

基于宽度学习系统的可见光室内位置感知方法

张峰 张定定 孟祥艳 彭侠

Visible light indoor position perception method based on broad learning system

ZHANG Feng, ZHANG Dingding, MENG Xiangyan, PENG Xia

引用本文:

张峰, 张定定, 孟祥艳, 等. 基于宽度学习系统的可见光室内位置感知方法[J]. 应用光学, 2025, 46(5): 1126–1134. DOI: 10.5768/JAO202546.0508001

ZHANG Feng, ZHANG Dingding, MENG Xiangyan, et al. Visible light indoor position perception method based on broad learning system[J]. Journal of Applied Optics, 2025, 46(5): 1126–1134. DOI: 10.5768/JAO202546.0508001

在线阅读 View online: <https://doi.org/10.5768/JAO202546.0508001>

您可能感兴趣的其他文章

Articles you may be interested in

K-means+SSA-Elman网络可见光室内位置感知算法

K-means+SSA-Elman network visible light indoor location awareness algorithm

应用光学. 2022, 43(3): 453–459 <https://doi.org/10.5768/JAO202243.0302005>

自适应功率分配可见光MIMO信道容量研究

Research on MIMO channel capacity for adaptive power allocation visible light

应用光学. 2020, 41(3): 626–630 <https://doi.org/10.5768/JAO202041.0308002>

分区域BES-ELM融合WDME加权双模的室内可见光定位

Indoor visible light positioning based on fusion of subregion BES-ELM and WDME weighted dual-mode

应用光学. 2024, 45(6): 1321–1330 <https://doi.org/10.5768/JAO202445.0608002>

信道复用技术在LED水下可见光通信中的应用

Application of channel multiplexing technology in LED underwater visible light communication

应用光学. 2023, 44(5): 1133–1141 <https://doi.org/10.5768/JAO202344.0508002>

基于红外和可见光图像逐级自适应融合的场景深度估计

Depth estimation based on adaptive fusion of infrared and visible light images progressively

应用光学. 2020, 41(1): 24–32 <https://doi.org/10.5768/JAO202041.0101004>

基于多变量纳米线栅复合结构的可见光偏振调控

Polarization control of visible light based on composited multivariable nanowire gratings structure

应用光学. 2024, 45(4): 700–708 <https://doi.org/10.5768/JAO202445.0401005>



关注微信公众号，获得更多资讯信息

文章编号: 1002-2082 (2025) 05-1126-09

引用格式: 张峰, 张定定, 孟祥艳, 等. 基于宽度学习系统的可见光室内位置感知方法[J]. 应用光学, 2025, 46(5): 1126-1134.

ZHANG Feng, ZHANG Dingding, MENG Xiangyan, et al. Visible light indoor position perception method based on broad learning system[J]. Journal of Applied Optics, 2025, 46(5): 1126-1134.



在线阅读

基于宽度学习系统的可见光室内位置感知方法

张峰¹, 张定定¹, 孟祥艳¹, 彭侠²

(1. 西安工业大学电子信息工程学院, 陕西 西安 710021; 2. 西安应用光学研究所, 陕西 西安 710065)

摘要: 针对深度学习在可见光室内位置感知中进行训练与位置预测时网络结构复杂、涉及大量超参数且易产生梯度爆炸, 从而导致定位时效性较差和精度不稳定的问题, 提出一种基于宽度学习的可见光室内位置感知方法。首先将室内可见光环境采集到的光辐射信息作为网络的特征节点, 构建基于宽度学习系统的可见光室内位置感知预测模型, 然后对网络特征节点进行宽度扩展, 最后求解伪逆矩阵, 对网络模型进行训练与测试。在 4 m×4 m×3 m 的室内实验场景下, 本文算法平均定位误差为 11.63 cm, 预测误差小于 10 cm, 其累积概率为 52%, 预测误差小于 20 cm, 其累积概率为 97%, 宽度学习网络定位速度相比于 BP(back propagation) 神经网络与 RBF(radial basis function) 神经网络分别提高了 55.1% 和 39.9%。本文方法提高了可见光室内位置感知的精度与速度, 为室内位置感知提供了一种稳定可靠的方法。

关键词: 宽度学习; 可见光通信; 室内位置感知; 神经网络

中图分类号: TN929.1

文献标志码: A

DOI: 10.5768/JAO202546.0508001

Visible light indoor position perception method based on broad learning system

ZHANG Feng¹, ZHANG Dingding¹, MENG Xiangyan¹, PENG Xia²

(1. School of Electronic Information Engineering, Xi'an Technological University, Xi'an 710021, China; 2. Xi'an Institute of Applied Optics, Xi'an 710065, China)

Abstract: To address the challenges of complex network architectures, a large number of hyperparameters, and gradient explosion encountered during deep learning training and position prediction in visible light indoor positioning, which can cause the problem of poor positioning timeliness and unstable accuracy, this paper introduces a broad-learning approach for visible light indoor position perception. First, the light radiation data acquired from the indoor visible light environment was utilized as the feature node for the network. Subsequently, a prediction model for visible light indoor positioning based on the broad learning system was established. Next, the dimensionality of the network feature nodes was expanded. Finally, the pseudo-inverse matrix was computed to train and evaluate the network model. In the laboratory experiment conducted in a 4 m×4 m×3 m environment, the proposed algorithm demonstrated an average positioning error of 11.63 cm. The cumulative probability of prediction errors less than 10 cm was 52%, and that for errors less than 20 cm was 97%. Compared to BP(back propagation) and RBF(radial basis function) neural networks, the width learning network exhibited a 55.1% and 39.9% increase in positioning speed, respectively. The method in this

收稿日期: 2024-06-13; 修回日期: 2024-12-26

基金项目: 国家自然科学基金 (12004292); 陕西省重点研发计划 (2024GX-YBXM-105); 陕西省科技厅一般项目 (2021GY-107); 西安市科技计划项目 (2020KJRC0040); 西安工业大学优秀硕士学位论文培育基金 (YS202210)

第一作者: 张峰, E-mail: zf_zx963@163.com

通信作者: 张定定, E-mail: 1044454079@qq.com

paper improves the accuracy and speed of visible light indoor position perception, and provides a stable and reliable method for indoor position perception.

Key words: broad learning; visible light communication; indoor location perception; neural network

引言

室内位置感知技术发展迅速,并在众多领域中取得广泛应用^[1]。现行的室内定位技术基于 WiFi 信号、蓝牙、超宽带等方法进行室内定位,但这些方法技术繁琐、耗能较高,且传输过程中易受到电磁干扰和多径衰落的影响,从而导致定位精度的下降^[2-3]。

可见光室内位置感知将照明与通信相结合,频谱资源丰富且不受电磁干扰,因此可见光室内位置感知技术也越来越受关注^[4]。常见的可见光室内位置感知通常利用光电探测器和图像传感器实现室内位置感知的功能^[5-6]。文献[7]提出建立多边协作位置感知机制实现定位,该机制为用户在实际可见光室内环境位置动态变化的场景以及 LED 信号受到干扰等问题提供了一种解决思路。文献[8]设计了一种卷积递归神经网络(convolutional recurrent neural network, CRNN)模型,提出利用基于 CRNN 的四维可见光室内定位架构处理室内可见光的非视线传播和不同的接收器方向问题,该方法实现了厘米级的定位精度,但模型复杂度高,堆叠较多算法,适用性较低。文献[9]在可见光室内定位坐标预测时采用天牛须搜索算法来优化深度学习神经网络,仿照自然生物特性优化神经网络训练,有效提高了训练速度。文献[10]提出利用决策树、支持向量机和神经网络与 LED 接收信号强度相结合的定位方法,在构建真实的室内场景中定位测试,结果表明所提方法有效降低了定位误差。

目前深度学习网络已应用到多个领域研究中,反向传播神经网络(back propagation neural network, BP 神经网络)通过误差反向传播来调整神经网络中的权重,使网络逐步学习并优化。径向基函数神经网络(radial basis function neural network, RBF 神经网络)是基于径向基函数作为激活函数的前馈型神经网络。深度学习是通过增加网络内部层数来提升分析复杂非线性问题的能力,然而会因结构复杂和冗余的超参数导致学习过程消耗过多资源^[11]。针对以上问题,论文提出了宽度学习系统(broad learning system, BLS)网络模型,文献[12]提出对 BLS 的参数进行改进,提升了混合气体浓

度的预测水平,展现了其方法优异的预测结果。文献[13]分别提出了递归型宽度学习网络和门控宽度学习网络,并将这两种网络用于文本等序列任务,结果表明其效率较其他方法有所提升。基于此,本文搭建了基于宽度学习的可见光室内位置感知系统,在宽度学习系统中不需要堆叠网络层数,面对可见光数据集时可以通过增量学习算法来优化网络系统,其算法复杂度低、训练速度快,解决了传统神经网络数据量和数据维度过大带来的问题,省去了反复训练求解或调参的过程。将宽度学习系统应用到可见光室内位置感知能有效提高定位性能,提高室内位置感知的速度,为室内位置感知提供了一种稳定可靠的解决方案。

1 可见光室内位置感知模型

1.1 可见光室内位置感知系统模型

论文提出了可见光室内位置感知系统,其框架如图 1 所示。根据光照补偿的原理,在室内空间顶部布置 m 个发光二极管(LED)光源。其中第 m 个 LED 光源坐标为

$$L_m = (x_m, y_m, z_m) \quad (1)$$

为了实现室内定位,需要对部署在不同高度和位置的 LED 光源信号进行解析,以获取光辐射数据和标定信息,从而建立起初始的训练数据集。

1.2 可见光室内位置感知中的信号辐射模型

将定位区域划分为等大小的网格,在室内不同高度平面上,将光源位置信息通过 LED 驱动电路转换为光信号,然后由光电探测器采集可见光辐射信息。光信号在传播过程中遇到障碍物会产生漫反射导致多径效应,从而影响定位精度。由于高阶反射链路对系统的影响较小,因此在建模过程中只需考虑直射和一阶反射链路所引起的信道增益^[14],光信道一阶反射的直流增益 H_{REF}^1 表达式为

$$H_{\text{REF}}^1 = \frac{m_1 + 1}{2\pi d_1 d_2^2} \cdot dS_f \cdot A \cdot \rho \cdot T_s \cdot \cos \alpha \cdot \cos \beta \cdot \cos^{m_1}(\theta) \cdot \cos^{m_2}(\varphi) \quad (2)$$

式中: m_1 、 m_2 分别表示发射端与接收端的朗伯发光阶数; d_1 、 d_2 为 LED 到反射点和反射点到接收机




图1 可见光室内位置感知系统框架图

Fig. 1 Framework diagram of visible light indoor position perception system

之间的距离; dS_i 为反射体的面积微元; A 为光电检测器的有效面积; ρ 为反射体材料系数; T_s 为光滤波器的增益; α 、 β 为反射光信号的入射角与出射角; θ 为相对于 LED 垂直轴的发射角; φ 为相对于接收轴的入射角。根据光电二极管特性, 解调后电流与接收到的光功率成正比, LED 的光辐射功率与接收端 PD 收到电功率的关系为

$$P_r = \{RP_i[H(0) + H(0)_{\text{REF}}]\}^2 + \sigma_{\text{noise}}^2 \quad (3)$$

式中: R 为接收端 PD 的响应度; P_i 为单个 LED 的光辐射功率; $H(0)$ 为光信道的直流增益; σ_{noise}^2 为总噪声方差。将采集的可见光辐射信息作为宽度学习网络的训练集输入到宽度学习网络中进行训练, 最终将数据输入训练好的网络模型中获得相应的位置信息。

2 基于宽度学习的可见光室内位置感知优化

2.1 宽度学习系统原理

BLS 算法^[12] 将输入样本映射至合适的特征空间, 处理高维度和时变数据, 保留了随机生成隐藏层节点权重的机制, 隐藏层至输出层权重仅需伪逆算法计算, 当输入节点不足而导致精度较差时, BLS 可以在不堆叠深层结构的情况下, 对网络的特征节点进行扩展。这是一种新型平面神经网络, 具有学习速度快、参数设置简单的特点, 适用于不同应用领域, 能有效解决高维大规模数据挑战以及深度学习的结构复杂、参数众多等问题。因此宽度学习非常适合中小样本环境下的建模和学习。宽度学习系统基本的结构如图 2 所示。




图2 宽度学习系统网络结构图

Fig. 2 Network architecture diagram of BLS

对输入数据 X 进行特征映射, 得到 n 组映射特征, 公式如式(4):

$$Z_i = \phi(XW_{e_i} + \beta_{e_i}), i = 1, 2, \dots, a \quad (4)$$

式中: W_{e_i} 为随机生成的连接权值系数; β_{e_i} 为随机生成的偏置; ϕ 为一个线性变换。则 $Z^a = [Z_1, Z_2, \dots, Z_a]$ 为前 a 组映射组合形成的特征节点, 再将特征节点增强为随机生成权重的增强节点, 公式如式(5):

$$E_j = \xi(Z^a W_{h_j} + \beta_{h_j}), j = 1, 2, \dots, b \quad (5)$$

式中: W_{h_j} 和 β_{h_j} 分别为权重和偏置; ξ 为非线性激活函数。则 $E^b = [E_1, E_2, \dots, E_b]$ 为 b 组增强节点, 将特征节点转换共生成 $\eta_2 \times b$ 个增强节点, 最终得到宽度学习模型如式(6)所示:

$$Y = [Z_1, \dots, Z_a | \xi(Z^a W_{h_1} + \beta_{h_1}), \dots, \xi(Z^a W_{h_j} + \beta_{h_j})] W^b = H W^b \quad (6)$$

式中: Y 为模型输出; W^b 是连接特征节点和增强节点到输出层的权重。

2.2 增量学习算法优化宽度学习网络

在深度学习中需要调整网络参数或堆叠更多层数,越深的网络层数会让结构更加复杂,既增加了网络训练时间,又影响了定位结果的稳定性。BLS通过增量学习建立一个实时更新的网络,通过伪逆求解更新权重,在网络模型中添加新的增强节点,不需要重新训练整个网络,极大地提高了网络训练的效率,增量学习算法结构如图3所示。




图3 增量学习结构示意图

Fig. 3 Structure diagram of incremental learning




图4 宽度学习系统训练流程图

Fig. 4 Training flowchart of broad learning system

2.3 创建数据集

首先在位置感知区域不同位置随机选取 \$Q\$ 个点作为参考点,每个参考点为 \$m\$ 个 LED 光源的辐射功率,其中第 \$n\$ (\$1 \leq n \leq Q\$) 个指纹点的信息为

$$F_n = (n, x_n, y_n, z_n, P_{n1}, P_{n2}, \dots, P_{nm}), (1 \leq n \leq Q) \quad (11)$$

式中: \$(x_n, y_n, z_n)\$ 为第 \$n\$ 个点的真实坐标; \$P_{nm}\$ (\$1 \leq n \leq Q\$) 为第 \$n\$ 个点在 \$(x_n, y_n, z_n)\$ 处所测的功率。从中选取 \$L\$ 个样本作为测试集,剩下的 \$K\$ (\$K = Q - L\$) 个样本为训练集。

输入层神经元个数是由室内可见光源的个数 \$m\$ (\$m \geq 4\$) 决定的。在训练阶段,将总计有 \$m\$ 组、每组有 \$K\$ 个样本的光源的光功率作为训练集,则网络的输入训练集矩阵 \$\mathbf{X}^T\$ 可表示为

$$\mathbf{X}^T = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_K \end{bmatrix}^T = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1m} \\ P_{21} & P_{22} & \dots & P_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ P_{K1} & P_{K2} & \dots & P_{Km} \end{bmatrix}^T_{K \times m} \quad (12)$$

图3中 \$W_{h_{b+1}}\$ 和 \$\beta_{h_{b+1}}\$ 分别是新增加节点对应的随机权重和偏置, \$\mathbf{H}^{b+1}\$ 的伪逆 \$(\mathbf{H}^{b+1})^+\$ 为

$$(\mathbf{H}^{b+1})^+ = \begin{bmatrix} (\mathbf{H}^b)^+ - \mathbf{D}\mathbf{B}^T \\ \mathbf{B}^T \end{bmatrix} \quad (7)$$

式中 \$\mathbf{D}\$ 和 \$\mathbf{B}^T\$ 分别表示如下:

$$\mathbf{D} = (\mathbf{H}^b)^+ \xi(Z^a W_{h_{b+1}} + \beta_{h_{b+1}}) \quad (8)$$

$$\mathbf{B}^T = \begin{cases} (\mathbf{C})^+, & \mathbf{C} \neq 0 \\ (1 + \mathbf{D}^T \mathbf{D})^{-1} \mathbf{B}^T (\mathbf{H}^b)^+, & \mathbf{C} = 0 \end{cases} \quad (9)$$

式(9)中 \$\mathbf{C} = \xi(Z^a W_{h_{b+1}} + \beta_{h_{b+1}}) - \mathbf{H}^b \mathbf{D}\$。得出新的输出权重 \$W^{b+1}\$ 为

$$W^{b+1} = \begin{bmatrix} W^b - \mathbf{D}\mathbf{B}^T \mathbf{Y} \\ \mathbf{B}^T \mathbf{Y} \end{bmatrix} \quad (10)$$

BLS采用的增量学习算法简化了数据量和数据维度,它仅计算了新增节点的伪逆,而不是整个网络的伪逆,有效减少了训练时间并节省了资源。因此,在资源有限的情况下,增量学习算法能够快速更新权重。网络模型输入训练样本为采集的光辐射信息及相对应的坐标,输出为网络权重 \$W\$,宽度学习网络训练流程如图4所示。

式中: \$X_K = (P_{K1}, P_{K2}, \dots, P_{Km})\$, 代表训练集数据中在第 \$K\$ 个位置参考点所能接收到的 \$m\$ 个光源的光功率值。

\$L\$ 个测试集中包含参考点与对应的 \$m\$ 个接收光功率矩阵。定义矩阵 \$\overline{\mathbf{D}}^T\$ 为输入矩阵,输入到保存好的预测模型中:

$$\overline{\mathbf{D}}^T = \begin{bmatrix} \overline{D}_1 \\ \overline{D}_2 \\ \vdots \\ \overline{D}_L \end{bmatrix}^T = \begin{bmatrix} \overline{d}_{11} & \overline{d}_{12} & \dots & \overline{d}_{1m} \\ \overline{d}_{21} & \overline{d}_{22} & \dots & \overline{d}_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ \overline{d}_{L1} & \overline{d}_{L2} & \dots & \overline{d}_{Lm} \end{bmatrix}^T \quad (13)$$

式中 \$\overline{D}_L = (\overline{d}_{L1}, \overline{d}_{L2}, \dots, \overline{d}_{Lm})\$ 为测试集中在第 \$L\$ 个位置到 \$m\$ 个 LED 光源之间距离的预测值。最后获得网络输出的位置矩阵,则位置 \$\mathbf{X}\$ 的计算公式为

$$\mathbf{X} = (\mathbf{D}^T \mathbf{D})^{-1} \mathbf{D}^T \mathbf{Y} \quad (14)$$

式中 \$\mathbf{D}\$ 表示为

$$D = \begin{pmatrix} 2(x_m - x_1) & 2(y_m - y_1) & 2(z_m - z_1) \\ \vdots & \vdots & \vdots \\ 2(x_m - x_{m-1}) & 2(y_m - y_{m-1}) & 2(z_m - z_{m-1}) \end{pmatrix} \quad (15)$$

矩阵 Y 表示为

$$Y = \begin{bmatrix} L_1^2 - L_m^2 - (x_1^2 + y_1^2 + z_1^2) + (x_m^2 + y_m^2 + z_m^2) \\ \vdots \\ L_{m-1}^2 - L_m^2 - (x_{m-1}^2 + y_{m-1}^2 + z_{m-1}^2) + (x_m^2 + y_m^2 + z_m^2) \end{bmatrix} \quad (16)$$

3 实验与数据分析

3.1 实验环境及参数设置

在实际室内场景,搭建了不同光源布局下的实验平台,如图 5 所示。在 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$ 的室内空间中一般需要 3~4 个 LED 光源分布,分别对 3LED 和 4LED 进行实验布局。




图 5 不同光源及其模型分布图

Fig. 5 Distribution of different light sources and their models

图 5 中 LED 光源矩阵之间的距离为 $v\text{ m}$, 2 个并排的 LED 阵列与室内空间顶部边缘最近的边之间的距离为 $k\text{ m}$, 其矩阵与空间边缘的距离统一用 L 表示, LED 内灯珠之间间距为 i 。

通过测试后, 3LED 阵列中, $k = 0.9$, $v = 0.03$, 在 4LED 阵列中, $L = 0.3$, $i = 0.015$ 。两种布局的光照强度分布如图 6 所示。

通过图 6 可知, 3LED 的光照强度均值较好且光照强度值较大, 4LED 总体的均匀性更好。综合考虑实验结果以及日常生活环境, 基于宽度学习系

统的可见光室内位置感知实验在 4LED 光照布局下进行。3LED 和 4LED 布局下的指标如表 1 所示。




图 6 3LED 和 4LED 室内光照度分布图

Fig. 6 3LED and 4LED indoor illuminance distribution maps

表 1 两种不同阵列方案光照度对比

Table 1 Comparison of the illuminance of two different array schemes

名称	3LED阵列	4LED阵列
总功率/W	$324 \times 0.5 = 162$	$324 \times 0.5 = 162$
照度最大值/lx	874.67	462.51
照度最小值/lx	182.45	348.28
照度均值/lx	654.1	418.09
满足标准比例/%	74.7	90.4

实验环境相关的参数及光电探测器参数如表 2 所示。

表 2 实验环境和光电探测器参数

Table 2 Experimental environment and photodetector parameters

参数	数据指标	参数	数据指标
实验环境大小	$4\text{ m} \times 4\text{ m} \times 3\text{ m}$	光敏面积	12 mm^2
LED功率	10 W	接收视场角	90°
光电探测器接收面积	1.2 cm^2	额定电压	3 V~5 V
采样间隔	0.2 m	额定电流	6 mA~10 mA
噪声带宽系数	0.612	光谱响应范围	300 nm~1 200 nm
数据传输速率	10 Mbit/s	环境温度	$-2\text{ }^\circ\text{C} \sim 80\text{ }^\circ\text{C}$

在实验场景地面, 用彩色线将实验场地划分为等大小的网格区域, 为了模拟人们在室内活动时

正常活动高度范围,实验在不同高度下按照间隔0.2 m采集光源强度值,再使用朗伯模型优化修正与扩充数据库共获得8405组数据,表3为数据库部分数据。

表3 部分实验数据
Table 3 Partial experimental data

X轴/m	Y轴/m	Z轴/m	LED1/mW	LED2/mW	LED3/mW	LED4/mW
0	0	0	20.16	2.71	4.68	1.44
3	1	0	10.16	2.48	23.79	12.76
2	2	0.5	11.25	12.42	37.69	26.46
3.5	2.5	1	23.94	13.69	56.03	75.83

3.2 宽度学习的网络模型训练

在BLS网络的训练阶段,设定相同的目标误差,可以确保网络模型在避免陷入局部最优或梯度爆炸的情况下实现目标误差,但误差所需的训练次数可能会有显著差异。本文选用最常用的BP神经网络、RBF神经网络与BLS网络进行对比。将采集的数据分别输入到BP神经网络、RBF神经网络和BLS网络中进行训练,其中BLS网络参数设置如表4所示。

表4 BLS网络参数设置
Table 4 BLS network parameter settings

BLS网络训练参数	取值
输入层神经节点数	4
特征节点数量	120
增强节点数量	1000
正则化参数	2×10^{-3}
输出层神经节点数	3

在同样的训练数据集规模和同样的训练目标定位误差下,对3种网络训练所需要的迭代次数进行对比,训练目标误差为10 cm,结果如图7所示。




图7 3种网络训练速度对比

Fig. 7 Comparison of training speed of 3 kinds of networks

由实验结果可知,要达到目标误差,BP神经网络需要约188376次迭代,RBF神经网络需要约140932次迭代,BLS网络需要约84651次迭代。BLS网络相对于BP神经网络训练速度提高了约55.1%,相对于RBF神经网络提高了约39.9%。

设置BLS网络训练模型参数,设置初始值为20个特征节点,500个增强节点,正则化参数设置为 2×10^{-30} 。将采集的数据输入到BLS网络中进行训练并进行定位测试,在不改变增强节点数量的情况下,当调整特征节点数量为80、100、120、140、200时,其误差分别为19.14 cm、17.85 cm、16.77 cm、15.79 cm、12.86 cm。在不改变特征节点数量的情况下,调整增强节点数量为500、700、900、1100、2000,其误差分别为17.85 cm、16.03 cm、14.11 cm、12.27 cm、11.28 cm。

通过实验测试,在BLS网络其他参数不变的情况下,固定增强节点数量为500,发现特征节点数量在100左右时,定位误差趋于稳定,当继续增加特征节点数量时,训练时间相比之前有所增加。固定特征节点数量为100,通过增加增强节点的数量进行网络训练,当增强节点的数量在1000左右时,定位误差趋于稳定,但当大幅增加增强节点数量时,训练时间会成倍增长,而误差很难再有效降低。

3.3 实验结果及分析

3.3.1 网络模型样本数量的分析

实验对不同神经网络的样本数量进行了分析,实验结果如图8所示。




图8 不同网络模型的不同样本误差对比图

Fig. 8 Comparison of errors for different network models with different sample sizes

图8实验结果表明,在样本量为1000时,BLS网络模型的误差达到最小,为11.36 cm,BLS网络相较于ELM、CNN、RBF和BP神经网络更适用于中小样本的应用。

3.3.2 不同区域的室内位置感知误差分析

按照真实的室内场景在 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$ 的定位实验平台中进行定位实验,在实验场地中选取 100 个不同的坐标点,采集这些坐标点处的光强值,并将其输入到训练好的网络模型中进行位置预测,选择 BLS 网络特征节点数量为 120,增强节点数量为 1000,正则化参数设置为 2×10^{-30} 。将实验结果中实验场地中心区域点与边缘区域点位的定位结果分离开,设定距离实验场地各个边缘 1 m 内的区域为边缘区域,其他区域为中心区域,分别计算两个区域定位误差,定位结果如图 9 所示。




图 9 定位误差分布图

Fig. 9 Positioning error distribution diagram

红色实心圆圈、蓝色空心圆圈分别代表预测坐标、真实坐标,在中心区域的 50 个预测点平均误差为 8.06 cm,在边缘区域的 50 个预测点平均误差为 15.19 cm。由实验结果可知,相对于中心区域系统,在边缘区域的定位误差较大,边缘区域接收端离墙面更近,系统受到墙面高阶漫反射的影响更大,导致多径效应在边缘区域比中心区域更为明显,从而影响定位精度。从实测定位结果中选取 8 组位置数据,对其真实坐标与预测坐标进行对比,如表 5 所示。

表 5 部分位置坐标比较

Table 5 Part of position coordinate comparison

真实坐标/m	预测坐标/m	真实坐标/m	预测坐标/m
(1.02, 1.12, 1.00)	(1.04, 1.09, 1.01)	(2.00, 2.00, 2.00)	(2.00, 2.02, 2.01)
(1.68, 1.20, 1.00)	(1.71, 1.20, 0.97)	(1.06, 2.80, 1.50)	(1.11, 2.78, 1.45)
(1.24, 1.30, 0.50)	(1.17, 1.29, 0.46)	(2.80, 2.80, 1.50)	(2.81, 2.73, 1.44)
(2.50, 1.66, 0.50)	(2.51, 1.64, 0.51)	(3.60, 3.84, 2.00)	(3.71, 3.96, 1.94)

3.3.3 网络模型的效率分析

对 BLS 网络算法、ELM 网络算法、CNN 网络算法、RBF 网络算法以及 BP 网络算法进行比较,BLS 网络算法的效率优于其他网络,其实验结果如图 10 所示。




图 10 不同网络算法时间对比图

Fig. 10 Comparison chart of different network algorithms

由图 10 可知,BLS 网络算法的训练时间为 16.38 ms,较其他网络算法训练时间较短,结果表明 BLS 网络在可见光室内位置感知的效率较好。

3.3.4 网络模型的累积误差概率分析

BLS 网络算法预测点误差小于 10 cm 的占 52%,预测点误差小于 20 cm 的点占比为 97%,比 ELM 网络算法、CNN 网络算法、RBF 网络算法以及 BP 网络算法均有提升,定位误差累计分布如图 11 所示。




图 11 定位误差累计分布图

Fig. 11 Cumulative distribution of positioning errors

5 种算法定位误差对比如表 6 所示。

表 6 5 种算法定位误差比较

Table 6 Comparison of positioning errors of 5 algorithms

定位算法	最小误差/cm	最大误差/cm	平均误差/cm
BLS	0.53	20.75	11.63
ELM	0.79	23.47	13.02
CNN	1.21	25.68	13.93
RBF	1.47	28.30	15.60
BP	1.66	27.67	16.40

由实验结果可知, BLS 网络算法性能均高于其他 4 种网络。宽度学习算法的平均误差为 11.63 cm, 与 ELM 神经网络相比, 其定位精度提高了 10.6%, 与 CNN 神经网络相比提高了 16.5%, 与 RBF 神经网络相比提高了 25.4%, 与 BP 神经网络相比提高了 29.1%。

4 结论

本文从可见光室内位置感知系统设计方案入手, 通过对可见光室内位置感知原理的研究, 建立可见光室内信道模型。针对可见光室内位置感知技术受环境影响大, 采用的传统神经网络结构复杂等原因导致的定位不稳定等问题, 在定位算法上将宽度学习网络应用到可见光室内位置感知系统中。为了验证论文所提出的算法, 在室内搭建了切合实际应用场景的定位实验平台, 进一步验证了论文所提算法的可靠性与稳定性。结果表明, BLS 网络相比其他神经网络在定位速度与定位精度上均有提升, 为室内位置感知提供了一种稳定可靠的方法。

参考文献:

- [1] 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): 680513.
- [2] 赵黎, 韩中达, 张峰. 基于神经网络的可见光室内立体定位研究[J]. 中国激光, 2021, 48(7): 0706004.
- [3] SEN U, YESILIRMAK Y E, BAYMAN I O, et al. 3D indoor positioning with spatial modulation for visible light communications[J]. Optics Communications, 2023, 529:

129091.

- [4] BAI L, YANG Y, FENG C, et al. A novel received signal strength assisted perspective-three-point algorithm for indoor visible light positioning[J]. Optics Express, 2020, 19: 28045-28059.
- [5] BAI L, Y YANG, ZHANG Z, et al. A high-coverage camera assisted received signal strength ratio algorithm for indoor visible light positioning[J]. IEEE Transactions on Wireless Communications, 2021, 20(9): 5730-5743.
- [6] 许永泽, 陈哲. 基于 LED 与图像传感器的可见光三维定位系统[J]. 激光与光电子学进展, 2023, 60(19): 87-96.
XU Yongze, CHEN Zhe. Visible light three-dimensional positioning system based on light-emitting diode and image sensor[J]. Laser & Optoelectronics Progress, 2023, 60(19): 87-96.
- [7] 刘思聪, 苏丹萍, 卫天阔, 等. 基于多节点协作的鲁棒可见光智能定位[J]. 电信科学, 2023, 39(5): 28-41.
LIU Sicong, SU Danping, WEI Tiankuo, et al. Multi-node cooperation based robust visible light intelligent positioning[J]. Telecommunications Science, 2023, 39(5): 28-41.
- [8] SU D P, WANG X Y, LIU S C, et al. Four-dimensional indoor visible light positioning: A deep-learning-based perspective[J]. Journal of the Franklin Institute, 2023, 360(6): 256978352.
- [9] 赵黎, 刘海涛, 陈俊波. 基于采用天牛须搜索算法优化神经网络的可见光室内定位方法[J]. 光通信技术, 2022, 46(2): 1-7.
ZHAO Li, LIU Haitao, CHEN Junbo. Visible light indoor positioning method based on optimizing neural network using Tianniu Xu search algorithm[J]. Optical Communication Technology, 2022, 46(2): 1-7
- [10] ABDALMAJEED A M M, MAHMOUD M, EL FAER A, et al. Improved indoor visible light positioning system using machine learning[J]. Optical and Quantum Electronics, 2023, 55(3): 209.
- [11] ZHANG Z, HWANG M, KILBAUGH J T, et al. Improving sub-pixel accuracy in ultrasound localization microscopy using supervised self-supervised deep learning[J]. Measurement Science Technology, 2024, 35(4): 045701.
- [12] WANG Y, JIA P, CUI H, et al. A novel regression prediction method for electronic nose based on broad learning system[J]. IEEE Sensors Journal, 2021, 21(17):

-
- 19374-19381.
- [13] DU J, VONG C M, CHEN C P. Novel Efficient RNN and LSTM-like architectures: recurrent and gated broad learning systems and their applications for text classification[J]. IEEE Transactions on Cybernetics, 2020, 51(3): 1586-1597.
- [14] CHEN C P, LIU Z. Broad learning system: an effective and efficient incremental learning system without the need for deep architecture[J]. IEEE Transactions on Neural Networks And learning Systems, 2017, 29(1): 10-24.