

分区域BES-ELM融合WDME加权双模的室内可见光定位

张慧颖 盛美春 马成宇 李月月 梁士达

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

ZHANG Huiying, SHENG Meichun, MA Chengyu, LI Yueyue, LIANG Shida

引用本文:

张慧颖, 盛美春, 马成宇, 等. 分区域BES-ELM融合WDME加权双模的室内可见光定位[J]. 应用光学, 2024, 45(6): 1321-1330. DOI: 10.5768/JAO202445.0608002

ZHANG Huiying, SHENG Meichun, MA Chengyu, et al. Indoor visible light positioning based on fusion of subregion BES-ELM and WDME weighted dual-mode[J]. Journal of Applied Optics, 2024, 45(6): 1321-1330. DOI: 10.5768/JAO202445.0608002

在线阅读 View online: <https://doi.org/10.5768/JAO202445.0608002>

您可能感兴趣的其他文章

Articles you may be interested in

基于LED照明灯光的可见光室内停车场定位导航系统

Visible light indoor parking lot positioning navigation system based on LED lighting

应用光学. 2019, 40(5): 746-750 <https://doi.org/10.5768/JAO201940.0501005>

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>

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>

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>

基于FPGA的PPM调制可见光图像传输系统

FPGA-based PPM modulated visible light image transmission system

应用光学. 2019, 40(1): 162-166 <https://doi.org/10.5768/JAO201940.0108002>



关注微信公众号, 获得更多资讯信息

文章编号: 1002-2082 (2024) 06-1321-10

分区域 BES-ELM 融合 WDME 加权双模的 室内可见光定位

张慧颖, 盛美春, 马成宇, 李月月, 梁士达

(吉林化工学院 信息与控制工程学院, 吉林 吉林 132022)

摘 要: 针对室内定位精度低、边界区域定位误差大等问题, 提出一种秃鹰搜索算法-极限学习机 (bald eagle search-extreme learning machine, BES-ELM) 神经网络融合加权双模边缘 (weighted dual-mode edge, WDME) 定位模型的室内可见光定位方法。该方法提出采用单 LED 和 5 个光电探测器可见光系统结构, 通过模糊 C 均值聚类算法实现房间区域划分; 采用 BES 优化 ELM 神经网络, 分区域建立 BES-ELM 定位模型; 针对边界区域, 构建 WDME 定位模型, 实现边缘精准定位。基于 $3.2\text{ m}\times 3.2\text{ m}\times 3\text{ m}$ 的室内环境进行仿真, 结果表明: 采用 BES-ELM 算法对中心区域进行定位, 平均定位误差为 0.011 m , 最小定位误差为 0.001 m ; 采用 WDME 定位模型对边缘区域定位, 平均定位误差为 0.013 m , 相较于 ELM、Elman、BES-ELM 模型定位精度分别提高 84%、27%、26%。因此, 所提可见光定位方法使整体区域定位误差减小, 尤其是边缘区域定位精度得到改善。

关键词: 光通信; ELM 神经网络; 秃鹰搜索算法; 分区域; 边缘定位; 可见光定位

中图分类号: TN929.12

文献标志码: A

DOI: 10.5768/JAO202445.0608002

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

ZHANG Huiying, SHENG Meichun, MA Chengyu, LI Yueyue, LIANG Shida

(College of Information and Control Engineering, Jilin Institute of Chemical Technology, Jilin 132022, China)

Abstract: Aiming at the problems of low indoor positioning accuracy and large boundary area positioning error, an indoor visible light positioning method based on the bald eagle search-extreme learning machine (BES-ELM) neural network and weighted dual-mode edge (WDME) positioning model was proposed. In this method, a visible light system structure with a single LED and five photodetectors was proposed, and the room was divided by fuzzy c-means clustering algorithm. The BES was used to optimize the ELM neural network, and the BES-ELM positioning model was established in different regions. Aiming at the boundary area, a weighted dual-mode edge (WDME) positioning model was constructed to achieve accurate edge location. Based on the indoor environment simulation of $3.2\text{ m}\times 3.2\text{ m}\times 3\text{ m}$, the results show that using the BES-ELM algorithm to locate the center area, the average positioning error is 0.011 m , and the minimum positioning error is 0.001 m . Using the WDME positioning model to locate the edge area, the average positioning error is 0.013 m , which is 84%, 27%, and 26% higher than that of ELM, Elman and BES-ELM models, respectively. Therefore, the proposed visible light positioning method reduces the overall area positioning errors, especially improving the positioning accuracy of edge area.

Key words: optical communications; ELM neural network; eagle search algorithm; subregion; edge positioning; visible light positioning

收稿日期: 2023-09-11; 修回日期: 2023-12-19

基金项目: 吉林省自然科学基金 (联合基金 YDZJ202101ZYTS189); 吉林省科技发展计划项目 (20220508145RC)

作者简介: 张慧颖 (1982—), 女, 博士, 主要从事光通信技术应用、可见光通信、检测技术研究。E-mail: yingzi1313@163.com

引言

近年来,随着社会对定位服务需求的与日俱增,如何在复杂的室内空间达到准确定位逐渐变成热门话题。目前广泛应用的定位技术有蓝牙、红外线、无线局域网、射频识别技术和超宽带等^[1-2],但大部分定位精度低、成本高,抗干扰效果差。基于可见光的定位方法具有抗干扰效果强、定位准确、速度快等优势,已经成为室内定位领域研究热点^[3-4]。现有的 VLP (visible light positioning) 系统大部分采用多个 LED 灯,需要采用相关技术来消除 LED 灯之间的互相干扰。相比而言,使用单个 LED 灯进行定位能够防止 LED 灯之间的干扰,节省资源,并能提高定位准确度。因此,采用单 LED 的 VLP 技术在日常生活中更加环保实用。现阶段,人工智能技术发展迅速,基于机器学习的室内可见光定位技术被广泛应用。文献[5]提出基于 BP (back propagation) 神经网络拟合可见光信道参数,实现待测目标初始定位,然后利用定位误差约束模型确定待测目标的最终位置,但 BP 神经网络的初始权阈值是随机生成的,定位精度欠佳;文献[6]利用神经网络拟合信道模型,预测光信号的传输距离,基于优化的遗传算法进行三维定位,但位置坐标仍需要用最小二乘法计算;文献[7]提出基于欧式距离改进的加权 K 最近邻算法,平均定位误差为 0.163 m,精度提升有限,且计算量较大;文献[8]提出选用天牛须搜索算法改进神经网络的初始权值和阈值,定位误差低于 3.42 cm,但整体定位误差分布不均匀,边缘区域定位精度需进一步提高。

基于以上问题,本文提出一种秃鹰搜索算法-极限学习机(BES-ELM)神经网络融合加权双模边缘(WDME)定位模型的室内可见光定位方法。本文采用单 LED 和 5 个光电探测器 (photodetector, PD) 作为可见光系统结构,采集 PD 接收端的接收信号强度值和对应的物理坐标来建立指纹数据库。采用模糊 C 均值聚类算法通过指纹数据库将房间分为中心区域和边界区域,从而实现区域划分。由于极限学习机 (ELM) 神经网络容易陷入局部最优且收敛速度慢,采用 BES 算法优化 ELM 神经网络的初始权值和阈值,分区域建立 BES-ELM 室内定位模型来提高定位精度。受四周环境的影响,中心区域和边缘区域定位精度存在波动,边缘区域定位需进一步改善,提出在 BES-ELM 神经网络基础上结合 Elman 神经网络来构建 WDME 模型,实现边缘精准定位。仿真结果表明,所提可见光定位方法实现了高精度定位。

1 室内可见光定位模型

在室内设置单个 LED, 房间地面上任意位置放置 5 个 PD 作为接收器, 位置定位模型如图 1 所示。为了使接收器收到的信号强度更加均匀, PD 采用圆形排列, 如图 2 所示。




图 1 定位结构

Fig. 1 Positioning structure




图 2 PD 布局

Fig. 2 PD layout

考虑到可见光在直射链路(LOS)时的信号远大于非视距传播(NLOS), 且二阶反射分量在 NLOS 反射分量所占比例较低, 因此本文只考虑视距传播^[9]。假设 LED 灯在空间传播时遵循朗伯辐射模型, 在 LOS 链路中, 接收端(PD)的直流增益 $H(0)_{\text{LOS}}$ 可以表示为^[10]

$$H(0)_{\text{LOS}} = \begin{cases} \frac{(m+1)}{2\pi d^2} A \cos^m(\phi) T_s(\psi) g(\psi) \cos(\psi), & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases} \quad (1)$$

式中: A 为 PD 的物理面积; d 表示发送端到接收端的间距; m 为朗伯散射系数; ϕ 为发散角; ψ 为 PD 接收角; ψ_c 表示 PD 视场角; $T_s(\psi)$ 和 $g(\psi)$ 分别表示链路中光滤波器增益和光学集中器增益^[11]。

2 分区域房间模型建立

房间边界区域受四周环境的影响, 定位稳定性差且精度低, 因此提出采用模糊 C 均值聚类算法

(fuzzy c-means, FCM) 根据 PD 端接收信号强度指示 (received signal strength indication, RSSI) 将待测房间划分区域, 从而实现分区域定位来提高边界区域定位精度。设室内定位环境中存在 w 个参考点, 对每个参考点收集接收器 PD 的 RSSI 值及对应的物理坐标, 可表示为

$$\mathbf{F}_\delta = (x_\delta, y_\delta, R_{\delta 1}, R_{\delta 2}, R_{\delta 3}, R_{\delta 4}, R_{\delta 5}) \quad (2)$$

式中: (x_δ, y_δ) 为第 δ 个参考点的物理坐标, $\delta = 1, 2, 3, \dots, w$; $R_{\delta M}$ ($M=1, 2, 3, 4, 5$) 代表接收器 M 在第 δ 个参考点的 RSSI 值。根据采集的指纹信息建立指纹数据库得:

$$\mathbf{X}_{\text{data}} = \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \\ \vdots \\ \mathbf{F}_w \end{bmatrix} = \begin{bmatrix} x_1, y_1, R_{11}, R_{12}, R_{13}, R_{14}, R_{15} \\ x_2, y_2, R_{21}, R_{22}, R_{23}, R_{24}, R_{25} \\ \vdots \\ x_w, y_w, R_{w1}, R_{w2}, R_{w3}, R_{w4}, R_{w5} \end{bmatrix} \quad (3)$$

将指纹数据库 $\mathbf{X}_{\text{data}}$ 通过模糊 C 均值聚类^[12] 算法分成两个模糊组, 计算出待测房间每个参考点在不同模糊组中的隶属度, 将参考点划分到隶属度值最大的对应模糊组中, 即使如下目标函数获得最小值:

$$S(\mathbf{X}_{\text{data}}, u_1, u_2, \dots, u_c) = \sum_{k=1}^w \sum_{i=1}^c (v_{ik})^f (d_{ik})^2 \quad (4)$$

式中: u_i 为第 i 类的模糊聚类中心; v_{ik} 表示第 k 个参考点对于第 i 个类的隶属度; $d_{ik} = \|\mathbf{F}_k - u_i\|$ 表示第 k 个参考点与第 i 类聚类中心的欧式距离。

S 对 u_i 和 v_{ik} 求偏导数, 并令其值等于 0, 则令式 (4) 取得极小值的必要条件为

$$u_i = \frac{\sum_{k=1}^w (v_{ik}) \mathbf{F}_k}{\sum_{k=1}^w (v_{ik})^f} \quad (i = 1, 2, \dots, c; f > 1) \quad (5)$$

$$v_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{\frac{2}{f-1}}} \quad (6)$$

对式 (5) 和式 (6) 不断迭代求解, 直到获得目标函数的最小值。基于 FCM 算法的空间划分过程如表 1 所示。根据表 1 流程将房间划分为中间区域和边界区域后, 然后利用提出的方法实现分区域定位, 分区域定位模型如图 3 所示。构建可见光定位信道模型, 建立指纹数据库, 基于 FCM 算法将房间进行区域划分。针对两个区域构建 BES-ELM 定位模型, 中心区域实现了高精度定位, 但受环境的影响, 整体定位精度不均匀, 边缘区域定位误差大, 提出边缘加权双模定位模型。

表 1 模糊 C 均值聚类算法流程

Table 1 Fuzzy c-means clustering algorithm flow

步骤	流程
步骤1	将指纹数据库输入到模糊C均值聚类算法中, 确定聚类数, 随机生成初始模糊类, 并根据式(5)计算模糊聚类中心
步骤2	根据式(6)计算剩余指纹点与聚类中心指纹点之间的隶属度, 指纹点聚类后重新计算聚类中心, 更新隶属度, 重组隶属度矩阵
步骤3	根据式(4)计算目标函数, 判断目标函数是否达到最小值或达到最大迭代次数, 如果满足, 迭代停止, 否则返回步骤2继续迭代
步骤4	基于输出数据指纹库的最优聚类结果, 将定位区域划分为中心区域和边界区域




图 3 分区域定位模型

Fig. 3 Schematic diagram of subregional positioning model

3 BES-ELM 定位模型的建立

3.1 BES 算法

BES 算法由 ALSATTAR H A 提出^[13], 该方法对秃鹰抓捕猎物的行为进行模拟, 具有较强的全局搜索能力^[14]。秃鹰抓捕猎物包含选取搜索范围、搜索和俯冲 3 个过程^[15], 具体如下文。

1) 选择阶段。在此过程, 秃鹰任意选取探索区域, 依照猎物的多少从而选择合适的寻找区域。

$$P_{\text{new},q} = P_{\text{best}} + \alpha \cdot r(P_{\text{mean}} - P_q) \quad (7)$$

式中: $P_{\text{new},q}$ 为第 q 只秃鹰迭代后的位置; α 用来调节秃鹰的位置变动, 取值为 $[1.5, 2]$ 区域; r 表示随机数, 其值在 $[0, 1]$ 内; P_{best} 表示目前最佳位置; P_q 为第 q 只秃鹰的位置; P_{mean} 是秃鹰搜索完成后的平均

位置。

2) 搜索阶段。此过程,秃鹰种群在探索范围内以螺旋状移动来加快对食物的寻找。该位置的更新公式可表示为

$$P_{\text{new},q} = P_q + y(q) \cdot (P_q - P_{q+1}) + x(q) \cdot (P_q - P_{\text{mean}}) \quad (8)$$

式中 $x(q)$ 与 $y(q)$ 代表秃鹰在极坐标中的位置,取值均为 $(-1,1)$ 。

3) 俯冲阶段。秃鹰在最佳位置向目标对象俯冲,同时剩余种群也朝着最佳点移动。该位置的更新公式可表示为

$$P_{\text{new},q} = \text{rand} \cdot P_{\text{best}} + x_1(q) \cdot (P_q - c_1 \cdot P_{\text{mean}}) + y_1(q) \cdot (P_q - c_2 \cdot P_{\text{best}}) \quad (9)$$

式中 c_1 和 c_2 为秃鹰向最佳位置和中心位置的运动强度,取值范围均介于1至2之间。

3.2 BES-ELM 算法设计

ELM由输入层、隐藏层和输出层构成^[16]。ELM算法随机初始化隐藏层的连接权值和阈值,不需要复杂的参数设置,该算法具有训练参数少、训练速度快、泛化性能强的优点。ELM神经网络结构如图4所示。将参考点的RSSI值作为ELM神经网络的输入,预测参考点的坐标。




图4 ELM神经网络结构

Fig. 4 Structure diagram of ELM neural network

ELM神经网络的数学表达式为

$$T_\eta = \sum_{s=1}^L \beta_s g(W_s \cdot Q_\eta + b_s), \eta = 1, \dots, \tau \quad (10)$$

式中: W_s 为输入层第 s 个神经元和隐藏层间的连接权值矩阵; Q_η 为输入矩阵; β_s 为连接隐藏层第 s 个神经元与输出层的权重矩阵; b_s 为隐藏层的阈值矩阵; τ 为参考点总数; $g(x)$ 为激活函数; L 为隐藏层神经元的数目; T_η 为输出矩阵。

采用BES来改进ELM随机生成的初始权阈值,将ELM的初始权阈值映射为每只秃鹰在不同

维度的位置,计算秃鹰种群的适应度值,其适应度函数为

$$E = \frac{1}{n} \sum_{s=1}^n (T_s - \hat{T}_s)^2 \quad (11)$$

式中: T 为训练集实际坐标; $\hat{T}$ 为预测坐标; n 为训练样本总数。因此确定神经网络最优初始参数问题即为适应度值最小化的问题。BES-ELM的算法流程如图5所示,主要包括ELM神经网络参数初始化、BES寻优确定神经网络参数和ELM神经网络训练3个部分。




图5 BES-ELM定位算法流程

Fig. 5 Flow chart of BES-ELM positioning algorithm

具体的实现步骤如下:

1) 构建网络模型。初始化模型参数,由网络隐藏层输入权重与阈值的数量定义秃鹰个体的空间维度 K ,表示为

$$K = F \times L + L \quad (12)$$

式中: L 为隐藏层神经元数目; F 表示输入层神经元数目。

2) 通过式(11)计算算法的适应度值。根据获得的适应度,更新最优个体值,进行选择、搜索与俯冲等行为,直至满足约束条件,终止更新得到最优解。

3) 训练网络模型。将使适应度函数达到最小的参数值作为ELM网络的最优权阈值,构建BES-ELM网络模型。

4 WDME 加权双模边缘定位模型构建

4.1 Elman 神经网络

Elman 网络在 BP 神经网络基础上加入一个承接层, 从而实现记忆效果, 该网络将之前时刻的隐含层信息与当前时刻的输入都作为隐含层的输入, 从而增加了解决动态信息的功能^[17], 模型如图 6 所示。




图 6 Elman 模型

Fig. 6 Schematic diagram of Elman model

Elman 神经网络数学模型可表示为

$$y(t) = g(w_3 x(t)) \quad (13)$$

$$x(t) = f(w_1 x_c(t) + w_2 u(t-1)) \quad (14)$$

$$x_c(t) = x(t-1) \quad (15)$$

式中: $u(t-1)$ 表示输入层的输入矩阵; $y(t)$ 表示输出层的输出矩阵; w_1, w_2, w_3 为连接权值; $x_c, x(t)$ 分别为承接层输出、隐含层输出。

4.2 WDME 边缘定位模型设计

本文提出一种基于 WDME 加权双模边缘定位模型来实现边缘精确定位。首先分别用 BES-ELM 神经网络和 Elman 神经网络对训练集数据进行训练, 获得两组初始定位坐标。根据定位误差确定两个模型的权值, 将两组初始定位坐标加权得到最终定位坐标, 定位模型如图 7 所示。




图 7 WDME 定位模型图

Fig. 7 Schematic diagram of WDME positioning model

WDME 定位模型具体步骤如下:

- 1) 分别采用 BES-ELM 和 Elman 神经网络对相同的训练集进行训练, 获得最佳定位模型;
- 2) 利用训练好的神经网络对测试集数据预测, 获得待测点的粗定位坐标 (x_1, y_1) 、 (x_2, y_2) ;
- 3) 分别计算 BES-ELM、Elman 模型的定位误差总和 R_1, R_2 ;
- 4) 根据定位误差总和计算两个模型的权重, 则 BES-ELM 模型的权重为

$$w_1 = \frac{R_2}{R_1 + R_2} \quad (16)$$

Elman 模型的权重为

$$w_2 = \frac{R_1}{R_1 + R_2} \quad (17)$$

- 5) 则最终定位坐标为

$$\begin{cases} x = w_1 x_1 + w_2 x_2 \\ y = w_1 y_1 + w_2 y_2 \end{cases} \quad (18)$$

因此, 利用加权双模定位模型可精确获得边缘预测点的最终坐标 (x, y) 。

5 仿真与分析

本文通过在 $3.2 \text{ m} \times 3.2 \text{ m} \times 3 \text{ m}$ 的测试区域下进行实验来评估定位系统的性能, 单 LED 灯的三维坐标为 $(0, 0, 3)$, 通过采集的位置信息和 RSSI 值创建指纹数据库, 并对所提方法进行仿真实验验证, 参数如表 2 所示。

表 2 仿真参数

Table 2 Simulation parameters

名称	参数
房间高度/m	3
滤波器增益	1
半功率角 $\Phi_{1/2} / (^\circ)$	80
LED 发射功率/W	18
r/cm	5
视场角 $(^\circ)$	55

5.1 房间区域划分实验

受四周环境的影响, 边界区域和中心区域的接收信号强度差异较大, 从而导致训练时间长、边界区域定位误差大等问题。利用模糊 C 均值聚类算法根据接收信号强度值实现空间分区, 结果如图 8 所示。可以看出, 由于墙壁周围区域光照强度降低, 接收端的接收信号强度值会相应减弱, 墙壁周围区域的 RSSI 值比内部区域的 RSSI 值小, 待测空

间被分为边缘区域和中心区域。




图 8 区域划分结果

Fig. 8 Results of regional division

5.2 定位性能对比分析

在 $3.2\text{ m} \times 3.2\text{ m} \times 3\text{ m}$ 的测试区域下, 采用相同训练数据对 BP 神经网络、ELM 神经网络和 BES-ELM 神经网络进行训练, 比较 3 种算法模型在待测点数目为 20、40、60、80、100、120 和 140 的预测准确率、稳定性及泛化性, 实验结果如图 9 所示。




图 9 定位误差比较

Fig. 9 Comparison of positioning errors

由图 9 可以看出, 在待测点数目为 20、40、60、80、100、120 和 140 时, BP 算法模型平均定位误差分别为 0.109 1 m、0.097 5 m、0.116 7 m、0.114 8 m、0.097 9 m、0.111 5 m、0.101 9 m; ELM 算法模型平均定位误差分别为 0.070 6 m、0.070 7 m、0.073 0 m、0.063 7 m、0.074 8 m、0.078 7 m、0.061 3 m; BES-ELM 算法模型平均定位误差分别为 0.029 6 m、0.024 7 m、0.017 6 m、0.024 2 m、0.028 1 m、0.022 2 m、0.026 1 m。当测试点数目发生变化时, BP 算法定位误差浮动大, 定位精度较低; BES-ELM 算法最大平均定位误差为 0.029 6 m, 相较于 BP 算法和 ELM 算法定位精度高、定位性能较稳定。因此,

BES-ELM 算法预测精度、稳定性及泛化性均优于 BP 算法和 ELM 算法。


5.3 单 LED 多 PD 定位模型性能分析

为了验证本文提出的单 LED 多 PD 定位模型的性能, 采用 BES-ELM 算法分别在传统 4-LED 单 PD、单 LED 多 PD 布局下随机选取相同数目指纹点进行定位测试, 定位误差如表 3 所示, 定位效果如图 10 所示。


表 3 误差对比

Table 3 Error comparison

定位模型	最大误差	最小误差	平均误差
传统4-LED	0.382 1	0.002 0	0.040 3
单LED多PD	0.063 0	0.005 8	0.028 1



(a) 传统4-LED



(b) 单LED多PD

图 10 定位效果分布图

Fig. 10 Distribution diagram of positioning effects

由表 3 和图 10 分析可知, 传统 4-LED 布局的误差最大为 0.382 1 m, 平均定位误差为 0.040 3 m, 定位误差浮动大; 单 LED 多 PD 布局的误差最大达到 0.063 0 m, 最小为 0.005 8 m, 误差平均值为 0.028 1 m, 相较于传统 4-LED 布局平均定位误差提升 30%。可以看出, 单 LED 多 PD 布局泛化性

更好, 定位精度得到大幅度提升, 且定位效果较稳定。

5.4 分区域定位误差仿真对比分析

在单灯情况下, 将 $3.2\text{ m} \times 3.2\text{ m} \times 3\text{ m}$ 的待测区域划分为中间区域和边界区域后, 随机选取 100 个测试点, 分别利用全局 BES-ELM 定位法和分区域 BES-ELM 定位法进行测试, 累计误差分布如图 11 所示。




图 11 累积误差分布

Fig. 11 Distribution diagram of accumulative errors

由图 11 可知, 分区域 BES-ELM 定位法在误差为 0.12 m 左右时累积误差分布概率达到 1, 且 81% 的测试点定位误差小于 0.02 m, 误差最大为 0.128 6 m, 平均定位误差为 0.014 8 m; 而全局 BES-ELM 定位法在误差为 0.15 m 时累积误差分布概率接近于 1, 定位性能不稳定, 误差最大为 0.152 8 m, 平均定位误差为 0.027 8 m。可知, 分区域 BES-ELM 法累积误差分布概率能更快达到 1, 平均定位误差相较于全局 BES-ELM 定位法改善了 47%, 整体预测结果得到改善。

分区测试误差分布如图 12 所示, 累积误差结果如图 13 所示。由图 12 知, 使用 BES-ELM 模型进行分区测试时, 中间位置误差最小达到 0.001 9 m, 最大误差为 0.003 4 m, 定位误差平均值为 0.011 7 m, 定位精度高且整体定位误差浮动较小; 边界位置定位误差的平均值为 0.018 0 m, 最大值为 0.128 6 m, 最小值为 0.004 4 m, 定位误差相差较大。由图 13 知, 中间区域误差稳定在 0.04 m 以内, 86% 的测试点误差小于 0.02 m, 而边界区域在误差为 0.12 m 左右时累积误差分布概率达到 1。因此, 房间中心区域和边界区域定位误差存在浮动, 总体定位精度不均匀, 中心区域能实现高精度预测, 累积误差分布概率能很快接近 1, 而边缘区域定位需进一步改善。




图 12 定位误差分布

Fig. 12 Distribution diagram of positioning errors




图 13 累积误差分布

Fig. 13 Distribution diagram of accumulative errors

5.5 边缘区域定位误差仿真对比

为提高分区域后边界区域定位精度, 构建 WDME 边缘定位模型。从边缘区域随机选取相同测试点, 将 WDME 边缘定位模型与 BES-ELM 定位模型的定位误差进行对比, 累积误差分布如图 14 所示。

从图 14 中可以看出, BES-ELM 定位算法平均误差为 0.018 0 m, 最大误差为 0.128 6 m; WDME 定位模型平均误差为 0.013 3 m, 最大误差为 0.078 2 m, 94% 的定位点误差小于 0.02 m, 比 BES-ELM 定位模型精度提高 26%。可以发现 WDME 定位模型定位准确率较高, 累积误差分布概率能很快接近 1, 整体定位结果均匀, 稳定性更强。为进一步验证 WDME 模型定位精度, 分别采用 ELM 模型、BES-

ELM模型、Elman模型、所提WDME定位模型等定位方法训练对边界区域数据,定位测试结果如图15所示,定位误差占比如图16所示。




图14 累积误差分布曲线

Fig. 14 Distribution curves of accumulative errors







图15 边界区域定位误差分布图

Fig. 15 Distribution diagram of boundary area positioning errors




图16 定位误差占比直方图

Fig. 16 Histogram of positioning errors proportion

由图15可知,WDME定位模型大部分预测点靠近真实点,误差最小达到0.0019 m,最大误差为0.0782 m,定位误差平均值为0.0133 m,与ELM模型、BES-ELM模型、Elman模型等定位方法相比,平均定位误差分别提高84%、26%、27%。由图16可以看出,传统ELM神经网络定位算法定位性能不稳定,在0~0.02 m误差区间内的占比仅为8%,大部分集中在0.04 m~0.06 m和>0.08 m误差区间上,误差所占比例共为62%;Elman神经网络和BES-ELM神经网络两种定位方法的定位误差在0~0.02 m区间内的占比分别为54%、76%。所提出的加权双模定位模型在0~0.02 m、0.02 m~0.04 m、0.04 m~0.06 m、0.06 m~0.08 m、>0.08 m这5个区间范围内占比情况分别为94%、4%、0%、2%、0%,整体定位误差稳定在0.02 m内。可以看出,边界区域采用WDME定位模型定位误差降低,且稳定性得到提升。

6 结论

本文提出一种基于机器学习算法的单LED多

PD 的室内可见光定位模型。在 VLP 系统中,采用 BES 算法优化 ELM 神经网络,使 ELM 神经网络结构更加稳定,不易陷入局部最优,建立 BES-ELM 定位模型提高整体区域定位精度;考虑到边界区域受四周环境的影响,定位误差较大,采用模糊 C 均值聚类算法将房间分为中心区域和边界区域,利用 BES-ELM 定位模型分区域定位,在 BES-ELM 神经网络基础上构建 WDME 定位模型来提高边角区域的定位精度。仿真结果表明,采用单 LED 多 PD 系统模型平均定位误差为 0.028 1 m,相比于传统 4-LED 系统模型定位精度提高且节省资源;利用 BES-ELM 神经网络对中心区域进行定位时,平均定位误差为 0.011 7 m;提出的加权双模边缘定位模型对边角区域定位时,其平均定位误差为 0.013 3 m,相较于 BES-ELM 模型定位精度提高 26%。因此,WDME 定位算法提高了边界区域定位精度,使整个房间的定位精度趋于稳定。

参考文献:

- [1] MARTÍN-GOROSTIZA E, GARCÍA-GARRIDO M A, PIZARRO D, et al. An indoor positioning approach based on fusion of cameras and infrared sensors[J]. *Sensors*, 2019, 19(11): 2519.
- [2] ZHU Q, XIONG Q, WANG K, et al. Accurate WiFi-based indoor localization by using fuzzy classifier and MLPs ensemble in complex environment[J]. *Journal of the Franklin Institute*, 2020, 357(3): 1420-1436.
- [3] 张慧颖, 于海越, 陈玲玲. 基于反向学习策略的自适应花授粉接收信号强度指示室内可见光定位[J]. *中国激光*, 2021, 48(1): 0106001.
ZHANG Huiying, YU Haiyue, CHEN Lingling. Adaptive flower pollination received signal strength based on reverse learning strategy for indicating indoor visible light localization[J]. *Chinese Journal of Lasers*, 2021, 48(1): 0106001.
- [4] SHI C, NIU X, LI T, et al. Exploring fast fingerprint construction algorithm for unmodulated visible light indoor localization[J]. *Sensors*, 2020, 20(24): 7245.
- [5] 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): 145-154.
ZHAO Li, HAN Zhongda, ZHANG Feng. Research on stereo location in visible light room based on neural network[J]. *Chinese Journal of Lasers*, 2021, 48(7): 145-154.
- [6] GUAN W P, WU Y X, XIE C Y, et al. High-precision approach to localization scheme of visible light communication based on artificial neural networks and modified genetic algorithms[J]. *Optical Engineering*, 2017, 56(10): 106103.
- [7] 梁哲豪, 石磊, 唐杰, 等. 室内可见光指纹定位系统中改进的加权 K 最近邻算法[J]. *激光与光电子学进展*, 2022, 59(17): 123-127.
LIANG Zhehao, SHI Lei, TANG Jie, et al. Improvement of WKNN algorithm in indoor visible light fingerprint location system[J]. *Laser & Optoelectronics Progress*, 2022, 59(17): 123-127.
- [8] 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. Indoor visible light location method based on neural network optimized by beetle antennae search algorithm[J]. *Optical Communication Technology*, 2022, 46(2): 1-7.
- [9] 张慧颖, 于海越, 王凯, 等. 基于 KPCA-K-means++ 和 GA-LMS 模型的改进 RBF 神经网络室内可见光定位[J]. *光学学报*, 2021, 41(19): 1906001.
ZHANG Huiying, YU Haiyue, WANG Kai, et al. Indoor visible light positioning of improved RBF neural network based on KPCA-K-means++ and GA-LMS model[J]. *Acta Optica Sinica*, 2021, 41(19): 1906001.
- [10] SONG Y, CHEN Z, YUAN Z. New chaotic PSO-based neural network predictive control for nonlinear process[J]. *IEEE Transactions on Neural Networks*, 2007, 18(2): 595-601.
- [11] LU X, ZOU H, ZHOU H, et al. Robust extreme learning machine with its application to indoor positioning[J]. *IEEE Transactions on Cybernetics*, 2015, 46(1): 194-205.
- [12] 徐金东, 赵甜雨, 冯国政, 等. 基于上下文模糊 C 均值聚类的图像分割算法[J]. *电子与信息学报*, 2021, 43(7): 2079-2086.
XU Jindong, ZHAO Tianyu, FENG Guozheng, et al. Image segmentation algorithm based on context fuzzy c-means clustering[J]. *Journal of Electronics & Information Technology*, 2021, 43(7): 2079-2086.
- [13] ALSATTAR H A, ZAIDAN A A, ZAIDAN B B. Novel meta-heuristic bald eagle search optimization algorithm[J]. *Artificial Intelligence Review*, 2020, 53(3): 2237-2264.
- [14] ZHANG Y Z, HOU L H, WU W L, et al. On the metric

- dimension of the folded -cube[J]. [Optimization Letters](#), 2020, 14(1): 249-257.
- [15] 贾鹤鸣, 姜子超, 李瑶. 基于改进秃鹰搜索算法的同步优化特征选择[J]. 控制与决策, 2022, 37(2): 445-454.
- JIA Heming, JIANG Zichao, LI Yao. Simultaneous feature selection optimization based on improved bald eagle search algorithm[J]. Control and Decision, 2022, 37(2): 445-454.
- [16] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1): 489-501.
- [17] 王文川, 王莉芳, 郭安强. 基于 PSO-Elman 修正模型的年径流预测[J]. 人民长江, 2022, 53(11): 66-71.
- WANG Wenchuan, WANG Lifang, GUO Anqiang. Annual runoff prediction based on PSO-Elman modified model[J]. Yangtze River, 2022, 53(11): 66-71.