

基于注意力机制的可见光定位单元模型复制

王创世^{1*}, 陈勇^{1*}, 刘焕淋², 吴金兰¹, 陈豪¹, 张薇薇¹¹重庆邮电大学工业物联网与网络化控制教育部重点实验室, 重庆 400065;²重庆邮电大学通信与信息工程学院, 重庆 400065

摘要 针对室内可见光定位接收信号强度易出现波动而产生较大定位误差,以及从一个定位单元迁移到其他定位单元可能会降低定位精度的问题,笔者提出了一种基于注意力机制的卷积神经网络的室内三维定位方法,以减小接收信号波动产生的影响,并采用迁移学习将在第一个定位单元中训练的网络迁移到其他定位单元中,在保证定位精度不变的前提下减少了训练网络的成本。仿真结果表明:所提算法在 $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ 的定位单元内可以实现平均误差为 3.54 cm 的三维定位;采用迁移学习将已训练网络部署到第二个定位单元中,可以实现平均误差为 3.67 cm 的定位。实验结果表明:在 $1.2\text{ m} \times 0.75\text{ m} \times 1.2\text{ m}$ 的定位单元实验中,所提算法可以实现平均误差为 3.32 cm 的三维定位,90% 的误差分布在 4.12 cm 内;采用迁移学习将已训练网络部署到第二个定位单元中,可以实现平均误差为 3.35 cm 的定位。与现有算法相比,所提算法迁移前后的定位精度均有所改善。

关键词 光通信; 可见光定位; 注意力机制; 卷积神经网络; 迁移学习

中图分类号 O436 **文献标志码** A

DOI: 10.3788/CJL231279

1 引言

随着物联网的快速发展及应用,基于位置服务的高精度室内定位技术展现出了广阔的应用前景。Wi-Fi、红外、蓝牙和超宽带等室内定位方法存在系统稳定性低、响应时间长、电磁干扰大、成本高等问题,与之相比,可见光定位(VLP)方法具有成本低、精度高、绿色环保和无电磁干扰等优势。可见光定位系统可以与可见光通信(VLC)结合,同时提供照明、数据传输和定位,具有较强的实用性和商业价值^[1-3]。

基于接收信号强度值(RSS)的定位方法现存的主要挑战之一是RSS随机波动,这是接收器的热效应、信道中阴影的变化和多径效应共同作用的结果。为了提高室内可见光定位的精度,需要在整个定位空间中进行采样,获得更精细的指纹库。Chen等^[4]采用改进的蝙蝠算法实现了三维定位,但其未考虑信号强度变化以及单元迁移的问题;Chuang等^[5]将整个定位区域划分为多个定位单元,但只考虑了单元间LED相对位置不变的情况,这会导致误差增大以及迁移能力下降;2019年,Zhang等^[6]通过仿真实现了基于人工神经网络(ANN)和混合RSS/到达相位差(PDOA)的3D室内可见光定位系统,但是ANN可能会出现过拟合的问题。为了提高室内可见光定位的精度,张雁鹏等^[7]

设计了一种光敏二极管(PD)接收机并用其进行定位,但其所用算法需要对LED的位置进行固定,不易迁移到其他定位单元中。目前,大多数研究人员只关注一个定位单元内的定位性能,并假设该定位单元可以重复复制,以覆盖整个区域,但实际上不同单元中LED的相对位置可能是不同的。因此,这样的假设会存在比较大的定位误差^[8]。

针对上述研究中存在的问题,笔者提出了基于注意力机制的卷积神经网络(以下简称“注意力CNN”)的室内三维定位方法。首先采用快速傅里叶变换对RSS值进行预处理,将得到的频域信号代入卷积神经网络^[9]中进行训练,然后采用迁移学习(TL)将经过训练的网络模型部署到其他定位单元中。

2 室内可见光定位模型分析

2.1 系统模型与信道分析

图1给出了可见光定位系统模型,定位空间尺寸为 $10\text{ m} \times 10\text{ m} \times 3\text{ m}$,该定位空间被分成4个定位单元,8个LED安装在房间的天花板上。编码调制后实现信息的传送,接收端为PD。

由于光线在反射和传播中会大幅衰减,而视距(LoS)链路和一次反射链路占总信道的98.56%^[10],因此这里仅考虑视距链路信道和一次反射链路信

收稿日期: 2023-10-12; 修回日期: 2023-11-16; 录用日期: 2023-12-11; 网络首发日期: 2023-12-12

基金项目: 国家自然科学基金(51977021)、重庆市自然科学基金(CSTB2023NSCQ-MSX0734)、重庆市研究生科研创新项目(CYS22483)

通信作者: *chenyong@cqupt.edu.cn; **s210301048@stu.cqupt.edu.cn




图1 室内定位仿真模型

Fig. 1 Indoor positioning simulation model

道。假设 t 时刻 PD 接收 N 条 LED 视距链路和 M 条一次反射链路的信号 $s_i(t)$, 则 PD 接收到的信号可以表示为

$$\gamma(t) = R_p s_i \left[\sum_{i=1}^N H_i^{\text{dir}}(t - \tau_i^{\text{dir}}) + \sum_{i=1}^M H_i^{\text{ref}}(t - \tau_i^{\text{ref}}) \right] + \sigma_{\text{sum}}^2(t), \quad (1)$$

式中: R_p 是光电转换效率; τ_i^{dir} 和 τ_i^{ref} 是第 i 个 LED 光通过直射链路和一次反射链路到达 PD 的延时; σ_{sum}^2 表示接收到的噪声; H_i^{dir} 和 H_i^{ref} 分别表示为第 i 个 LED 与接收器之间视距链路和一次反射链路的信道增益。直射

$$H^{\text{ref}}(0) = \begin{cases} \frac{(m+1)A_{\text{PD}}}{2(\pi d_1 d_2)^2} \rho d A_{\text{wall}} \cos^m(\phi) \cos(\psi) \cos(\alpha) \cos(\beta) G, & 0 \leq \psi \leq \theta_{\text{FOV}} \\ 0, & \psi > \theta_{\text{FOV}} \end{cases} \quad (3)$$

设 P_i 为发光二极管的光功率, 则某一点接收的光功率可以表示为

$$P_{r,i} = P_i H^{\text{dir}}(0) + \int P_i H^{\text{ref}}(0). \quad (4)$$

在 VLC 系统中, 接收信号存在散粒噪声 σ_{shot}^2 与热噪声 $\sigma_{\text{thermal}}^2$, 两者之和通常采用加性高斯白噪声 (AWGN) σ_{sum}^2 表示。接收信号的质量可以通过信噪比 (SNR) 来反映, 其计算公式为

$$S_{\text{SNR}} = 10 \lg_{10} \left[\frac{(P_{r,i} R_p)^2}{\sigma_{\text{sum}}^2} \right]. \quad (5)$$

2.2 定位单元模型设计

LED 部署在不同定位单元中的相对位置可能存在差异, 如图 2 所示。将待定位的室内分为 4 个定位单元, LED 的坐标分别为 $(0 \text{ m}, 0 \text{ m}, 3 \text{ m})$ 、 $(0 \text{ m}, 10 \text{ m}, 3 \text{ m})$ 、 $(2.5 \text{ m}, 5 \text{ m}, 3 \text{ m})$ 、 $(5 \text{ m}, 3 \text{ m}, 3 \text{ m})$ 、 $(5 \text{ m}, 7.5 \text{ m}, 3 \text{ m})$ 、 $(8 \text{ m}, 5 \text{ m}, 3 \text{ m})$ 、 $(10 \text{ m}, 0 \text{ m}, 3 \text{ m})$ 和 $(10 \text{ m}, 10 \text{ m}, 3 \text{ m})$ 。本定位系统的发射端用 STM32 驱动 LED 实现信息的发送, 接收端由 PD 实现。对每个单元中的 3 个 LED 进行脉宽调制 (PWM), 单元内的 LED 分配不同的频率, 单元之间的 LED 通过不同的占空比来区分, 以产生频域可以区分的信号。采用偏置电路将调制后的信号与直流 (DC) 源结合, 以确保 LED 在线性区域偏置。

链路的信道增益^[11]描述为

$$H^{\text{dir}}(0) = \begin{cases} \frac{(m+1)A_{\text{PD}}}{2\pi d^2} \cos^m(\phi) \cos(\psi) G, & 0 \leq \psi \leq \theta_{\text{FOV}} \\ 0, & \psi > \theta_{\text{FOV}} \end{cases}, \quad (2)$$

式中: $m = \frac{-\ln 2}{\ln(\cos \Phi_{1/2})}$ 代表 LED 的朗伯阶, 其中 $\Phi_{1/2}$

是 LED 的功率半角 (m 值的大小决定了波束的方向性, 而且 m 值越大, 波束的方向性越好); A_{PD} 表示 PD 的有效接收面积; d 代表接收端到 LED 的距离, 由 $d = \|\mathbf{r}_{\text{LED}_i} - \mathbf{r}_{\text{PD}}\|$ 给出, $\|\cdot\|$ 代表矢量的欧氏范数, \mathbf{r}_{PD} 代表接收端的位置坐标; ϕ 和 ψ 分别表示发射角和入射角; G 为物理器件的增益, $G = T(\psi)g(\psi)$, 其中 $T(\psi)$ 为滤波器的增益, $g(\psi)$ 为光集中器的增益; θ_{FOV} 为视场角。

在反射环节中, 墙体上的反射点也被视为朗伯辐射。假设 d_1 为 LED 到墙壁反射点的距离, d_2 为反射点到 PD 的距离, ρ 为墙壁的反射系数, dA_{wall} 为反射墙面的微元面积, α 为 LED 灯发出的光在墙面反射点处的入射角, β 为反射光从墙面射出的出射角。因此, 反射环节的信道增益可以表示为




图2 仿真定位模型俯视图

Fig. 2 Top view of simulation positioning model

假设有占空比为 D 、幅值为 A 、周期为 T 的方波, 其在一个周期内的函数表达式为

$$x(t) = \begin{cases} A, & |t| \leq \frac{DT}{2} \\ 0, & t > \frac{DT}{2} \end{cases}, \quad -\frac{T}{2} \leq t \leq \frac{T}{2}, \quad (6)$$

在一个周期内的傅里叶展开式为

$$f(t) = DA + \frac{2A}{\pi} \sum_{n=1}^{\infty} \frac{\sin(Dn\pi)}{n} \cos(n\omega_p t), \quad n = 1, 2, 3, \dots, \quad (7)$$

式中： $\omega_p = 2\pi/T$ 为相位。因此，在占空比 D 不同的 PWM 波形的傅里叶展开中，不同谐波的振幅和相位

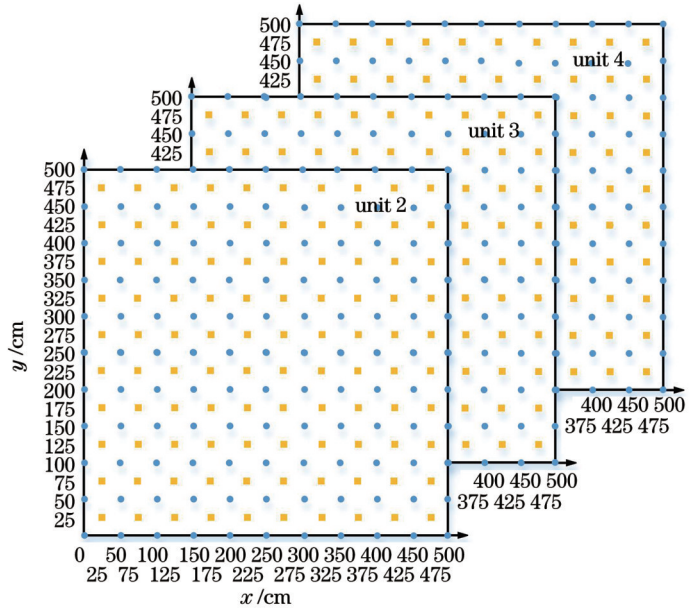
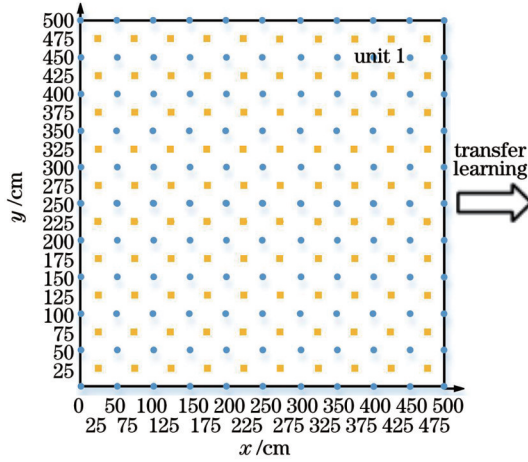


图 3 仿真定位单元俯视图(圆形点为训练点,矩形点为测试点)

Fig. 3 Top view of simulation positioning units (circular and rectangular dots are training and test points, respectively)

2.3 RSS 信号预处理

由于接收到的 RSS 值可能会产生波动,将 t 时刻接收到的信号 $\gamma(t)$ 作为特征值进行定位计算可能会产生较高的定位误差,因此要在每个定位点连续采集 N 次,并对接收到的时域信号进行处理,以减小 RSS 值波动带来的影响。

对于接收信号 $\gamma(t)$,其快速傅里叶变换(FFT)为

$$Y_N(\omega) = \sum_{t=1}^N \gamma(t) \exp(-j\omega t), \quad (8)$$

式中： N 是快速傅里叶变换的长度,本文选择 $N = 1024$; $\omega = 2\pi f$ 是模拟频率,其中 f 为 LED 的频率。根据帕塞瓦尔定理,信号的能量在时域和频域上相等,则 $\gamma(t)$ 的功率谱密度(PSD)估计可表示为

$$S(\omega) = \frac{1}{N} |Y_N(\omega)|^2. \quad (9)$$

$S(\omega)$ 的峰值可以指示不同频率下接收信号的平均功率^[13]。因此,可以通过捕捉 $S(\omega)$ 中固定频率的峰值来获得估计的 RSS 向量 \mathbf{r} ,即

$$\mathbf{r} = [S(\omega_1), S(\omega_2), \dots, S(\omega_N)]^T, \quad (10)$$

式中： $\omega_i = 2\pi f_i$, f_i 为第 i 个 LED 的频率。为了避免人眼能识别到的闪烁,选取的频率应该大于 200 Hz^[14]。

快速傅里叶变换后的数据 $S(\omega_i)$ ($i=0, 1, 2, \dots, N/2-1$) 与 $-S(\omega_i)$ ($i=N/2, N/2+1, \dots, N-1$) 等价,即功率信号关于点 $(N/2, 0)$ 中心对称。为了减少

都不同,可用此区别不同的 LED。

如图 3 所示,在每个单元中采集 121 个圆形点位的 RSS 值并将其作为神经网络的训练数据集,采集 100 个矩形点位的 RSS 值并将其作为测试数据集。每个点采集 20 次并取平均值,以减小测量误差。

计算量,只利用变换后功率信号的 1024 个信号点中的前 512 个点,将其转换为 16×32 的矩阵并代入到 CNN 算法中进行训练。

2.4 注意力机制的 CNN 模型

利用 CNN 处理 PSD 特征,通过卷积处理得出的不同特征来降低接收信号波动产生的影响。该 PSD 特征是由移动节点从定位点捕获的 RSS 时间序列通过快速傅里叶变换生成的。如图 4 所示,CNN 包括两个卷积层、两个最大池化层和两层全连接层,以便兼顾

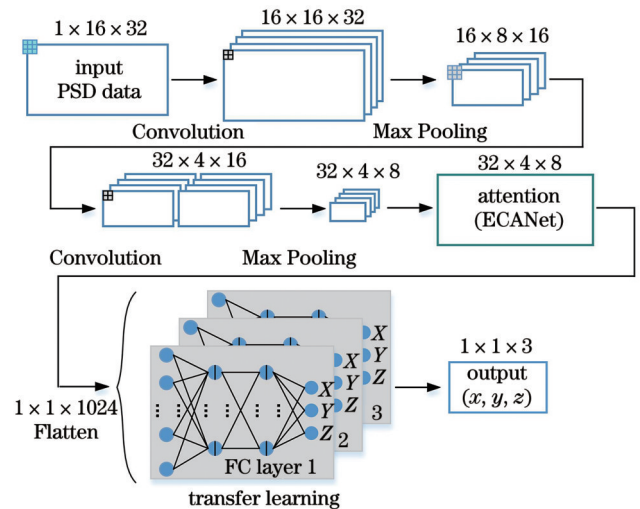


图 4 注意力 CNN 结构图

Fig. 4 Architecture of attention CNN

定位精度和计算成本。每个隐藏层的激活函数是校正线性单位(ReLU)函数。此外,为了保证卷积输出的特征图大小与输入信号不变,卷积核大小设置为3,步长设置为1,填充设置为1,第一个卷积操作输出16层特征,第二个卷积操作输出32层特征;最大池化选取 2×2 矩阵,输出矩阵的长宽都变为原来的1/2。

由于输入PSD矩阵可能存在冗余无用的信息,为了提升所设计的网络模型的细节特征学习能力,引入注意力机制^[15-16]。在图4所示的网络结构中增加通道注意力模块(CAM),经模块调整后的通道权值乘以输入的特征层便可得到融合注意力特征。同时,将通道注意力模块的输出平坦化成一维阵列,以便连接后面的FC层。两层FC层神经元的数量分别是64和32,其中FC层的激活函数采用ReLU函数。3个输出分别是预测的坐标 $(\hat{x}, \hat{y}, \hat{z})$ 。为了获得较好的预测效果,选取均方误差(MSE,在公式中记为 E_{MSE})作为损失函数,即

$$E_{\text{MSE}} = \frac{\sum_{i=1}^n [(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2 + (\hat{z}_i - z_i)^2]}{n}, \quad (11)$$

式中: n 为定位点的个数; (x, y, z) 为实际坐标。

选取初始学习率为0.001的Adam优化器,训练数据batch为12,丢弃层的比率设置为0.1^[8]。

如图5所示,采用通道注意力模块对输入的 $32 \times 4 \times 8$ 特征层进行全局平均池化(GAP),池化后的特征大小为 $1 \times 1 \times 32$,用1D卷积进行处理,卷积核由输入特征层的大小自适应计算得到。处理后的结果通过Sigmoid压缩到(0~1)之间作为权值,即得到输入特征层每一个通道的权值 $M_c(F) \in [0, 1]$ 。将这个权值乘以原输入特征层,得到通道注意力特征为

$$M_c(F) = \sigma \{ \text{conv1D}[\text{AvgPool}(F)] \}, \quad (12)$$

式中: F 为输入特征; $\sigma(\cdot)$ 为Sigmoid函数;conv1D(\cdot)为1D卷积操作;AvgPool为全局平均池化(GAP)。




图5 注意力网络结构(ECANet)

Fig. 5 Attention network architecture (ECANet)

当定位空间较大时,需要将其划分为很多定位单元。若每个定位单元都进行训练,则会耗费比较高的时间成本。由于处于同一个空间中的定位单元的特征是相似的,因此引入迁移学习来优化参数的训练,减少网络的训练次数。

2.5 迁移学习模型

在训练阶段采用注意力CNN算法对图3所示单元1中的数据进行训练,选取均方误差作为损失函数,利用反向传播更新参数,直到均方误差小于设定的阈值,然后将注意力CNN分别迁移到单元2、3中。不同的单元具有相似的特征(可能LED位置以及噪声大小存在差异),因此保留提取特征的CNN卷积层,只对单元2、3中全连接层的参数进行更新。这样不仅减少了采集数据量,还缩短了训练时间。在实验阶段,针对不同的单元选择训练好的网络即可实现定位。采用式(11)作为损失函数来实现全连接层的反向传播。

3 仿真与实验

3.1 仿真测试

为了验证本文算法的性能,采用CNN算法作为对比算法。选取的CNN算法的结构与本文算法具有相

同的结构,系统仿真模型参数见表1。将 $10 \text{ m} \times 10 \text{ m} \times 3 \text{ m}$ 的定位空间均分为4个单元(单元1、单元2、单元3、

表1 仿真模型参数

Table 1 Parameters of simulation model

Parameter	Value
Positioning space size	$10 \text{ m} \times 10 \text{ m} \times 3 \text{ m}$
Unit size	$5 \text{ m} \times 5 \text{ m} \times 3 \text{ m}$
Transmitted power of a lamp	$P_i = 5 \text{ W}$
Semi-angle at a half power	$\Phi_{1/2} = 60^\circ$
Gain of optical filter	$T_s(\psi) = 1$
Gain of optical concentrator	$g(\psi) = 1$
Physical area of photo-detector	$A_{\text{PD}} = 1 \text{ cm}^2$
Position of LEDs	$(0 \text{ m}, 0 \text{ m}, 3 \text{ m}), (0 \text{ m}, 10 \text{ m}, 3 \text{ m}), (2.5 \text{ m}, 5 \text{ m}, 3 \text{ m}), (5 \text{ m}, 3 \text{ m}, 3 \text{ m}), (5 \text{ m}, 7.5 \text{ m}, 3 \text{ m}), (8 \text{ m}, 5 \text{ m}, 3 \text{ m}), (10 \text{ m}, 0 \text{ m}, 3 \text{ m}), (10 \text{ m}, 10 \text{ m}, 3 \text{ m})$
Field of view	$\theta_{\text{FOV}} = 60^\circ$
Refractive index	$n = 1.5$
Wall reflection coefficient	$\rho = 0.6$
Signal-to-noise ratio	$S_{\text{SNR}} = 20 \text{ dB} - 29 \text{ dB}$

单元 4), 每个单元的尺寸为 $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ 。为了模拟真实环境中存在的噪声, 在采集的数据中添加均值为 0、标准差为 0.1 的高斯噪声, 信噪比为 20 dB~29 dB。

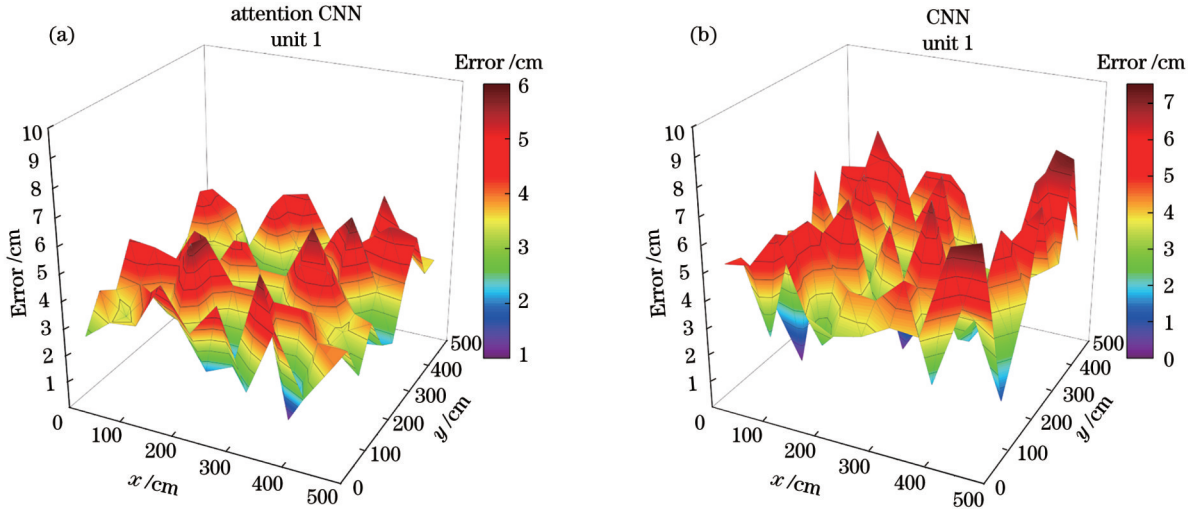


图 6 迁移学习前的仿真误差分布图。(a)注意力 CNN 的定位; (b)CNN 的定位

Fig. 6 Simulation error distributions before transfer learning. (a) Positioning of attention CNN; (b) positioning of CNN

图 7 的横轴为三维定位误差, 纵轴表示概率密度函数(CDF, 用来表征定位误差的概率密度分布)。由图 6 和图 7 可以看出: 注意力 CNN 算法的最大误差为 5.9 cm, 平均误差为 3.54 cm, 90% 的误差为 4.41 cm; CNN 算法的最大误差为 7.63 cm, 平均误差为 4.25 cm, 90% 的误差为 5.32 cm。可见, 注意力 CNN 算法具有更高的定位精度。

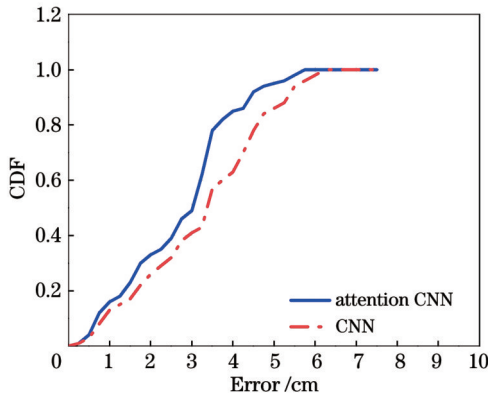


图 7 仿真定位误差累积分布函数图

Fig. 7 Simulation positioning error cumulative distribution function diagram

3.1.2 迁移学习效果分析

接下来以网络迁移到定位单元 2 和定位单元 3 为例进行分析, 迁移到其他单元同理。图 8 是注意力 CNN 在单元 2 和单元 3 中的定位误差分布图。

分析图 8 可知: 部署在单元 2 中定位得到的最大误差为 6.16 cm, 平均误差为 3.67 cm; 部署到单元 3 中的最大定位误差为 5.94 cm, 平均误差为

3.1.1 迁移前的误差分析

在单元 1 中对圆形数据点(图 3)进行训练, 采用矩形数据点进行测试。注意力 CNN 与 CNN 算法的定位误差分布如图 6 所示。

3.66 cm。仿真结果证明了所提出的迁移学习方法的有效性。

分析图 9 可得: 采用迁移学习将注意力 CNN 算法分别部署到单元 2 和单元 3, 90% 以上的定位误差分别低于 4.33 cm 和 4.31 cm; CNN 算法的平均定位误差为 10.97 cm。可见, 采用迁移学习的注意 CNN 算法的定位误差更小。

3.1.3 收敛性分析

图 10 表明了采用迁移学习的注意力 CNN 算法与 CNN 算法在同一定位单元内的迭代次数与损失函数值之间的关系, 其中横轴表示迭代次数, 纵轴表示损失函数值。为了减小偶然性的影响, 分别对两种算法进行 10 次训练并取平均值。相比于 CNN, 在损失函数值降低到 100 内时, 注意力 CNN 可以提升 48% 的收敛速度。采用迁移学习的注意力 CNN 算法比 CNN 算法的收敛更快。这是由于在单元 1 中训练好的网络应用迁移学习部署到其他单元中时, 只更新全连接层的参数, 保留前面卷积层的参数, 因而在部署到其他单元时可以快速收敛。同时, 融合注意力特征可以使模型更加关注有用的通道信息, 也能使网络实现更快速的拟合。

3.2 实验测试

如图 11 所示, 实验空间大小为 $1.5\text{ m} \times 1.2\text{ m} \times 1.2\text{ m}$, 分为两个定位单元(单元 1 和单元 2), 每个定位单元的大小为 $0.75\text{ m} \times 1.2\text{ m} \times 1.2\text{ m}$ 。每个单元采用 3 个 LED, 接收端是采用 RC 低通滤波器的 PD。采集并经过滤波后的数据通过数据采集卡(USB-6001)进行 ADC(模数转换)数据采样, 然后进入计算机中进行处理, 采集速率为 10 kHz, 计算机 CPU 为 AMD Ryzen7

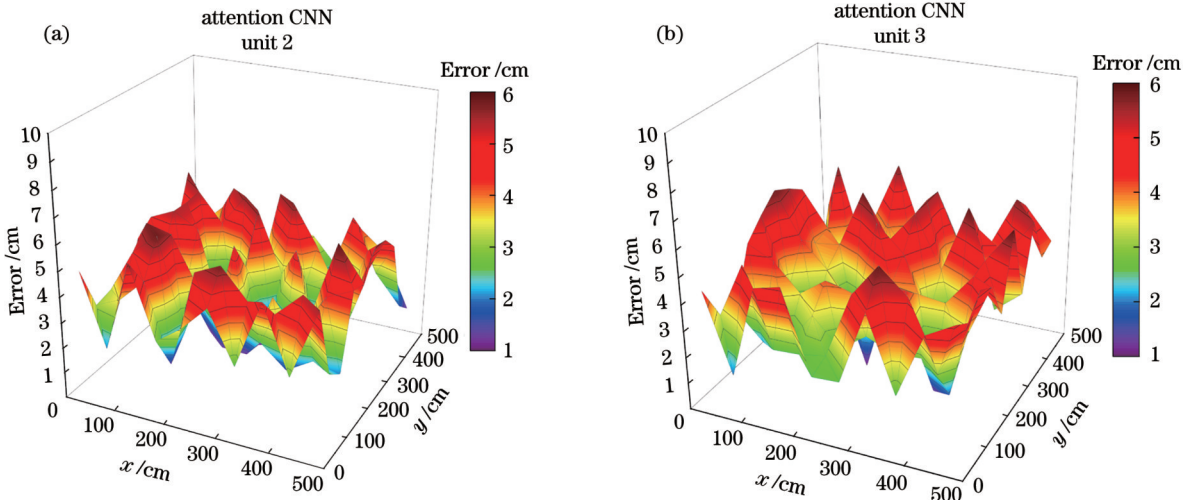


图 8 注意力 CNN 部署到其他定位单元时的定位误差分布图。(a)注意力 CNN 在单元 2 中的定位; (b)注意力 CNN 在单元 3 中的定位
Fig. 8 Positioning error distributions when attention CNN was deployed to other positioning units. (a) Positioning of attention CNN in unit 2; (b) positioning of attention CNN in unit 3

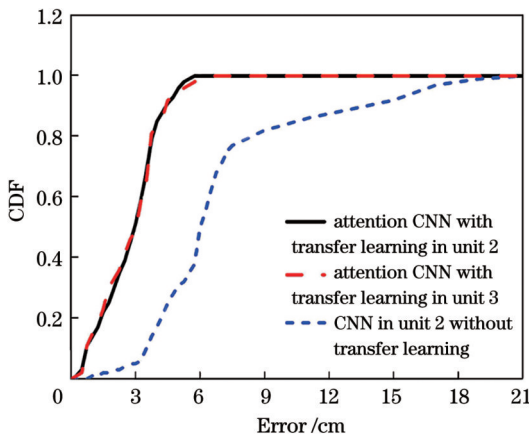


图 9 迁移学习和未更新参数复制到新定位单元中的网络的累积误差图
Fig. 9 Cumulative error function diagram of the network copied into the new location cell using transfer learning and unupdated parameters

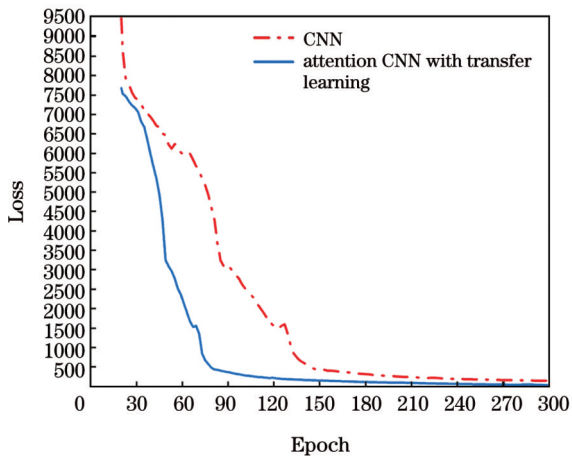


图 10 采用迁移学习的注意力 CNN 算法与 CNN 算法的收敛性对比
Fig. 10 Convergence comparison between attention CNN with transfer learning and CNN

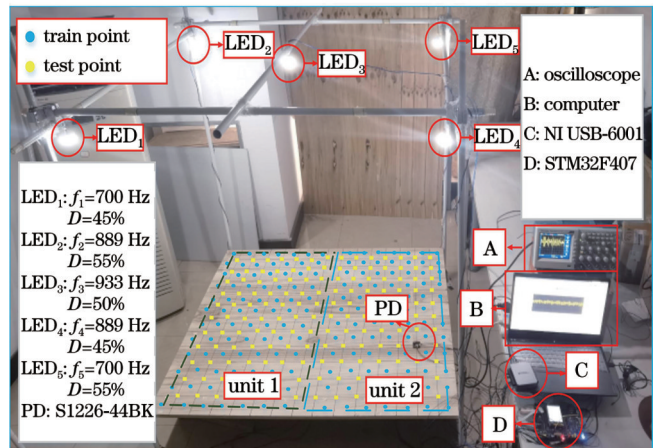


图 11 室内定位实验图

Fig. 11 Indoor positioning experiment photo

5800H, 运行内存为 16 GB, GPU 为 RTX 3060。实验参数见表 2。

3.2.1 迁移前的定位误差分析

如图 11 所示,在迁移前的单元 1 与迁移后的单元中每隔 10 cm 进行采样,84 个圆形点位为训练点位,在 77 个矩形点位置设置测试点。为了降低误差,在每个点采集 20 次并取平均值,分别采用注意力 CNN 算法、CNN 算法和残差级联神经网络(RCNN)算法^[17]进行训练,并用测试点对训练好的网络进行测试。图 12 是注意力 CNN、CNN 和 RCNN 算法在迁移前的单元 1 中的误差分布图。注意力 CNN 算法的最大误差为 6.86 cm,平均误差为 3.32 cm,90% 的误差分布在 4.12 cm 内;CNN 算法的最大误差为 7.36 cm,平均误差为 4.02 cm,90% 的误差分布在 5.42 cm 内;RCNN 算法的最大误差为 8.33 cm,平均误差为 4.69 cm,90% 的误差分布在 6.09 cm 内。上述分析表明所提算法的定位误差最低。

表 2 实验参数
Table 2 Experimental parameters

Parameter	Value
Positioning space size	$1.5\text{ m} \times 1.2\text{ m} \times 1.2\text{ m}$
Unit size	$0.75\text{ m} \times 1.2\text{ m} \times 1.2\text{ m}$
Transmitted power of a lamp	$P_t=5\text{ W}$
Semi-angle at a half power	$\Phi_{1/2}=60^\circ$
Gain of optical filter	$T_s(\psi)=1$
Gain of optical concentrator	$g(\psi)=1$
Physical area of photo-detector	$A_{PD}=12.96\text{ mm}^2$
Position of LED _s in unit 1	(0 mm, 0 mm, 1.2 mm), (0 mm, 1.2 mm, 1.2 mm), (0.75 mm, 0.6 mm, 1.2 mm)
Position of LED _s in unit 2	(0.75 mm, 0.6 mm, 1.2 mm), (1.5 mm, 0 mm, 1.2 mm), (1.5 mm, 1.2 mm, 1.2 mm)
Field of view	$\theta_{FOV}=60^\circ$
Signal-to-noise ratio	$S_{SNR}=20\text{ dB}$

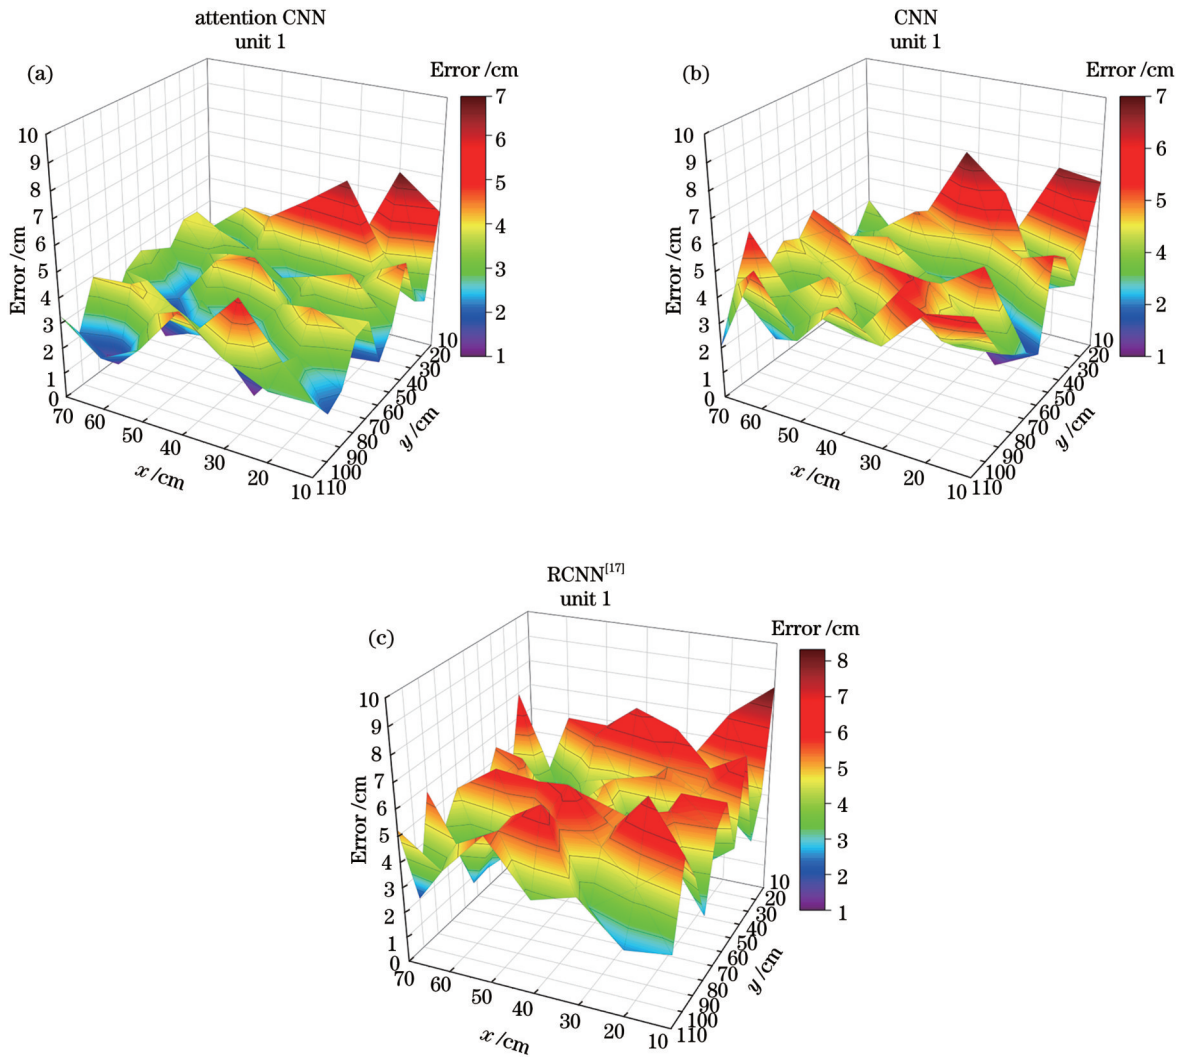


图 12 迁移学习前的实验定位结果。(a)注意力 CNN 的定位;(b) CNN 的定位;(c) RCNN 的定位^[17]

Fig. 12 Experimental positioning results before transfer learning. (a) Positioning of attention CNN; (b) positioning of CNN; (c) positioning of RCNN^[17]

3.2.2 迁移后的定位误差分析

图 13 是注意力 CNN、CNN 和 RCNN 算法分别迁移到单元 2 中的误差分布图。注意力 CNN 算法定位的最大误差为 6.46 cm, 平均误差为 3.35 cm, 90% 的误差分布在 4.47 cm 内; CNN 算法定位的最

大误差为 7.02 cm, 平均误差为 4.04 cm, 90% 的误差分布在 5.49 cm 内; RCNN 算法定位的最大误差为 8.98 cm, 平均误差为 5.64 cm, 90% 的误差分布在 7.05 cm 内。上述结果表明所提算法的定位效果最好。

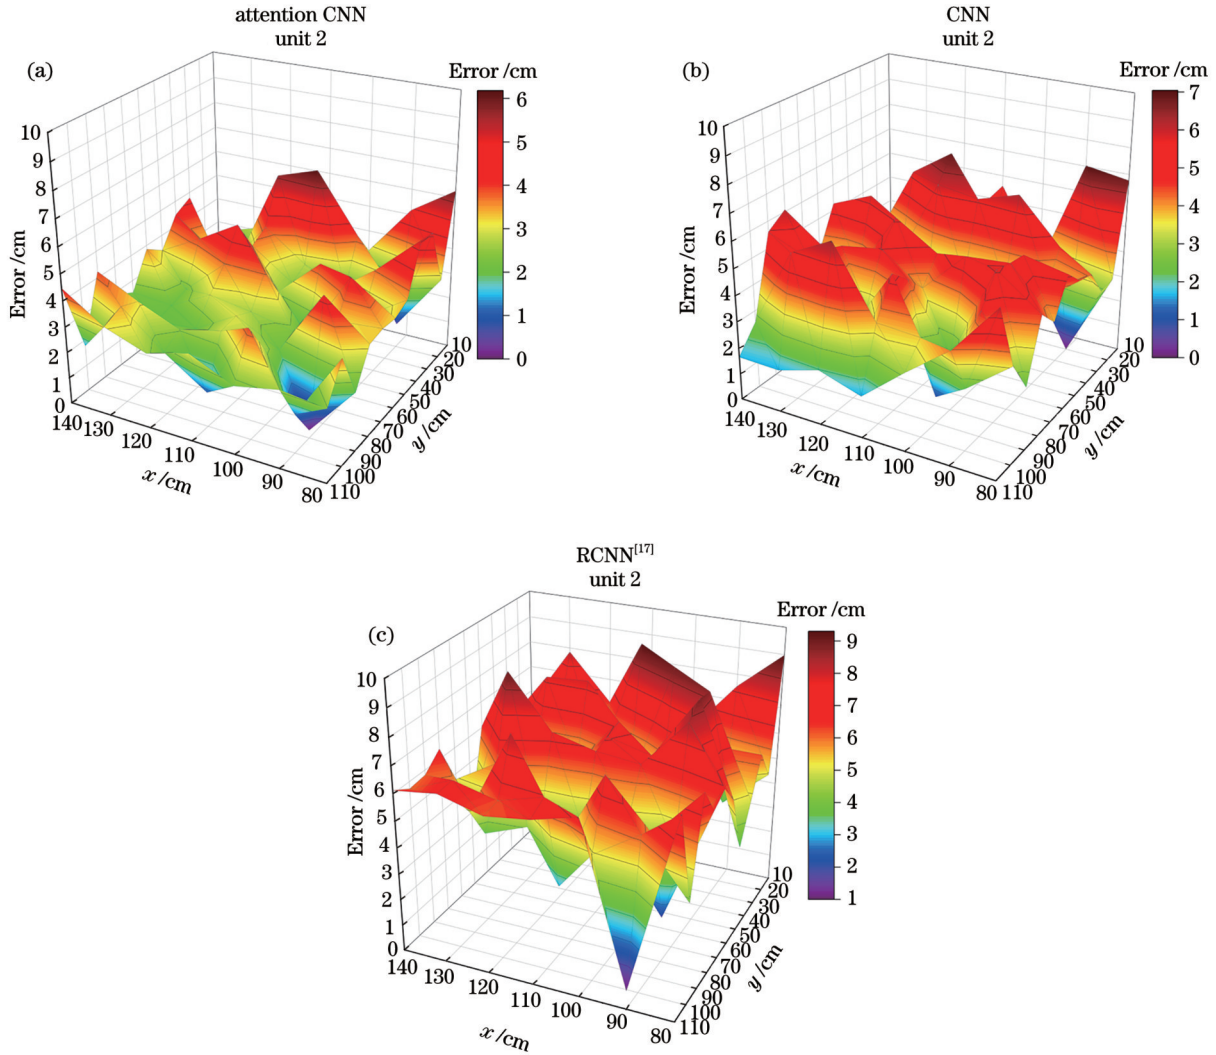


图 13 迁移学习后的实验定位结果。(a)注意力 CNN 的定位;(b) CNN 的定位;(c) RCNN 的定位

Fig. 13 Experimental positioning results after transfer learning. (a) Positioning of attention CNN; (b) positioning of CNN; (c) positioning of RCNN

3.2.3 算法定位误差对比

分析表 3 可得:与 CNN 和 RCNN 算法相比,所提算法在单元 1 中的平均定位误差分别减小了 17.4% 和

29.2%,在单元 2 的平均定位误差分别减小了 17.1% 和 40.6%。验证了所提算法的有效性。

4 结 论

笔者提出了基于注意力 CNN 的室内三维定位方法。采用快速傅里叶变换对 RSS 值进行预处理,然后将得到的频域信号代入 CNN 中进行训练。为了降低训练成本,采用迁移学习将训练好的网络模型部署到其他定位单元。仿真与实验结果表明,与对比算法相比,所提出的算法可以有效降低接收信号波动带来的影响,提高定位精度。所提算法具有一定的参考价值。

表 3 不同算法的平均定位误差对比

Table 3 Comparison of average positioning error of different algorithms

Algorithm	Average positioning error in unit 1 /cm	Average positioning error in unit 2 /cm
Attention CNN	3.32	3.35
CNN	4.02	4.04
RCNN ^[17]	4.69	5.64

参 考 文 献

- [1] 陈勇, 吴志倩, 刘焕淋, 等. 基于神经网络的可见光通信系统信道估计方法[J]. 光学学报, 2023, 43(7): 0706004.
Chen Y, Wu Z Q, Liu H L, et al. Neural-network-based channel estimation method for visible light communication systems[J]. Acta Optica Sinica, 2023, 43(7): 0706004.
- [2] 谢显中, 高龙龙, 卢华兵. VLC 网络中兼顾 QoS 和公平性的协作子载波与功率分配算法[J]. 重庆邮电大学学报(自然科学版), 2021, 33(1): 7-17.
Xie X Z, Gao L L, Lu H B. Coordinated subcarrier and power allocation algorithms considering both QoS and fairness for VLC networks[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2021, 33(1): 7-17.
- [3] Jenila C, Jeyachitra R K. Green indoor optical wireless communication systems: pathway towards pervasive deployment [J]. Digital Communications and Networks, 2021, 7(3): 410-444.
- [4] Chen Y, Zheng H, Liu H L, et al. Indoor high precision three-dimensional positioning system based on visible light communication using improved hybrid bat algorithm[J]. IEEE Photonics Journal, 2020, 12(5): 6802513.
- [5] Chuang Y C, Li Z Q, Hsu C W, et al. Visible light communication and positioning using positioning cells and machine learning algorithms[J]. Optics Express, 2019, 27(11): 16377-16383.
- [6] Zhang S, Du P F, Chen C, et al. Robust 3D indoor VLP system based on ANN using hybrid RSS/PDOA[J]. IEEE Access, 2019, 7: 47769-47780.
- [7] 张雁鹏, 朱东亚, 马军民, 等. 基于单目视觉和可见光成像通信的地铁列车定位[J]. 激光与光电子学进展, 2022, 59(16): 1606001.
Zhang Y P, Zhu D Y, Ma J M, et al. Subway train positioning based on monocular vision and optical camera communication[J]. Laser & Optoelectronics Progress, 2022, 59(16): 1606001.
- [8] Abdalmajeed A M M, Mahmoud M, El-Fikky A E R A, et al. Improved indoor visible light positioning system using machine learning[J]. Optical and Quantum Electronics, 2023, 55(3): 209.
- [9] 万子文, 吴雅婷, 梁如斌, 等. 基于联合干扰的室内可见光通信安全系统[J]. 光学学报, 2023, 43(4): 0406002.
Wan Z W, Wu Y T, Liang R B, et al. Indoor visible light communication security systems based on cooperative jamming[J]. Acta Optica Sinica, 2023, 43(4): 0406002.
- [10] 雷新颖, 王成. 一种多孔径接收器的设计及其可见光通信系统[J]. 重庆邮电大学学报(自然科学版), 2021, 33(1): 59-66.
Lei X Y, Wang C. Design of amultiple bore diameter receiver and its visible communication system[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2021, 33(1): 59-66.
- [11] Li Q L, Wang J Y, Huang T, et al. Three-dimensional indoor visible light positioning system with a single transmitter and a single tilted receiver[J]. Optical Engineering, 2016, 55(10): 106103-106110.
- [12] Guo X S, Shao S H, Ansari N, et al. Indoor localization using visible light via fusion of multiple classifiers[J]. IEEE Photonics Journal, 2017, 9(6): 7803716.
- [13] IEEE recommended practices for modulating current in high-brightness LEDs for mitigating health risks to viewers: IEEE Std 1789-2015[S]. New York: IEE Press, 2015.
- [14] Guo M H, Xu T X, Liu J J, et al. Attention mechanisms in computer vision: a survey[J]. Computational Visual Media, 2022, 8(3): 331-368.
- [15] Khan L U. Visible light communication: applications, architecture, standardization and research challenges[J]. Digital Communications and Networks, 2017, 3(2): 78-88.
- [16] Lin D C, Chow C W, Peng C W, et al. Positioning unit cell model duplication with residual concatenation neural network (RCNN) and transfer learning for visible light positioning (VLP)[J]. Journal of Lightwave Technology, 2021, 39(20): 6366-6372.

Attention Mechanism for Visible Light Positioning Unit Model Replication

Wang Chuangshi^{1**}, Chen Yong^{1*}, Liu Huanlin², Wu Jinlan¹, Chen Hao¹, Zhang Weiwei¹¹Key Laboratory of Industrial Internet of Things & Network Control, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;²School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract

Objective With the rapid development and application of the Internet of Things (IoT) and indoor activities, high-precision indoor positioning technology based on location services has a wide range of applications. Given that GPS and Beidou signals lead to signal attenuation when penetrating buildings, it is impossible to realize accurate indoor positioning, and an effective indoor positioning method is urgently required to compensate for the vacancy of high-precision indoor positioning. Compared with other indoor positioning methods, visible light indoor positioning, based on the received signal strength, can be used as an effective indoor positioning method owing to its advantages of low cost, high precision, and ease of deployment. However, the existence of multipath effect, shadow change, receiver thermal effect, and other problems can lead to fluctuations in the strength of the received indoor visible light positioning signal, and thereby, resulting in large positioning errors. Furthermore, in extant studies, researchers tend to solely examine one positioning unit and assume that it can be completely copied to other positioning units. However, the migration from one positioning unit to other positioning units may lead to high positioning errors due to different LED positions, varying noise levels, and other differences. Therefore, it is important to solve the jitter problem of the received signal and improve the accuracy of

indoor positioning.

Methods To address the problem of jitter in received signals, in this study, a convolutional neural network was proposed based on an attention mechanism (Fig. 4) to reduce the impact of fluctuations in received signals. First, a fast Fourier transform was used to preprocess the received time-domain signal strength values, and the power spectra of the signals were obtained. A CNN with an attention mechanism was used to extract the features of the signal power spectrum, and a channel attention module (Fig. 5) was used to increase the weights for each channel to reduce the influence of redundant information on the network. This in turn reduces the influence of signal fluctuations on positioning accuracy. To solve the problem, in which migrating to different localization units may decrease the localization accuracy, transfer learning was used to migrate the network trained in the first localization unit to other localization units. Based on the premise that the general features of each location unit are similar, the parameters of the attention convolutional neural network trained in the first unit were maintained as unchanged, and only the final fully connected layer was updated. This can reduce the cost of the training network without changing the location accuracy.

Results and discussions A simulation environment of $10\text{ m} \times 10\text{ m} \times 3\text{ m}$ (Table 1) is divided into four positioning units. The proposed algorithm is simulated and compared with the convolutional neural network algorithm. The simulation results (Fig. 7–Fig. 10) indicate that the proposed algorithm can realize 3D positioning with an average error of 3.54 cm in a positioning unit of $5\text{ m} \times 5\text{ m} \times 3\text{ m}$. The average error of the CNN algorithm is 4.25. Furthermore, through the introduction of transfer learning, the proposed neural network model can be deployed more easily in other positioning units with an average error of 3.67 cm. Additionally, the training time of the neural network in the other positioning units is significantly shortened, which can effectively reduce the time and computing costs during network deployment. A $1.5\text{ m} \times 1.2\text{ m} \times 1.2\text{ m}$ positioning platform (Table 2) is built and divided into two positioning units for testing (Fig. 12). A comparison with the comparative algorithms shows that the algorithm proposed in this study can effectively reduce the impact due to the fluctuation of the received signal strength, with an average error of 3.32 cm and 90% of the errors are within 4.12 cm. When transfer learning is deployed to the second location unit, the average error is 3.35 cm, and the location performance does not deteriorate. Based on simulations and experiments, it is proven that the proposed algorithm exhibits excellent performance in terms of convergence speed and anti-jitter of the received signal.

Conclusions In this study, a convolutional neural network (CNN) algorithm based on an attention mechanism is proposed to realize three-dimensional indoor positioning. By preprocessing the received signal strength in the time domain and iterating the channel information using the attention mechanism, the algorithm effectively improves the positioning accuracy and fitting rate of the neural network and reduces the training cost of the neural network. To reduce the positioning accuracy after application to different positioning units, transfer learning is deployed to other positioning units. Compared with the convolutional neural network model, the proposed algorithm can effectively improve the positioning accuracy and fitting rate. Compared with the comparative algorithms, the proposed algorithm is not only more accurate, but can also maintain positioning accuracy when deployed to other positioning units. Simulation and experimental results show that the proposed algorithm can effectively reduce the influence of the received signal strength fluctuation on the positioning accuracy and improve the positioning accuracy.

Key words optical communications; visible light positioning; attention mechanism; convolutional neural network; transfer learning