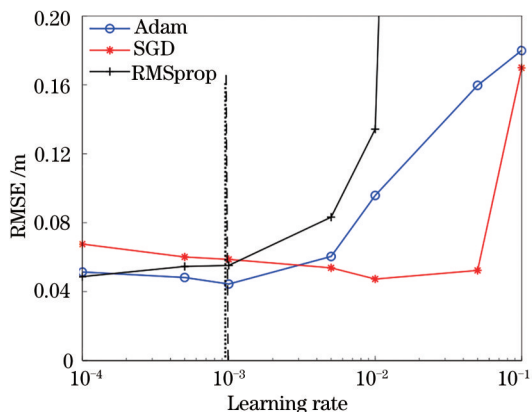


图 3 不同学习率下各种优化器对定位性能的影响

Fig. 3 Effects of various optimizers on positioning performance with different learning rates

率设为 0.001。

## 4.2 定位实验

### 4.2.1 定位误差分布

确定好网络模型，并选取最优的激活函数和优化方法。对定位区域内均匀选取的 2601 个  $0.1 \text{ m} \times 0.1 \text{ m}$  的参考点进行位置估计，得到基于 CNN 定位方法的误差分布。图 4 为定位误差空间分布图，平均定位误差为 4.44 cm，最大定位误差为 25.12 cm。图 5 为定位误差分布直方图，可以看出大部分定位误差都分布在 10 cm 以内，验证了所提方法的可行性。




图 4 定位误差空间分布

Fig. 4 Spatial distribution of positioning error




图 5 定位误差概率直方图

Fig. 5 Histogram of positioning error probability

#### 4.2.2 与 BP 神经网络方法作比较

为了说明所提方法网络结构的优越性,将所提方法与基于多层全连接的 BP 神经网络方法作比较。离线阶段,用指纹库中的数据训练神经网络模型,随机选取指纹库中 20% 的数据作为验证数据,用来评估两种网络模型的准确率,结果如图 6 所示。可以看出,所提网络模型具有较好的收敛性。对定位区域内选取的 2601 个点进行测量并比较定位误差,每种方法重复进行 5 次仿真实验,结果如图 7 所示。可以看出:随着实验次数的增加,所提方法定位误差大小几乎不变,维持在 5 cm 以内;而基于多层全连接的 BP 神经网络定位方法的误差波动很大,最大平均定位误差接近 8 cm。说明所提方法的网络结构具有稳定性。图 8 给出了两种方法的累积分布函数(CDF)曲线。所提方法的 CDF 曲线左移,所提方法和基于多层全连接的 BP 神经网络方法在 95% 置信区间的定位误差分别为 10.5 cm 和




图 8 不同网络模型 CDF 比较

Fig. 8 Comparison of CDF in different network models

14.1 cm。所提方法误差小,定位性能优于基于多层全连接的 BP 神经网络方法。在基于多层全连接的 BP 神经网络中,每个隐藏层中的神经元与上一层的神经元是全连接状态,权重矩阵的参数非常多,训练效率非常低。同时,训练参数多会导致参数中很容易引入误差量。CNN 具有局部连接和权重共享的特点,用 CNN 来代替全连接 BP 网络,能减少参数数量并降低模型的复杂度。

#### 4.2.3 与传统方法作比较

为了进一步证明所提方法定位的有效性,改变测试点数量,在实验场景内每隔 0.7 m 均匀选取 64 个点来测试所提方法的性能。图 9 给出了所提方法的 64 个估计点和参考点位置。同时,选取传统的 RSS 三边法、基于 SVM 的定位方法及基于决策树的定位方法与所提基于 CNN 的定位方法相比较,结果如图 10 所示。基于 SVM 的定位方法是深度学习出现之前,在机器学习中表现最好的方法。基于决策树的定位方法易于实现,短时间可以对大量数据有良好的结果,效率高。表 3 给出了 4 种不同定

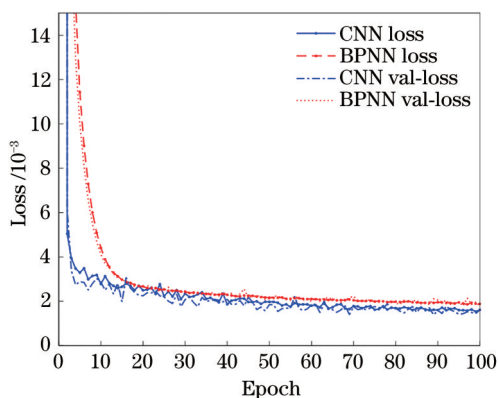


图 6 不同网络模型训练误差比较

Fig. 6 Comparison of training errors in different network models




图 7 不同网络模型定位误差比较

Fig. 7 Comparison of positioning errors in different network models




图 9 所提方法定位结果

Fig. 9 Positioning results of proposed method

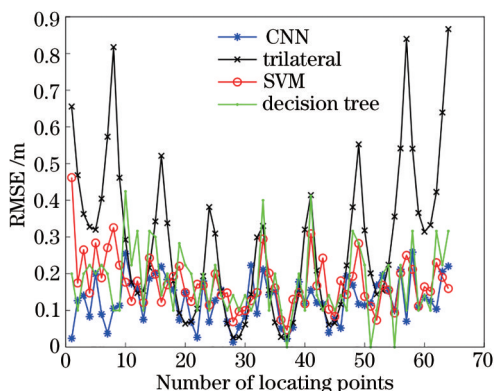


图 10 不同方法定位误差比较

Fig. 10 Comparison of positioning errors in different methods

表 3 不同方法定位误差比较

Table 3 Comparison of positioning errors in different methods

Location algorithm	Max location error	Average location error
CNN	25.02	10.13
Trilateral method	82.03	28.57
SVM	46.22	17.41
Decision tree	42.43	17.79

位方法的定位误差,可以看出,所提定位方法的最大定位误差、平均定位误差都比其他三种定位方法小很多,说明所提基于CNN的定位方法性能更好。与传统的RSS三边法相比,所提方法平均定位误差减少了64.5%,最大定位误差减小了69.5%。与基于SVM的定位方法相比,所提方法平均定位误差减少了41.8%,最大定位误差减少了45.8%。与基于决策树的定位方法相比,所提出方法平均定位误差减少了43.1%,最大定位误差减少了40.0%。

图 11 比较了不同方法的累计分布曲线,所提方法

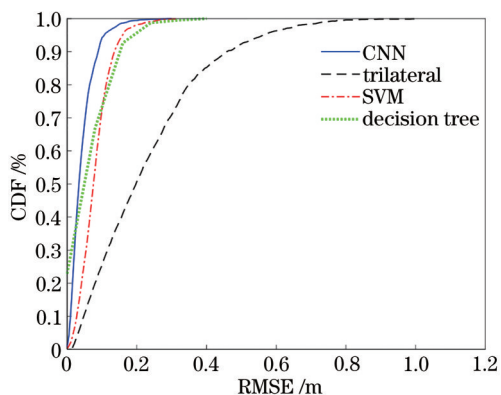


图 11 不同方法 CDF 比较

Fig. 11 Comparison of CDF in different methods

CDF 曲线左移,并且可以看出,所提方法、基于 SVM 的定位方法、基于决策树的定位方法及传统三边法在 95% 置信区间的定位误差分别为 10.50 cm、15.66 cm、19.70 cm、56.52 cm。

## 5 结 论

提出了一种基于 CNN 的室内可见光定位方法。将测量的信号强度 RSS 数据输入到 CNN 模型中,确定出精确度更高的预测位置。仿真结果表明:所提方法实现室内定位具有可行性,并可以实现高精度定位;在 5 m×5 m×3 m 的室内环境下,所提方法的平均误差为 4.44 cm,能够满足大多数室内定位服务的需求。与其他定位方法相比,所提定位方法可以更精确地定位。此外,基于 CNN 的定位方法易于训练且收敛快速,如何更好地运用到室内定位场景中值得深入研究。

## 参 考 文 献

- [1] Basiri A, Lohan E S, Moore T, et al. Indoor location based services challenges, requirements and usability of current solutions[J]. Computer Science Review, 2017, 24: 1-12.
- [2] Rida M E, Liu F Q, Jadi Y, et al. Indoor location position based on bluetooth signal strength[C]//2015 2nd International Conference on Information Science and Control Engineering, April 24-26, 2015, Shanghai, China. New York: IEEE Press, 2015: 769-773.
- [3] Liu F, Liu J, Yin Y Q, et al. Survey on WiFi-based indoor positioning techniques[J]. IET Communications, 2020, 14(9): 1372-1383.
- [4] Kitamura K, Sanada Y. Experimental examination of a UWB positioning system with high speed comparators[C]//2007 IEEE International Conference on Ultra-Wideband, September 24-26, 2007, Singapore. New York: IEEE Press, 2007: 927-932.
- [5] Bouet M, dos Santos A L. RFID tags: positioning principles and localization techniques[C]//2008 1st IFIP Wireless Days, November 24-27, 2008, Dubai, United Arab Emirates. New York: IEEE Press, 2008: 1-5.
- [6] Jovicic A, Li J Y, Richardson T. Visible light communication: opportunities, challenges and the path to market[J]. IEEE Communications Magazine, 2013, 51(12): 26-32.
- [7] Luo J H, Fan L Y, Li H S. Indoor positioning systems based on visible light communication: state of the art[J]. IEEE Communications Surveys &



- Tutorials, 2017, 19(4): 2871-2893.
- [8] Dong W J. High precision indoor visible light localization algorithm[D]. Dalian: Dalian Maritime University, 2019: 8-13.  
董文杰. 高精度室内可见光定位方法研究[D]. 大连: 大连海事大学, 2019: 8-13.
- [9] Wang X D, Wu N, Hu Q Q. Indoor visible light positioning based on multiple illuminated areas cooperation[J]. Journal of Optoelectronics·Laser, 2017, 28(4): 388-395.  
王旭东, 吴楠, 胡晴晴. 多照明区域协作的室内可见光定位[J]. 光电子·激光, 2017, 28(4): 388-395.
- [10] Alma'aitah A, Alsaify B, Bani-Hani R. Three-dimensional empirical AOA localization technique for indoor applications[J]. Sensors, 2019, 19(24): 5544-5566.
- [11] do Trong H, Yoo M. An in-depth survey of visible light communication based positioning systems[J]. Sensors, 2016, 16(5): 678-718.
- [12] Xu S W, Wu Y, Wang X F. Visible light positioning algorithm based on sparsity adaptive and location fingerprinting[J]. Acta Optica Sinica, 2020, 40(18): 1806003.  
徐世武, 吴怡, 王徐芳. 基于稀疏度自适应和位置指纹的可见光定位方法[J]. 光学学报, 2020, 40(18): 1806003.
- [13] Xu S W, Wu Y, Su G D. Fingerprint matching and localization algorithm based on orthogonal frequency division multiplexing modulation for visible light communication[J]. Laser & Optoelectronics Progress, 2019, 56(9): 090601.  
徐世武, 吴怡, 苏国栋. 基于正交频分复用调制的可见光通信指纹匹配定位方法[J]. 激光与光电子学进展, 2019, 56(9): 090601.
- [14] Zhuang Y, Hua L C, Qi L N, et al. A survey of positioning systems using visible LED lights[J]. IEEE Communications Surveys & Tutorials, 2018, 20(3): 1963-1988.
- [15] Dong W J, Wang X D, Wu N. A hybrid RSS/AOA algorithm for indoor visible light positioning[J]. Laser & Optoelectronics Progress, 2018, 55(5): 050603.  
董文杰, 王旭东, 吴楠. 基于 RSS/AOA 混合的室内可见光定位方法[J]. 激光与光电子学进展, 2018, 55(5): 050603.
- [16] Saadi M, Ahmad T, Zhao Y, et al. An LED based indoor localization system using k-means clustering [C]//2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA), December 18-20, 2016, Anaheim, CA, USA. New York: IEEE Press, 2016: 246-252.
- [17] Xiao L C, Behboodi A, Mathar R. A deep learning approach to fingerprinting indoor localization solutions [C]//2017 27th International Telecommunication Networks and Applications Conference (ITNAC), November 22-24, 2017, Melbourne, VIC, Australia. New York: IEEE Press, 2017: 1-7.
- [18] Huang H Q, Yang A Y, Feng L H, et al. Artificial neural-network-based visible light positioning algorithm with a diffuse optical channel[J]. Chinese Optics Letters, 2017, 15(5): 050601.