

doi:10.13756/j.gtxyj.2026.240201.

光无线技术

姚瑶,朱亚丽,邵鑫玉. 基于Transformer模型的可见光通信室内定位[J]. 光通信研究, 2026(1): 240201.

Yao Y, Zhu Y L, Shao X Y. Indoor Positioning of Visible Light Communication based on Transformer Model [J]. Study on Optical Communications, 2026(1): 240201.

## 基于Transformer模型的可见光通信室内定位

姚瑶,朱亚丽,邵鑫玉

(江苏商贸职业学院 电子与信息学院, 江苏南通 226011)

**摘要:**【目的】可见光在室内进行了多径传播时,符号间干扰(ISI)导致基于接收信号强度的室内可见光定位精度不足。针对此问题,文章结合Transformer模型提出了一种新的基于接收信号强度的室内可见光定位系统。【方法】首先,文章推导了室内可见光接收信号强度的数学模型,分析了ISI和室内噪声对室内可见光通信系统的影响;然后,收集了各参考点的接收信号强度和真实坐标构建室内指纹数据库,文章所提神经网络模型在指纹数据库上进行端到端训练,学习从接收信号强度指纹到对应位置坐标的映射关系。【结果】仿真结果表明,文章所提定位系统的定位误差达到厘米级,在地面、0.5、1.0、1.5和2.0 m高度接收面的平均定位误差分别为0.73、0.94、1.13、1.92和2.97 cm,在室内不同高度的定位精度均优于其他基于接收信号强度的定位方法。此外,文章所提系统的平均定位时间为2.3 ms,虽然其速度不具备优势,但所提定位系统的定位精度更高,因此综合性能更具优势。【结论】Transformer模型提取了接收信号强度指纹内部各元素间的依赖性,而且提取了接收信号强度指纹间的依赖性,可挖掘出接收信号强度指纹结构中隐含的空间信息,从而提升了特征关于室内位置的判别性。因此,当接收面高度升至1.5和2.0 m时,文章所提定位系统的平均定位误差并未出现大幅提高的现象。经比较,文章所提系统的累积分布函数图显著好于对比方法。**关键词:**可见光多径传播;符号间干扰;室内定位;光强过滤;深度学习;位置检测

中图分类号:TP394.1;TH691.9 文献标志码:A

### Indoor Positioning of Visible Light Communication based on Transformer Model

YAO Yao, ZHU Yali, SHAO Xinyu

(School of Electronics and Information, Jiangsu Vocational College of Business, Nantong 226011, China)

**Abstract:** 【Objective】In the multipath propagation scenario of indoor visible light communication, Inter-Symbol Interference (ISI) leads to low precision of indoor visible light positioning due to low received signal strength. In view of this, a new received signal strength based indoor visible light positioning system combined with Transformer model is proposed. 【Methods】Firstly, the indoor visible light received signal strength is analyzed by mathematical derivation, and the impact of ISI and indoor noise on indoor visible light communication systems is analyzed. Then, the received signal strength and real coordinate of each reference point are collected to construct the indoor fingerprint database. The proposed neural network model is end-to-end trained on the fingerprint database, so as to learn the mapping relationship from the received signal strength fingerprint to the corresponding position coordinate. 【Results】Simulation results demonstrate that the positioning error of the proposed positioning system reaches the centimeter level, with average positioning errors of 0.73, 0.94, 1.13, 1.92 and 2.97 cm recorded for the receiving planes at ground level, 0.5, 1.0, 1.5 and 2.0 m, respectively. Compared with the other received signal strength based positioning methods, the indoor positioning precision of the proposed system is better at different heights. Besides, the average positioning time of the proposed system is 2.3 ms. 【Conclusion】The Transformer model extracts the dependency among the elements of every received signal strength fingerprint. It also extracts the dependency within the received signal strength fingerprints. The hidden spatial information within the received signal strength fingerprint structure is retrievable, effectively boosting the feature discriminability relevant to indoor locations. Hence, the average positioning error of the proposed system does not increase sharply even when the receiving plane height reaches 1.5 and 2.0 m. Moreover, the system's cumulative distribution function curve shows a clear advantage over those of the comparative approaches.

**Key words:** visible light multipath propagation; ISI; indoor positioning; light strength filtering; deep learning; location detection

## 0 引言

可见光在室内多径传播时,面临符号间干扰(Inter Symbol Interference, ISI)和环境噪声的问题<sup>[1]</sup>,这限制了基于接收信号强度(Received Signal

Strength, RSS)的室内可见光定位<sup>[2]</sup>性能。文献[3]提出了基于多源信息融合的径向基函数网络室内可见光定位算法;文献[4]采用发光二极管(Light Emitting Diode, LED)配光曲线档案训练人工神经网络,而非使用实际环境采集的光信号强度数据。

收稿日期:2024-09-13; 修回日期:2024-10-08; 纸质出版日期:2026-02-10

基金项目:南通市基础科学研究计划资助项目(JCZ2022087);南通市社会民生科技计划资助项目(MS2023062);南通市自然科学基金资助项目(指导性)(JCZ2023029)

作者简介:姚瑶(1990-),女,江苏南通人。实验师,硕士,主要研究方向为计算机应用和图形图像处理。

通信作者:姚瑶,实验师。E-mail: xiariniunai@163.com

© Editorial Office of *Study on Optical Communications*. This is an open access article under the CC BY-NC-ND license.


虽然此类方法<sup>[5-8]</sup>在一定程度上抑制了 ISI 和环境噪声对可见光定位性能的影响,但依然存在明显的不足之处:随着接收面的升高,系统定位精度会大幅下降。

当光接收器升至一定高度时,LED 发射角增大,光信号衰减明显。此时,非视距路径(Non Line Of Sight, NLOS)对视距路径(Line Of Sight, LOS)信号的干扰加剧,RSS 指纹的特征判别性降低,导致基于 RSS 的定位精度降低。Transformer 模型<sup>[9]</sup>提取的特征不仅包含词在句子中的上下文信息,而且包含词在整个文本中的上下文信息<sup>[10]</sup>。受此启发,本文结合 Transformer 模型提出了一种基于 RSS 的室内定位系统。本文所提定位系统利用 Transformer 模型处理序列数据的优势,不仅可提取 RSS 指纹内各元素(RSS 值)的依赖性,而且可提取指纹库中 RSS 指纹间的全局依赖性。因此 Transformer 模型可深入挖掘 RSS 指纹与室内位置间的高维映射关系,以此可提高基于 RSS 指纹的可见光定位精度。

## 1 室内可见光定位原理

### 1.1 室内可见光定位模型

室内可见光定位模型采用 LED 作为光源,采用光电二极管(Photo Diode, PD)作为光接收器,根据 PD 接收的光信号强度来估计接收器的位置坐标,如图 1 所示。室内可见光传播包含 LOS 和墙面反射产生的 NLOS,由此产生的 ISI 在室内不同位置存在显著的差异,这会对室内可见光定位系统产生不利影响。



注:( $x, y$ )为 PD 位置坐标。

图 1 室内可见光定位模型

Figure 1 The positioning model of indoor visible light

### 1.2 室内可见光信道模型

假设 LED 发射光服从 Lambert 传播模式,根据接收信号的功率可得直流信道增益  $H(0)$  可表示为

$$H(0) = \begin{cases} 0, \psi > \Psi_c \\ \frac{(m+1)A}{2\pi d_0^2} \cos^m(\phi) T_s(\psi) g(\psi) \times, & (1) \\ \cos(\psi), 0 \leq \psi \leq \Psi_c \end{cases}$$

式中: $\psi$  为入射角; $\Psi_c$  为 PD 视场角; $A$  为 PD 检测面积; $m$  为 Lambert 发光阶数; $d_0$  为接收器和发射器间距离; $\phi$  为发射角; $T_s(\psi)$  为光滤波器增益; $g(\psi)$  为聚光透镜增益。

可见光信道增益  $h$  可分解为 LOS 和 NLOS 信道增益  $h_{\text{LOS}}$  和  $h_{\text{NLOS}}$ , 可表示为

$$h = h_{\text{LOS}} + h_{\text{NLOS}} \quad (2)$$

$h_{\text{LOS}}$  可表示为

$$h_{\text{LOS}} = \frac{(m+1)A \cos^m(\phi) T_s(\psi) g(\psi) \cos(\psi)}{2\pi d_0^2} \quad (3)$$

$h_{\text{NLOS}}$  可表示为

$$h_{\text{NLOS}} = h_{\text{LOS}} \delta\left(S_{\text{NLOS}} - \frac{d_0}{c}\right) + \int h_{\text{LOS}} \cdot \delta\left(S_{\text{NLOS}} - \frac{d_{\text{NLOS}}}{c}\right) dS_{\text{NLOS}} \quad (4)$$

式中: $\delta(\cdot)$  为冲激函数; $c$  为光速; $S_{\text{NLOS}}$  为 NLOS 路径经过的反射次数; $d_{\text{NLOS}}$  为光源到光接收器的链路总距离。考虑 3 次反射后的反射响应已小于 LOS 链路响应的 1%, 因此将 NLOS 链路的最大反射次数设为 3。

可见光信噪比  $\text{SINR}$  可表示为

$$\text{SINR} = \frac{(\gamma \cdot h \cdot P_s)^2}{\sigma_{\text{shot}}^2 + \sigma_{\text{thermal}}^2 + (\gamma \cdot P_{\text{ISI}})^2} \quad (5)$$

式中: $\gamma$  为光探测器的光/电转换率; $P_s$  为 LED 发射的光强度; $\sigma_{\text{shot}}^2$  和  $\sigma_{\text{thermal}}^2$  分别为散粒噪声和热噪声,这两个噪声的计算可参考文献[11]; $P_{\text{ISI}}$  为接收光 ISI 功率。观察式(5)可知,多径传播和室内噪声导致可见光信号发生高维非线性失真,这为建立从 RSS 指纹到室内位置的映射关系带来了极大的困难。

## 2 可见光定位系统

### 2.1 基于 RSS 的可见光定位系统

假设 RSS 指纹的结构中隐含与位置有关的特征信息,基于 RSS 的室内可见光定位系统首先要建立从 RSS 指纹到位置的映射关系,然后根据 RSS 指纹估计其位置。然而,由式(5)可知,可见光多径传播导致 RSS 指纹到位置的映射关系包含高维于

扰信息,导致定位性能不足。

Transformer 模型的自注意力机制具有训练效率高、捕捉长期依赖性强和全面建模上下文的优点,具有很强的抗噪声和抗干扰能力。因此,本文利用 Transformer 模型学习从 RSS 指纹到位置的映射关系,在提取每个 RSS 特征时考虑序列的全部上下文和全局依赖性,以减少噪声和 ISI 对定位性能的影响。

图 2 所示为基于 RSS 的可见光定位流程图。首先,对采集的 RSS 指纹库进行标记嵌入处理,对序列中各元素的位置进行标记;然后,Transformer 回归网络(TrReNet)使用 Transformer 模型提取 RSS 指纹结构与位置有关的特征信息,并将信息传入回归器预测 RSS 指纹所对应的位置坐标 $(x, y)$ 。

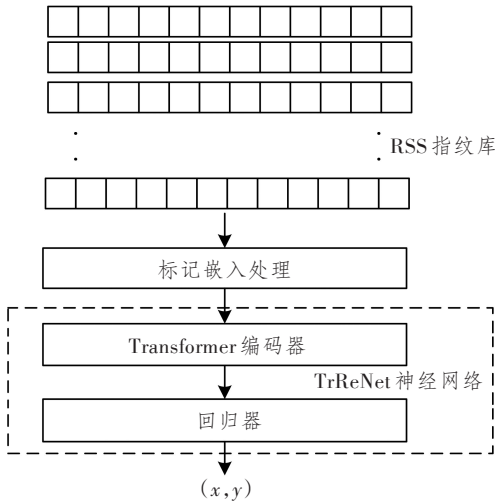


图 2 基于 RSS 的可见光定位流程图

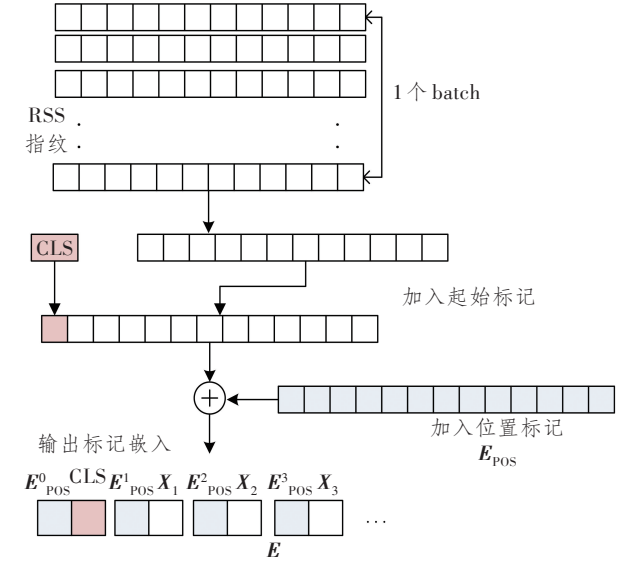
Figure 2 The diagram of RSS based visible light positioning

## 2.2 标记嵌入处理

本文采用基于 Transformer 的双向编码器表示(Bidirectional Encoder Representations from Transformers, BERT)作为 Transformer 模型,该模型能从前两个方向挖掘 RSS 指纹的上下文语义信息。将一维 RSS 指纹设为  $X=[x_1, x_2, \dots, x_N] \in \mathbb{R}^{1 \times N}$ , 式中,  $N$  为室内安装的 LED 数;  $x_i$  为来自第  $i$  个 LED 的 RSS 值。为满足 Transformer 模型的输入格式要求,需对  $X$  进行标记嵌入处理,将  $X$  转换成标记嵌入表示  $E=[e_0, e_1, \dots, e_N]$ ,  $e_i$  为第  $i$  个标记的嵌入向量。 $E$  中包含可学习的位置标记  $E_{\text{POS}}$ ,可提高 RSS 指纹的空间感知能力,  $E_{\text{POS}}$  为 Transformer 模型的可学习位置嵌入向量。

图 3 所示为  $X$  被转换成  $E$  的过程。首先,将  $X$  与“[CLS]”标记拼接成  $1 \times (N+1)$  的序列  $X'$ , “[CLS]”为序列起始标记;然后,将可学习位置嵌入

$E_{\text{POS}}$  与  $X'$  进行元素级拼接处理,将  $E$  输入 Transformer 编码器进行特征提取。



注: batch 为神经网络训练的一个批次;  $E_{\text{POS}}$  的上标为位置嵌入序列中位置的索引。

图 3 RSS 指纹的标记嵌入处理

Figure 3 The tag embedding process of RSS fingerprints

将 RSS 指纹转换成标记嵌入表示的过程,可表示为

$$E = \text{Concat}(E_{\text{CLS}}, X) + E_{\text{POS}}, \quad (6)$$

式中:  $\text{Concat}()$  为向量拼接操作;  $E_{\text{CLS}}$  为 Transformer 模型的“[CLS]”标记。

## 3 TrReNet 设计

TrReNet 由 Transformer 模型和回归器构成, Transformer 负责从 RSS 指纹提取位置相关的特征信息,回归器负责从特征信息预测对应的坐标值。

### 3.1 Transformer 模型

#### 3.1.1 注意力模块

自注意力机制是 Transformer 模型的核心,他允许模型对每个元素编码时,不仅关注当前元素,而且关注序列的其他元素。自注意力模块的输入为标记嵌入表示或上一个编码块输出向量。基于矩阵  $X$  创建 3 个新矩阵:查询矩阵  $Q$ 、键矩阵  $K$  和值矩阵  $V$ 。可对输入的标记嵌入向量分别乘以 3 个可学习矩阵来得到  $Q$ 、 $K$  和  $V$  向量。图 4 所示为自注意力机制的运算流程。 $Q$  的转置乘以  $K$  得到的矩阵表示 RSS 之间的注意力强度,  $\text{Softmax}()$  函数  $\text{Softmax}()$  将注意力强度归一化为注意力权重。

自注意力的数学形式可表示为

$$A(Q, K, V) = \text{Softmax}\left(\frac{Q^T K}{\sqrt{d}}\right)V, \quad (7)$$




图4 自注意力机制流程图

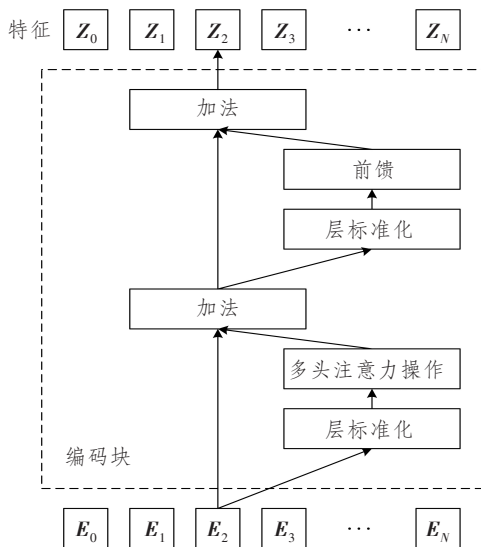
Figure 4 The diagram of self-attention mechanism

式中;  $A$  为注意力的等效函数;  $Q, K$  和  $V$  均为  $(N+1) \times d$  个矩阵;  $d$  为  $Q, K$  和  $V$  的列数。

多头自注意力机制由多个自注意力头并行构成, 每个自注意力头关注不同特征, 由此提高模型表达能力和并行运算能力。假设并行自注意力头输出的注意力向量为  $h_1, h_2, \dots, h_H$ , 其中  $H$  为自注意力头数量。综上所述, 每个多头自注意力模块  $A_{total}(Q, K, V)$  包含的可学习权重参数为  $(W_1^Q, W_1^K, W_1^V), (W_2^Q, W_2^K, W_2^V), \dots, (W_H^Q, W_H^K, W_H^V)$  和  $W^O$ , 通过神经网络训练来确定这些权重值。

### 3.1.2 Transformer 编码器

Transformer 编码器由若干个编码块级联而成。Pre-LN 与 Post-LN 是两种常见的编码块结构, Post-LN 参数梯度随着深度的增加以指数形式变大, 而 Pre-LN 参数梯度随深度的变化较小, 因此 Pre-LN 抗梯度消失能力强, 训练稳定性高。本文中 Transformer 编码器采用 Pre-LN 型结构, 图 5 所示为 Pre-LN 型编码块结构图。Pre-LN 型编码器



注:  $E_N$  为输入编码器的第  $N$  个元素;  $Z_N$  为编码器输出的第  $N$  个元素。

图5 Pre-LN 型编码器结构

Figure 5 The structure of Pre-LN type encoder

的输入首先进行层归一化操作, 再传递到注意力层或前馈层进行处理。

### 3.2 回归器设计

图 6 所示为回归器的网络结构图。Transformer 模型输出序列设为  $Z$ , 第一个元素  $Z_0$  是包含全局信息和局部信息的特征。将  $Z_0$  传入回归器, 回归器由两个全连接层和 1 个输出层构成, 全连接层的神经元数量等于  $Z_0$  的维度, 输出层的神经元数量为 2, 分别对应  $x$  坐标和  $y$  坐标。




图6 回归器的网络结构

Figure 6 The network structure of regression

### 3.3 神经网络训练

#### 3.3.1 训练数据采集

在室内各参考点采集 RSS 指纹, 将所有参考点的位置坐标和 RSS 样本保存于指纹库。指纹库矩阵  $Ref$  可表示为

$$Ref = \begin{bmatrix} RSS_{(1,1)} & RSS_{(1,2)} & \dots & RSS_{(1,N)} \\ RSS_{(2,1)} & RSS_{(2,2)} & \dots & RSS_{(2,N)} \\ \vdots & \vdots & \ddots & \vdots \\ RSS_{(U,1)} & RSS_{(U,2)} & \dots & RSS_{(U,N)} \end{bmatrix} \begin{bmatrix} x_1, y_1 \\ x_2, y_2 \\ \vdots \\ x_U, y_U \end{bmatrix}, \quad (8)$$

式中:  $(x_u, y_u)$  为第  $u$  个参考点的实际坐标;  $RSS_{(u,n)}$  为第  $u$  个参考点测量第  $n$  个 LED 的 RSS 值;  $U$  为参考点总数。

#### 3.3.2 神经网络训练

将各参考点的 RSS 指纹矩阵的第  $v$  行  $RSS_v$  作为神经网络 TrReNet 的输入, 参考点的实际坐标  $(x_v, y_v)$  作为输出, 对 TrReNet 进行端到端训练。采用均方误差 (Mean Squared Error, MSE) 评估估计坐标与真实坐标的偏差。TrReNet 的损失函数可定义为

$$\ell_{MSE} = \frac{1}{U} \sum_{u=1}^U [(x_u - x'_u)^2 + (y_u - y'_u)^2], \quad (9)$$

式中,  $(x'_u, y'_u)$  为第  $u$  个参考点的估计坐标。

图 7 所示为室内定位系统训练与测试的流程。两个阶段的处理过程分别如下:

①离线训练阶段:对训练集的 RSS 指纹进行标记嵌入处理,基于 MSE 损失函数对 TrReNet 进行端到端训练,得到优化的 Transformer 模型参数集  $\Theta_{Tr}$  和回归器参数集  $\Theta_{Re}$ 。

②在线预测阶段:基于参数集  $\Theta_{Tr}$  和  $\Theta_{Re}$  分别建立 Transformer 模型和回归器,估计每个测试 RSS 指纹的坐标,统计测试集的定位误差。

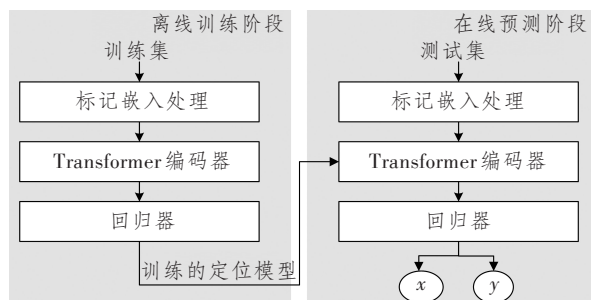


图 7 室内定位系统训练与测试流程

Figure 7 The training and test diagram of indoor positioning system

## 4 仿真结果

### 4.1 仿真建立

采用 Matlab 软件建模和仿真室内可见光定位系统。室内尺寸为  $6\text{ m} \times 6\text{ m} \times 3\text{ m}$ ,天花板设立 6 个 LED 吸顶灯,坐标分别为  $(2,2,3)$ 、 $(2,3,3)$ 、 $(2,4,3)$ 、 $(4,2,3)$ 、 $(4,3,3)$  和  $(4,4,3)$ 。设立 5 个接收面分别进行仿真,高度分别为 0、0.5、1.0、1.5 和 2.0 m。参考点的分辨率为 0.3 m,即每个接收面的参考点数为  $21 \times 21$ 。将每个参考点采集的 RSS 与坐标存入指纹库作为训练集,格式如式(8)所示。每个接收面另外选择  $6 \times 6$  个点作为测试点,测试点采集的 RSS 指纹和坐标组成测试集。仿真参数如表 1 所示。

表 1 室内可见光定位系统仿真参数

Table 1 Simulation parameters of indoor visible light positioning system

参数	值
LED 光功率/W	6
朗伯发光强度阶数	1
LED 视场角/ $^\circ$	90
LED 半功率角/ $^\circ$	60
PD 有效面积/ $\text{cm}^2$	1
PD 光/电转换率	0.7
光学滤波器增益	1
聚光器增益	1
数据传输速率/Gbit/s	1
墙面反射率	0.7
天花板反射率	0.7
地面反射率	0.3

采用软件 Keras-2.10.0 和 Tensorflow 2.10.0 搭建神经网络模型,编程环境为 Python 3.9.13。显卡采用 NVIDIA GeForce GTX 1660 Ti。使用 Adam 优化器训练 TrReNet,学习率为  $1\text{E}-4$ ,batch 尺寸为 32,epoch 数为 100。在每个接收面的训练集上训练所提模型,训练所得的参数为  $\Theta_{Tr}$  和  $\Theta_{Re}$ ,所得模型在对应的测试集上进行测试和评估。

### 4.2 参数分析

Transformer 的编码块数是影响 Transformer 性能的关键参数,因此在测试集上统计了不同编码块数的平均定位误差。图 8 所示为不同编码块数对应的平均定位误差。由图可知,当编码块数从 1 增加至 3 时,神经网络提取 RSS 指纹内元素间依赖性能力逐渐增强,且提取 RSS 指纹间依赖性的能力也逐渐增强,因此各接收面的平均定位误差均呈现下降趋势。编码块数增加到一定数量时,Pre-LN 结构编码器易出现信息崩溃现象,此时 Transformer 模型的特征提取能力降低。图中显示,当编码块数等于 4 时,Transformer 模型的特征提取能力开始下滑,因此将 Transformer 模型的编码块数设为 3。




图 8 不同 Transformer 模型编码块数的定位性能

Figure 8 The positioning performances of different Transformer model encoder blocks

### 4.3 定位性能

表 2 所示为各接收面的平均定位误差和最大定位误差。由表可知,在地面和 0.5 m 高度上,所提定位系统的平均定位误差均在 1 cm 以下。当接收面升至一定高度时,LED 发射角增大,光信号衰减明显。此时,NLOS 信号对 LOS 信号的干扰加剧,导致 RSS 指纹的特征判别性降低。Transformer 模型提取了 RSS 指纹内部各元素间的依赖性,而且提取了 RSS 指纹间的依赖性,可挖掘出 RSS 指纹结构中隐含的空间信息,从而提升了特征关于室内位置的判别性。因此,当接收面高度升至 1.5 和 2.0 m 时,本文所提定位系统的平均定位误差并未出现大

幅提高的现象。

表2 各接收面的定位误差

接收面高度/m	平均定位误差/cm	最大定位误差/cm
0	0.73	2.65
0.5	0.94	3.12
1.0	1.13	3.67
1.5	1.92	5.91
2.0	2.97	7.68

#### 4.4 对比分析

本文所提定位系统属于基于RSS的室内可见光定位方法,因此选择3种基于RSS的室内可见光定位方法作为对比方法,即人工神经网络(Artificial Neural Network, ANN)<sup>[4]</sup>、预处理卷积神经网络(Pre-Processing and Convolutional Neural Network, PPCNN)<sup>[10]</sup>和长短期记忆(Long Short Term Memory, LSTM)<sup>[11]</sup>网络。ANN、PPCNN和LSTM分别采用多层感知机、卷积神经网络和长短期记忆网络建立RSS指纹与室内位置的多维映射关系,这3种方法与本文所提系统均使用RSS指纹作为特征源,且不包含其他辅助信息。

表3所示为各定位在不同接收面的平均定位误差。由表所示,PPCNN、ANN和LSTM在地面上的定位误差均较小,但随着接收面升高,PPCNN、ANN和LSTM的定位误差大幅升高。当接收面升至一定高度时,LED发射角增大,光信号衰减明显。此时,NLOS信号对LOS信号的干扰加剧,导致RSS指纹的特征判别性降低。当高度为2.0 m时,PPCNN、ANN和LSTM提取RSS指纹的能力降低,其平均定位误差分别达到7.08、9.03和8.81 cm。本文所提模型在2.0 m高度时依然可挖掘出RSS指纹结构中隐含的空间信息,提升了特征关于室内位置的判别性。本文所提模型在2.0 m高度的平均定位误差为2.97 cm,明显优于其他3种模型。

表3 不同接收面的平均定位误差

高度/m	PPCNN/cm	ANN/cm	LSTM/cm	TrReNet/cm
0	1.23	1.820	1.47	0.73
0.5	1.38	2.120	1.71	0.94
1.0	1.89	2.925	2.59	1.13
1.5	4.23	7.04	5.22	1.92
2.0	7.08	9.03	8.81	2.97

图9所示为4种定位方法在2 m高度接收面

的累积分布函数(Cumulative Distribution Function, CDF)曲线。如图所示,ANN在高接收面的定位性能较弱,PPCNN和LSTM的CDF曲线较ANN明显左移,可见这两种神经网络从RSS指纹提取的位置特征判别力更强,因此这两种方法在2.0 m高度接收面的定位性能优于ANN。TrReNet利用Transformer模型提取了RSS指纹内部各元素间的依赖性,而且提取了RSS指纹间的依赖性,可挖掘出RSS指纹结构中隐含的空间信息。经比较,TrReNet的CDF曲线显著优于3种对比方法。

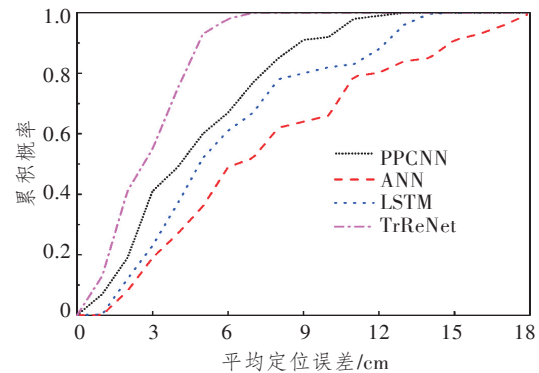


图9 接收器在2 m高度的累积分布函数

Figure 9 The CDF of receiver at 2 m height

表4所示为每个RSS样本的平均定位时间。由表可知,ANN的定位速度最快,仅需1.2 ms;PPCNN包含较多的卷积运算,其定位速度最慢;TrReNet的平均定位时间为2.3 ms,虽然其速度不具备优势,但本文所提定位系统的定位精度更高,因此综合性能更具优势。

表4 平均定位时间

定位方法	定位时间/ms
PPCNN	6.9
ANN	1.2
LSTM	1.7
TrReNet	2.3

## 5 结束语

为了提高多径传播下室内可见光定位系统的性能,本文结合Transformer模型提出了一种新的基于RSS的室内可见光定位系统。本文所提定位系统采用Transformer模型提取RSS各元素的全局依赖性,深入挖掘RSS指纹与室内位置间的多维映射关系,以提高定位系统的精度。虽然在高接收面上NLOS信号对LOS信号的干扰较大,导致RSS指纹的特征判别性降低,但本文所提系统依然取得

了较高的定位性能。

#### 参考文献:

- [1] 邢莉娟, 李卓, 王卓. 自由空间光通信中极化码的应用研究[J]. 光通信研究, 2024(3): 230058.  
Xing L J, Li Z, Wang Z. Research on Application of Polar Codes in Free Space Optical Communication[J]. Study on Optical Communications, 2024(3): 230058.
- [2] 张慧颖, 王凯, 于海越, 等. 基于自适应Levy飞行的黄金正弦可见光定位研究[J]. 激光技术, 2022, 46(4): 519.  
Zhang H Y, Wang K, Yu H Y, et al. Research on Golden Sine Visible Light Positioning based on Adaptive Levy Flight[J]. Laser Technology, 2022, 46(4): 519.
- [3] 张慧颖, 梁誉, 卢宇希, 等. 稀疏训练指纹库融合MMPSO-ELM室内可见光定位[J]. 激光技术, 2022, 46(6): 788-795.  
Zhang H Y, Liang Y, Lu Y X, et al. Indoor Visible Light Positioning Using MMPSO - ELM Neural Network based on Sparse Training Fingerprint Database[J]. Laser Technology, 2022, 46(6): 788-795.
- [4] do Nascimento M R F, Coutinho O G G, Olivi L R, et al. A Visible Light Positioning Technique based on Artificial Neural Network[J]. Journal of Control, Automation and Electrical Systems, 2024, 35 (4) : 677-687.
- [5] 赵霞, 张君毅, 龙倩倩. 基于Circle混沌映射的ISSA-ELM神经网络室内可见光定位方法[J]. 光学学报, 2023, 43(2): 0206004.  
Zhao X, Zhang J Y, Long Q Q. Indoor Visible Light Positioning Method Using ISSA -ELM Neural Network based on Circle Chaotic Mapping[J]. Acta Optica Sinica, 2023, 43(2): 0206004.
- [6] 王童瑶, 肖纯贤, 林作俊, 等. 基于标记LED的单灯室内定位系统设计[J]. 光通信研究, 2022(5): 38-42.  
Wang T Y, Xiao C X, Lin Z J, et al. The Design of Single LED Indoor Positioning System based on Marked LED[J]. Study on Optical Communications, 2022(5): 38-42.
- [7] 秦岭, 刘哲, 王凤英, 等. 基于BPNN-MLR的室内可见光定位算法[J]. 光通信研究, 2022(2): 7-11.  
Qin L, Liu Z, Wang F Y, et al. Indoor Visible Light Positioning Algorithm based on BPNN - MLR [J]. Study on Optical Communications, 2022(2): 7-11.
- [8] Komine T, Nakagawa M. Fundamental Analysis for Visible - Light Communication System Using LED Lights[J]. IEEE Transactions on Consumer Electronics, 2004, 50(1): 100-107.
- [9] 刘军, 王慧民, 张兴忠, 等. 基于Transformer的端到端路面裂缝检测方法[J]. 太原理工大学学报, 2022, 53(6): 1143-1151.  
Liu J, Wang H M, Zhang X Z, et al. End - to - End Pavement Crack Detection Method based on Transformer[J]. Journal of Taiyuan University of Technology, 2022, 53(6): 1143-1151.
- [10] Hsu L S, Tsai D C, Chen H M, et al. Using Received-Signal - Strength (RSS) Pre - Processing and Convolutional Neural Network (CNN) to Enhance Position Accuracy in Visible Light Positioning (VLP) [C]//2022 Optical Fiber Communications Conference and Exhibition (OFC). San Diego, CA, USA: IEEE, 2022: 9748179.
- [11] Chen H, Han W, Wang J, et al. High Accuracy Indoor Visible Light Positioning Using a Long Short Term Memory - Fully Connected Network based Algorithm[J]. Optics Express, 2021, 29(25): 41109-41120.