

基于遗传算法优化 ELM 神经网络的室内可见光定位系统

秦岭, 王东星, 史明泉, 王凤英, 胡晓莉*

内蒙古科技大学信息工程学院, 内蒙古 包头 014010

摘要 针对室内定位精度不高、稳定性差的问题,本文提出了一种基于遗传算法优化极限学习机(GA-ELM)的多LED灯室内可见光定位系统。该系统先通过遗传算法(GA)优化 ELM 神经网络的初始权值和阈值,使优化后的 ELM 网络的拓扑结构更加稳定,不易陷于局部最优;然后利用各个参考点处 LED 接收的光功率以及接收机的位置坐标作为指纹数据,构建指纹数据库,将指纹数据库引入到优化好的 ELM 网络模型中进行训练,建立定位模型。实验结果表明,在 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$ 的测试空间内,本文算法的平均定位误差为 0.9214 cm ,最大定位误差为 3.9192 cm ,定位精度可达毫米级。

关键词 探测器; 遗传算法; 极限学习机; 可见光定位; 神经网络; 指纹数据库

中图分类号 TN929.1 文献标志码 A

DOI: 10.3788/CJL202249.2106001

1 引言

近年来,全球定位系统(GPS)的应用已经普及到人们的生活中,例如手机导航、测绘等。但室内环境复杂,卫星发射的信号很容易被其他物体阻挡,从而导致 GPS 在室内定位误差变大^[1-3]。随着科技的发展,人们开发出了很多定位技术,如红外、无线网络通信(WiFi)、射频识别(RFID)、蓝牙、超宽带(UWB)等技术^[4-6]。但这些技术都存在一些不足:红外定位技术与 UWB 定位技术虽然在定位精度上有很大优势,但需要大量的仪器设备,成本较高;蓝牙容易受噪声的影响,而且当室内环境复杂时,定位效果就会变得不稳定;RFID 技术作用距离短,而且定位误差较大,平均定位误差高达 1 m ; WiFi 定位很容易受到其他信号的干扰,平均定位误差高达 2 m ^[7-14]。可见光具有保密性好和方便快捷的特点,定位精度也高,已成为现阶段的研究热点^[15-17]。

近年来,机器学习技术越来越成熟,将机器学习算法应用于室内可见光定位成为许多学者的研究重点,并且取得了较好的定位结果。2019 年, Huang 等^[18]提出了一种利用阵列伪卫星的室内定位系统,他们利用 4 层卷积神经网络(CNN)叠加构成深度学习框架 Keras,设计了带有位置信息的 VAE 深度学习网络模型;仿真结果表明,该系统的平均定位误差为 0.39 m ,95% 的定位误差小于 0.85 m 。2020 年, Mao 等^[19]提

出了一种基于改进 Camshift 跟踪算法的高精度室内可见光定位系统,该系统的定位误差能够达到 2 cm 左右,但算法涉及图像处理过程,较为复杂。由上述研究现状可知,现如今大多数学者将机器学习与可见光定位相结合,以获得更好的定位效果^[20]。

为了进一步提高室内可见光定位的精度及系统的稳定性,本团队提出了一种基于遗传算法优化极限学习机(ELM)神经网络的室内可见光定位系统。为了解决边界区域定位误差较大的问题,本团队将 4 只 LED 均匀地悬挂在天花板上作为发射端发射信号,在接收端利用光电探测器(PD)作为接收器接收光功率。在离线阶段,将接收到的光功率值以及 PD 坐标点作为特征,构建指纹数据库,然后将其引入 GA-ELM 网络模型中进行训练,得到基于接收光功率的定位模型。在线阶段,将测试点处的光功率值作为指纹数据输入定位模型中,实现定位。对于一些传统的定位算法,比如三边定位法,因多径效应的影响,采用这些算法进行测距时会产生距离估计不准确的问题,从而使得定位系统产生较大的定位误差。在 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$ 的测试空间内,本文所提算法可以达到毫米级的定位精度,且系统更加稳定,具有更高的适用性。

2 基本原理

2.1 LED 灯数量的选取

采用多 LED 灯进行室内定位时,LED 灯数量的

收稿日期: 2021-12-17; 修回日期: 2021-12-26; 录用日期: 2022-02-22

基金项目: 国家自然科学基金(62161041)、内蒙古关键技术攻关项目(2021GG0104)

通信作者: *huxiaoli@imust.edu.cn

选取至关重要:如果灯的数量过多,就会导致成本增加,定位系统更加复杂;而如果灯的数量过少,则不能满足日常生活需求。因此,本团队分别对以 3 只、4 只、6 只 LED 灯作为发射端的定位系统进行了仿真测试。在各个参数设置都相同的情况下,仿真结果如

表 1 LED 灯数量选取的仿真结果

Table 1 Simulation results for selecting the number of LED

The number of LED	Max localization error /cm	Average localization error /cm	Localization time /s
3	99.490	10.3500	0.0315
4	3.912	0.9418	0.0413
6	4.640	0.9500	0.0874

2.2 室内信道模型

设室内定位空间大小为 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$, 定位模型如图 1 所示。4 只 LED 灯均匀地安装在房间的天

花板上,作为发射信号源;PD 摆放在距离地面一定高度的位置上。假设 LED 的发光强度服从朗伯辐射模型,则在直射链路下信道增益可以表示为

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

其中,

$$m = \frac{\ln 2}{\ln(\cos \phi_{1/2})}, \quad (2)$$

式中: m 为光源的朗伯阶数; A 为 PD 内部的有效接收面积; d 为 LED 到 PD 的距离; ψ 为 PD 的入射角; φ 为 LED 的发射角; $T_s(\psi)$ 为滤波器增益; $g'(\psi)$ 为聚光器增益; ψ_c 为 PD 的视场角; $\phi_{1/2}$ 为 LED 光源的半功率角,即在此角度上的 LED 光源辐射功率是中心功率的 $1/2$ ^[21]。

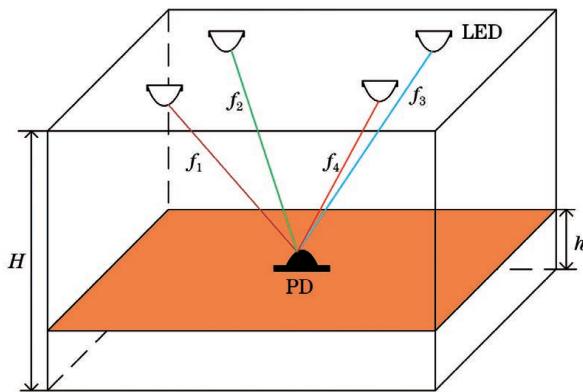


图 1 室内可见光定位模型

Fig. 1 Indoor visible light positioning model

当 LED 发射光功率为 P_t 时,接收器的接收功率 P_r 可以表示为

$$P_r = H_{\text{LOS}} \cdot P_t. \quad (3)$$

2.3 ELM

ELM 基于单层前馈神经网络(SLFN)通过不同的方法来分配网络的权值和阈值。换句话说,在 ELM 神经网络中,隐藏层的权重和阈值是随机初始化的,输

出层的权重通过最小二乘法(LSM)进行调整。由于其独特的训练过程,与传统的前馈神经网络相比,ELM 神经网络能够以更少的执行时间来解决回归预测问题。ELM 网络结构如图 2 所示。

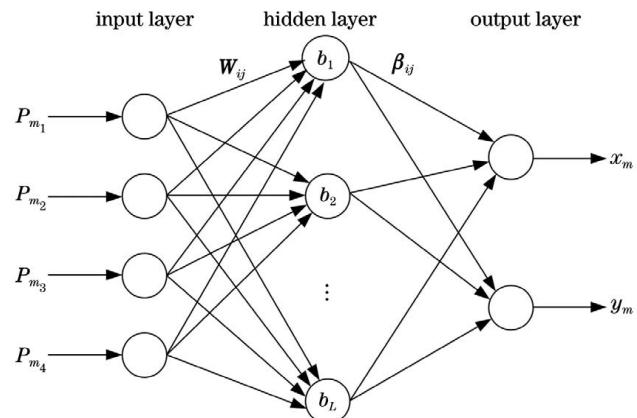


图 2 ELM 网络结构

Fig. 2 ELM network structure

图 2 中,ELM 神经网络的输入端为 4 个光功率值 $(P_{m_1}, P_{m_2}, P_{m_3}, P_{m_4})$, P_{m_u} ($u=1 \sim 4$) 表示第 m 个采样点处的 PD 接收到的第 u 个 LED 的光功率值,输出端是探测器的二维坐标点 (x_m, y_m) 。假设有 N 个任意样本 $(\mathbf{X}_i, \mathbf{y}_i)$, 其中 $\mathbf{X}_i = [x_{i_1}, x_{i_2}, \dots, x_{i_n}]^T \in \mathbf{R}^n$, $\mathbf{y}_i = [y_{i_1}, y_{i_2}, \dots, y_{i_n}]^T \in \mathbf{R}^m$, 则有 L 个隐藏层节点的单隐层神经网络可以表示为

$$\mathbf{f}_L(x) = \sum_{i=1}^L \boldsymbol{\beta}_i g(\mathbf{W}_i \cdot \mathbf{X}_i + \mathbf{b}_i), \quad (4)$$

$$\mathbf{X}_i \in \mathbf{R}^n, \mathbf{W}_i \in \mathbf{R}^n, \boldsymbol{\beta}_i \in \mathbf{R}^m,$$

式中: $\boldsymbol{\beta}_i$ 是连接隐藏层节点和输出层节点的输出权值

矩阵; $g(\cdot)$ 表示隐藏层输出函数; \mathbf{W}_i 和 \mathbf{b}_i 是随机分配的参数, 对应于神经元的激活功能; $\mathbf{W}_i \cdot \mathbf{X}_i$ 表示 \mathbf{W}_i 和 \mathbf{X}_i 的内积^[22]。

当测试样本数量与隐藏层神经元个数相等时, 存在 $\boldsymbol{\beta}_i, \mathbf{W}_i, \mathbf{b}_i$ 使

$$f_L(x) = \sum_{i=1}^L \boldsymbol{\beta}_i g(\mathbf{W}_i \cdot \mathbf{X}_i + \mathbf{b}_i) = \mathbf{y}_i, i = 1, 2, \dots, L. \quad (5)$$

式(5)可以写成

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}. \quad (6)$$

在 ELM 算法中, \mathbf{W}_i 和 \mathbf{b}_i 可以随机给定, \mathbf{H} 为神经网络隐藏层的输出矩阵。输出权值矩阵 $\boldsymbol{\beta}$ 可通过求解式(6)得到。

$$\tilde{\boldsymbol{\beta}} = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{C}\|, \quad (7)$$

其中 $\|\cdot\|$ 为范数, 可得

$$\tilde{\boldsymbol{\beta}} = \mathbf{H}^* \mathbf{C}, \quad (8)$$

式中: \mathbf{H}^* 表示隐藏层输出矩阵 \mathbf{H} 的伪逆; \mathbf{C} 表示测试目标的坐标。ELM 神经网络用于回归预测时, 其定位误差可以表示为

$$e_r = |\mathbf{C}_j - \mathbf{C}_i| = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2}, \quad (9)$$

式中: $\mathbf{C}_j = \{x_j, y_j\}_{j=1}^t$ 为测试目标估计值; $\mathbf{C}_i = \{x_i, y_i\}_{i=1}^t$ 为测试目标的真实位置; t 为测试目标数。

2.4 遗传算法的原理

遗传算法(GA)是在一个随机选择的种群上进行的进化过程, 该种群代表问题的解搜索空间。种

群由代表解决方案的个体组成, 这些个体由二进制符号组成。在遗传算法的进化过程中, 种群中的每个个体根据一个定义的代价函数记录其适应度度量。一个新的种群是由最高适应度的新个体组成的, 这使得它们有更好的机会在种群中繁殖新的个体。这个过程模仿了自然选择和自然进化, 有效改善了解决方案。在遗传算法的特征提取阶段, 需要选择最好的属性来表示问题的数据集, 这是由专门为问题定义的适应度函数决定的。适应度函数 F 的表达式为

$$F = k \left[\sum_{i=1}^{L_s} \text{abs}(y_i - o_i) \right], \quad (10)$$

式中: L_s 为个体样本数量; y_i 为 ELM 神经网络第 i 个个体的期望输出; o_i 为第 i 个个体的预测输出; k 为系数。

ELM 神经网络虽然能够对大部分测试点进行高精度定位, 但由于其自身的权值和阈值是随机产生的, 对定位系统的稳定性及定位精度有很大影响, 在实际应用中往往会出现过拟合现象。遗传算法的寻优功能能够找寻适应 ELM 神经网络的最优权值和阈值。寻优过程就是几个基于概率函数的最优点的选择过程, 可以有效解决 ELM 神经网络出现的过拟合现象。遗传算法的初始种群是随机产生的, 该算法同时对下一个群体的评价结果和最佳染色体进行选择。使用遗传算法进行调度包括几个必需的过程, 即确定个体、计算适应度值、生成早期种群、进行选择以及进行基因突变。具体流程如图 3 所示。

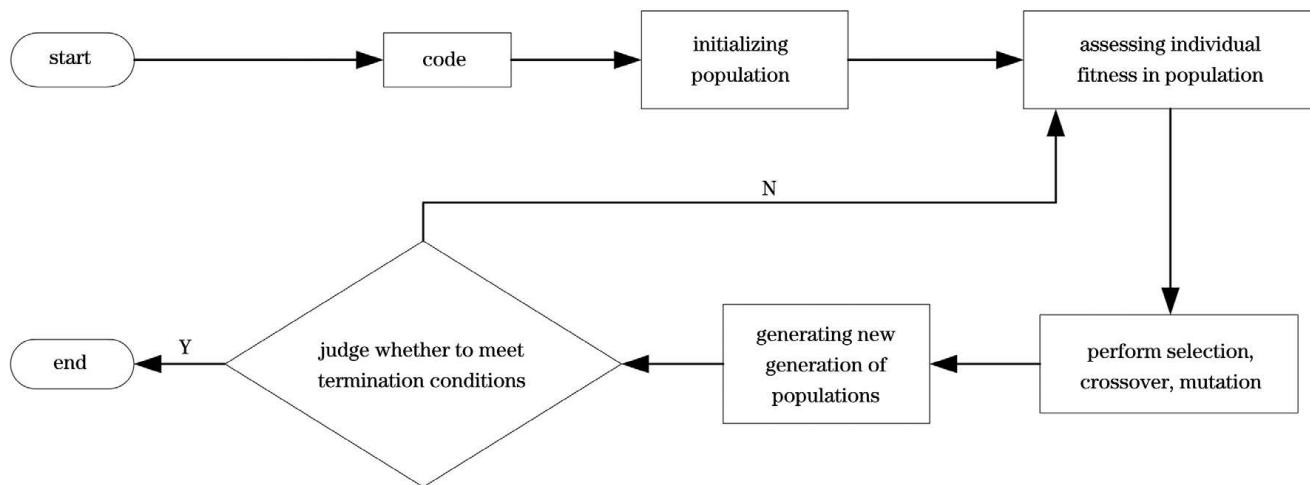


图 3 遗传算法流程图

Fig. 3 Genetic algorithm flow chart

2.5 GA-ELM 算法

本文提出的定位系统由一种特征选择方法和一种相对快速的 ELM 神经网络学习算法组成, 前者利用遗传算法对特征向量进行评估, 找到最优的向量个体, 然后将其赋给 ELM 神经网络。GA-ELM 算法的流程框图如图 4 所示。GA-ELM 算法实现步骤如下: 步

骤 1) 输入样本数据; 步骤 2) 将 ELM 神经网络随机生成的权值和阈值编码后作为遗传算法的初始种群; 步骤 3) 计算种群的适应度值; 步骤 4) 通过选择、交叉、变异操作找到最优适应度值对应的个体; 步骤 5) 经过迭代后, 找到最优个体, 并对其进行解码, 得到最适合该网络的权值和阈值; 步骤 6) 将最优权值和阈值赋给 ELM。

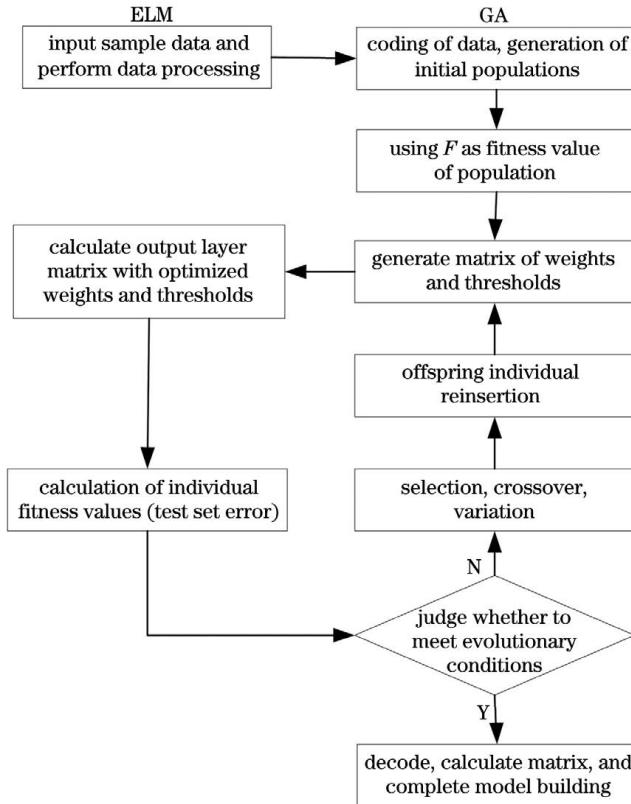


图 4 GA-ELM 算法流程图

Fig. 4 GA-ELM algorithm flow chart

3 仿真结果分析

3.1 仿真设计

本文选取的室内场景大小为 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$, 4 只 LED 灯悬挂在天花板上, 坐标分别为 $(1\text{ m}, 1\text{ m}, 3\text{ m})$ 、 $(1\text{ m}, 3\text{ m}, 3\text{ m})$ 、 $(3\text{ m}, 1\text{ m}, 3\text{ m})$ 、 $(3\text{ m}, 3\text{ m}, 3\text{ m})$, 接收器位于室内一定高度处。为了消除各 LED 灯之间的相互干扰, 分别为 4 只 LED 灯分配唯一的调制频率, 即 $3, 4, 5, 6\text{ kHz}$ 。接收器接收到混合信号之后, 将光信号转换成电信号, 然后采用带通滤波器对其进行区分, 并通过计算得到 4 只 LED 灯的光功率值。具体仿真参数如表 2 所示。

表 2 仿真参数

Table 2 Simulation parameters

Parameter	Value
Light source emission power /W	10
Receiver field of view $\psi_c/(\text{°})$	90
Filter gain $T_s(\psi)$	1
Concentrator gain $g(\psi)$	10
Effective receiving area of receiver / cm^2	1
Angle of half-power $\phi_{1/2}/(\text{°})$	30
Number of neurons	225
Population size	2
Chromosome length	1300
Maximum number of iteration	200
Crossover probability	0.7
Mutation probability	0.01

3.2 训练数据集的选取

作为神经网络的输入, 训练数据集对于整个系统的定位精度以及时效性起着重要作用。如果数据量过多, 系统的定位时间就会增加; 如果数据量过少, 系统的定位精度就会降低。鉴于此, 本团队选取 3 组仿真数据进行仿真测试, 选取的数据量分别为 11×11 组、 21×21 组、 41×41 组。仿真测试结果如表 3 所示。在系统各个参数设置都相同的情况下, 当训练数据集为 21×21 组时, 平均定位误差为 0.9214 cm , 定位时间为 0.04235 s ; 当训练数据集为 11×11 组时, 系统虽然具有良好的时效性, 但定位精度却大大降低; 当训练数据集为 41×41 组时, 系统的定位精度虽然很高, 但定位时效性变差。综合考虑, 选择 21×21 组训练数据集作为研究目标。

表 3 不同训练数据集的仿真结果

Table 3 Simulation results for different training data sets

Data set	Average localization error /cm	Localization time /s
11×11	74.6800	0.00215
21×21	0.9214	0.04235
41×41	0.9138	0.10940

3.3 GA-ELM 仿真结果分析

在 $4\text{ m} \times 4\text{ m} \times 3\text{ m}$ 的空间内, 将接收器放置在距地面不同高度($0.2, 0.4, 0.6, 0.8\text{ m}$)的位置处进行仿真。每个高度下选取 441 组训练指纹样本和 225 组测试样本, 整体定位结果如图 5 所示。图 5 中, 圆点代表实际位置, 方块代表预测位置。

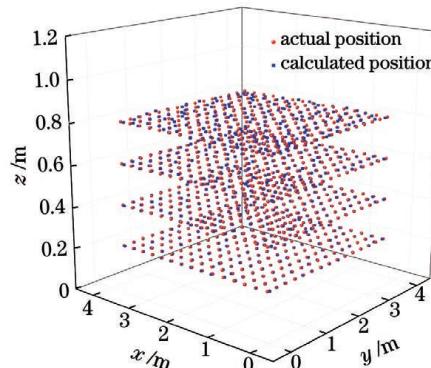


图 5 室内三维定位分布图

Fig. 5 Indoor three-dimensional localization distribution map

接收器在 $0.2, 0.4, 0.6, 0.8\text{ m}$ 测试高度时, 系统的预测坐标与实际坐标的对比如图 6 所示, 圆圈代表实际位置, 五角星代表预测位置。从图 6 可以直观地看出, 随着接收器高度增加, 预测位置与实际位置的偏差逐渐增大。

为了更加精确地评估系统的定位性能, 接下来进一步对系统进行定量分析。接收器位于不同高度时系统的定位误差如图 7 所示, 可以看出: 当高度为 0.2 m 时, 系统的最大定位误差为 6.86 cm , 平均定位误差为

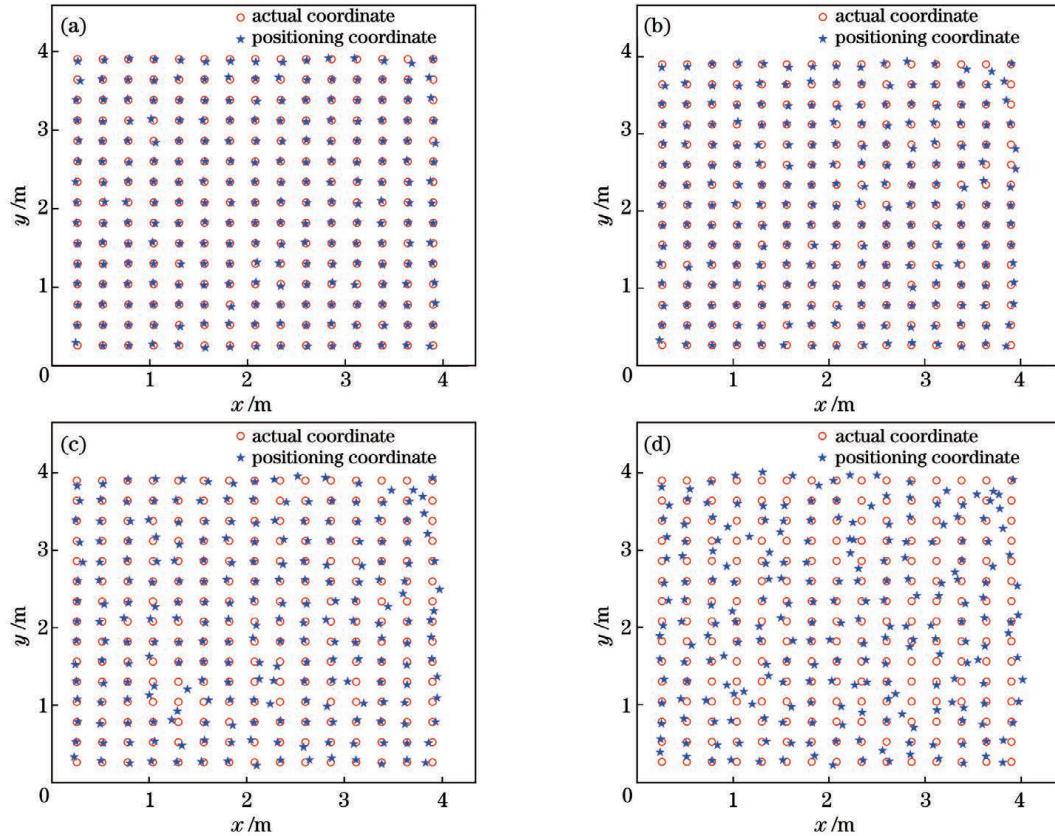


图 6 接收机在不同高度处时系统的预测坐标与实际坐标对比。(a) 0.2 m; (b) 0.4 m; (c) 0.6 m; (d) 0.8 m

Fig. 6 Actual coordinates versus system predicted coordinates when receiver is at different altitudes. (a) 0.2 m; (b) 0.4 m;
(c) 0.6 m; (d) 0.8 m

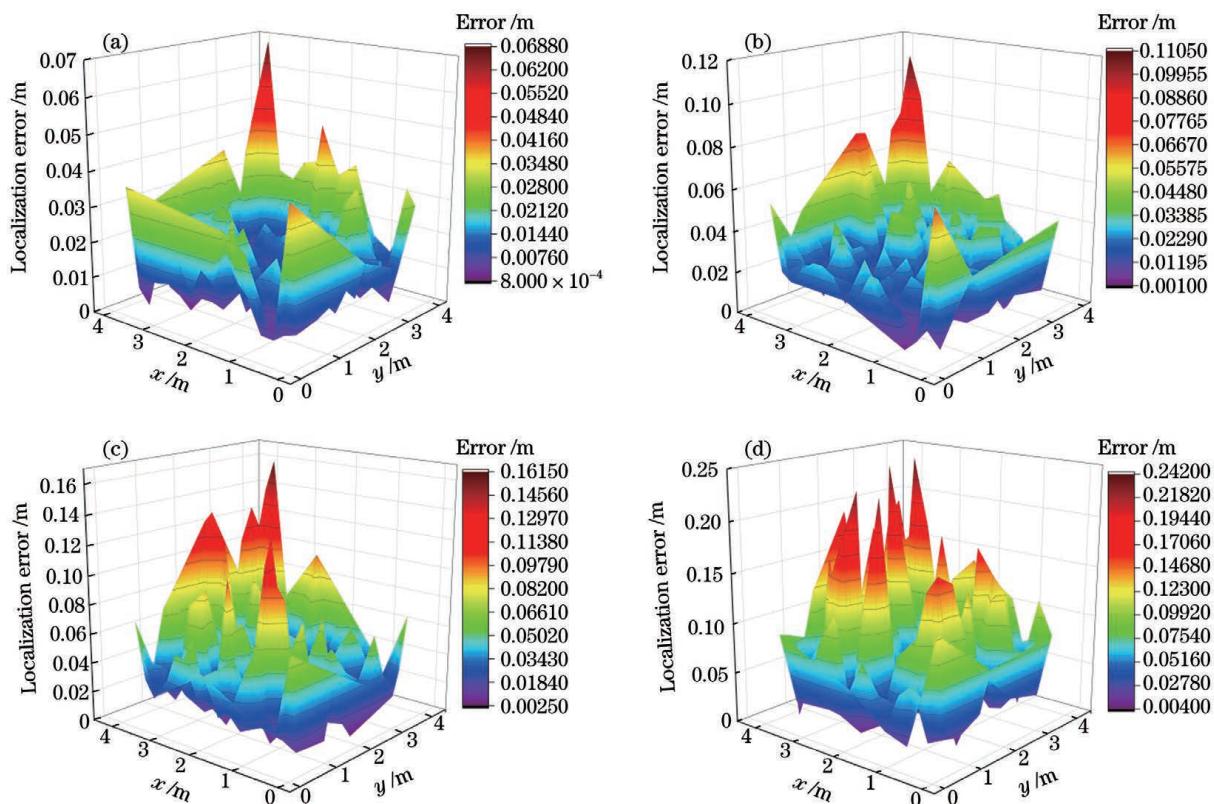


图 7 接收机在不同高度时系统的三维定位误差。(a) 0.2 m; (b) 0.4 m; (c) 0.6 m; (d) 0.8 m

Fig. 7 Three-dimensional localization error of system when receiver is at different altitudes. (a) 0.2 m; (b) 0.4 m;
(c) 0.6 m; (d) 0.8 m

1.39 cm; 当高度为 0.4 m 时, 系统的最大定位误差为 11.04 cm, 平均定位误差为 2.23 cm; 当高度为 0.6 m 时, 系统的最大定位误差为 16.41 cm, 平均定位误差为 3.75 cm; 当高度为 0.8 m 时, 系统的最大定位误差为 24.11 cm, 平均定位误差为 6.64 cm。

从上述数据中可以看出遗传算法优化 ELM 神经网络的定位精度可以达到厘米级, 能够较精确地实现室内可见光定位。

接收机位于不同高度时系统的定位误差累积分布如图 8 所示。从图 8 中可以明显看出, 随着接收器高度增加, 定位误差不断增大。这主要是由信道增益 H_{LOS} 的变化导致的。在发射端 LED 发射光功率不变的情况下, 随着接收器的高度不断增加, LED 灯的发射角 φ 和 PD 的入射角均逐渐增大, 由式(1)可知这会引起光信号衰减, 从而导致接收器接收到的光功率减小, 定位精度降低。

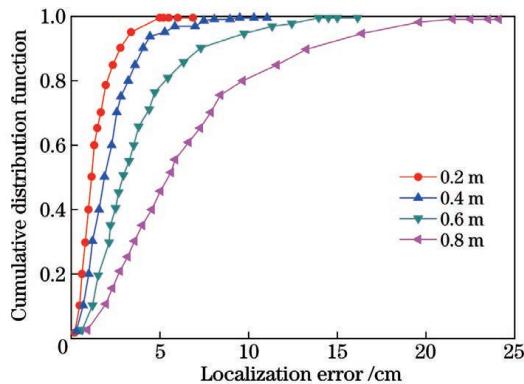


图 8 接收机在不同高度时系统的定位误差累积分布图

Fig. 8 Localization error cumulative distribution of the system when receiver is at different altitudes

4 实验及结果分析

4.1 实验系统

接下来在室内环境下验证本文所提基于遗传算法优化 ELM 神经网络的室内可见光定位系统(GA-ELM 系统)的有效性。实验场景如图 9(a)所示。考虑到边界区域定位误差较大, 将 4 只发射频率分别为 3、4、5、6 kHz 的 LED 灯安装在 4 m×4 m×3 m 定位区域的天花板上, 它们的位置坐标分别为(1 m, 1 m, 3 m)、(1 m, 3 m, 3 m)、(3 m, 1 m, 3 m)、(3 m, 3 m, 3 m), 同时用黑布将实验区域的四周包围, 以有效降低墙面反射光对边界区域定位误差的影响。接收端使用全新的进口 S1133 硅光电二极管作为光电检测器, 接收端设备如图 9(b)所示。如图 9(b)所示, 用放大器将光电二极管转化的电信号进行放大, 并通过带通滤波器对 4 只 LED 灯的光功率进行区分, 然后在示波器上读出该测试点处的电压值, 最后计算出 4 只 LED 灯的接收功率。

在本次实验中, 441 组训练点以 20 cm×20 cm 的间距将地面均匀划分, 225 组测试点以 26 cm×26 cm

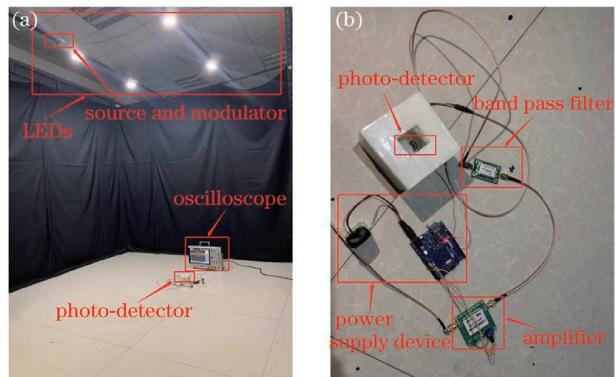


图 9 实验场景及接收端设备。(a)实验场景;(b)接收端设备

Fig. 9 Experimental scene and receiving end equipment.

(a) Experimental scene; (b) receiving end equipment

的间距均匀地放置在定位区域。为了减小光强波动对定位误差的影响, 在每个训练点及测试点处进行 5 次测量, 将 5 次测量的平均值作为该点的指纹数据。

4.2 结果及分析

本文选择了 225 组测试数据, 计算得到了 225 个定位点与预测点的定位误差。图 10 为定位误差分布图, 定位误差直方图如图 11 所示。从图 11 中可以看出, 定位误差主要集中在 0.7 cm, 定位误差在 2 cm 内的点占总测试点的 94.67%。

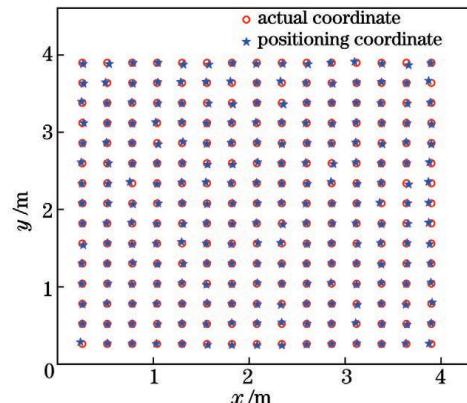


图 10 GA-ELM 的二维定位结果

Fig. 10 Two-dimensional localization results of GA-ELM

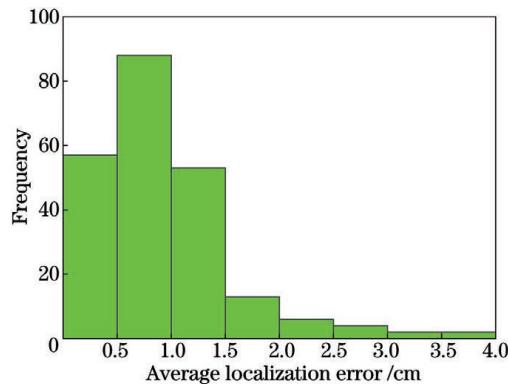


图 11 定位误差直方图

Fig. 11 Localization error histogram

为了进一步说明遗传算法对 ELM 算法的优化提高了系统的定位性能, 将 GA-ELM 与 ELM 算法(未

经遗传算法优化)的定位误差进行对比分析。图 12 给出了 GA-ELM 与 ELM 算法的定位误差累积分布图,从图中可以看出:GA-ELM 算法的最大定位误差为 3.95 cm,平均定位误差为 0.9214 cm,ELM 算法的最大定位误差为 13.24 cm,平均定位误差为 6.63 cm。与 ELM 算法相比,GA-ELM 算法的平均定位误差提升了 86.1%,最大定位误差提升了 70.16%。同时可以发现 GA-ELM 定位算法的平均定位误差已经达到了毫米级。

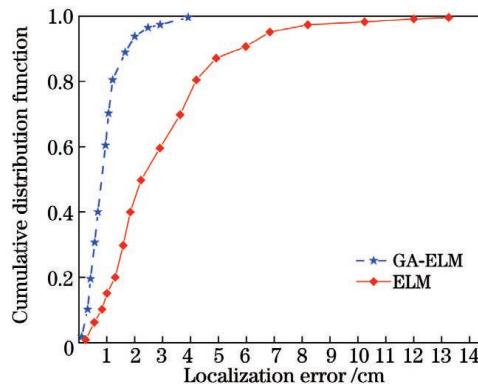


图 12 GA-ELM 算法与 ELM 算法的定位误差累积分布图

Fig. 12 Cumulative distribution of localization error of GA-ELM and ELM algorithms

除此之外,为了比较 GA-ELM 算法与 ELM 算法预测的稳定性,本文随机选取了两种算法的 10 次测试结果,计算每次预测结果的最大定位误差,然后计算两种算法估算最大定位误差的平均值和标准差。计算结果如表 4 所示。用标准差反映估算结果的离散程度,从而验证两种算法的稳定性。从表 4 可以看出:与 ELM 算法相比,GA-ELM 算法最大定位误差值的平均值及标准差都要小很多。这说明 GA-ELM 算法的稳定性及准确度较好。

表 4 随机 10 次估算结果的最大定位误差

Table 4 Maximum localization error for random 10 estimation results

No.	Maximum localization error /cm	
	GA-ELM	ELM
1	4.10	9.76
2	5.51	22.21
3	4.68	13.25
4	5.27	10.63
5	5.10	12.42
6	4.50	12.22
7	4.32	11.88
8	5.78	16.29
9	3.72	15.13
10	5.82	13.60
Average value /cm	4.88	13.34
Standard deviation /cm	0.72	3.55

接下来将本文算法与 BP 神经网络、支持向量机(SVM)、GA-BP 算法进行对比。表 5 给出了这几种算法的定位误差,可以看出,本文算法的最大定位误差及平均定位误差比另外三种算法要小很多:与 GA-BP 算法相比,本文算法的最大定位误差降低了 74.43%,平均定位误差降低了 75.23%;与 SVM 算法相比,本文算法的最大定位误差降低了 79.91%,平均定位误差降低了 75.36%;与 BP 算法相比,本文算法的最大定位误差降低了 93.49%,平均定位误差降低了 95.62%。这一结果表明,基于 GA-ELM 神经网络的定位算法具有更好的定位性能。

表 5 不同算法定位误差的比较

Table 5 Comparison of localization errors of different algorithms

Localization algorithm	Max localization error /cm	Average localization error /cm
GA-ELM	3.9192	0.9214
GA-BP	15.33	3.72
SVM	19.51	3.74
BP	60.18	21.04

4 种算法的定位误差累积分布如图 13 所示。从图 13 中可以看出,GA-BP、SVM 算法的定位误差与 GA-ELM 算法的定位误差相差较少,而 BP 算法的定位误差与 GA-ELM 算法的定位误差相差较多。

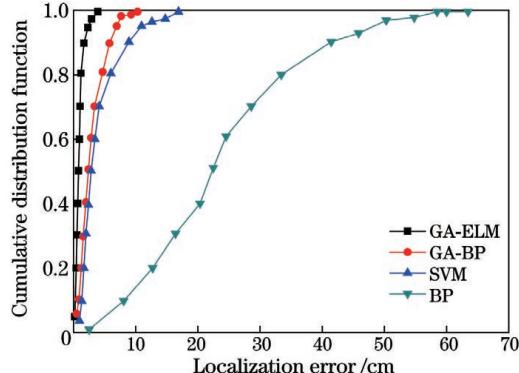


图 13 4 种算法的定位误差累积分布图

Fig. 13 Cumulative distribution of localization error of four algorithms

最后,本文对比分析了 GA-ELM 算法与其他三种算法的平均定位时间,以验证 GA-ELM 算法的时效性。对比结果如表 6 所示,可见:GA-ELM 算法的平

表 6 不同算法定位时效性的比较

Table 6 Comparison of localization timeliness of different algorithms

Localization algorithm	Average localization time /s
GA-ELM	0.04235
GA-BP	0.09237
SVM	0.09165
BP	0.09301

均定位时间为 0.04235 s。本文算法的定位时间约为 SVM、BP、GA-BP 算法的 1/2.2, 这说明本文算法在时效性方面更具优势。

5 结 论

本文采用遗传算法优化 ELM 神经网络的多 LED 灯定位系统实现了室内高精度定位。离线阶段, 在直射视距链路下, 测量 PD 的接收光功率值, 建立指纹数据库; 在线阶段, 将指纹数据引入优化好的 ELM 神经网络中, 完成定位。在 4 m×4 m×3 m 的空间内对定位算法进行性能仿真和实验测试。仿真结果表明, 本文采用的定位算法的平均定位误差随着接收器高度的增加而增大。实验结果表明: 本文采用的定位算法的平均定位误差为 0.9214 cm, 最大定位误差为 3.9192 cm, 与 ELM、GA-BP、SVM、BP 算法相比, 提高了定位精度, 具有更高的适用性。从近几年的国内外研究现状来看, 在不同的场景下, 采用基于深度学习算法的定位系统在定位精度方面均有不俗表现, 且具有较高的实用性。与国内外同类工作相比, 本文算法在定位精度上处于较高水平, 在系统的稳定性上也有不俗表现, 达到了先进水平。

采用遗传算法对 ELM 神经网进行优化, 不仅提高了多灯条件下室内定位的精度, 也有效解决了 ELM 网络结构稳定性差的问题, 但实验是在较理想的情况下完成的, 并没有考虑自然光等因素的影响, 这是该定位系统需要解决的一个问题。因此, 在后续的研究中会对系统进行进一步优化和改进, 使之适合在实际环境中应用。

参 考 文 献

- [1] Tan H C, Zhao W H, Qiu Q, et al. Green synthesis of nitrogen-doped fluorescent carbon quantum dots for selective detection of iron [J]. *Fullerenes, Nanotubes and Carbon Nanostructures*, 2017, 25(7): 417-422.
- [2] Akiyama T, Sugimoto M, Hashizume H. Time-of-arrival-based smartphone localization using visible light communication [C]// 2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN), September 18-21, 2017, Sapporo. New York: IEEE Press, 2017.
- [3] Chen Z, Wang J L. GROF: indoor localization using a multiple-bandwidth general regression neural network and outlier filter [J]. *Sensors*, 2018, 18(11): 3723.
- [4] Ma Y W, Chen J L, Chen Z Z. A high accuracy and efficiency indoor positioning system with visible light communication [J]. *Transactions on Emerging Telecommunications Technologies*, 2019, 30(2): e3452.
- [5] Mousa F I K, Almaadeed N, Busawon K, et al. Indoor visible light communication localization system utilizing received signal strength indication technique and trilateration method [J]. *Optical Engineering*, 2018, 57(1): 016107.
- [6] Qin L, Niu B, Li B S, et al. Indoor visible light high precision three-dimensional positioning algorithm based on single LED lamp [J]. *Optik*, 2020, 207: 163786.
- [7] Lain J K, Chen L C, Lin S C. Indoor localization using K-pairwise light emitting diode image-sensor-based visible light positioning [J]. *IEEE Photonics Journal*, 2018, 10 (6): 18278575.
- [8] Cai Y, Guan W P, Wu Y X, et al. Indoor high precision three-dimensional positioning system based on visible light communication using particle swarm optimization [J]. *IEEE Photonics Journal*, 2017, 9(6): 17363649.
- [9] Almadani Y, Ijaz M, Adeebi B, et al. An experimental evaluation of a 3D visible light positioning system in an industrial environment with receiver tilt and multipath reflections [J]. *Optics Communications*, 2021, 483: 126654.
- [10] 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.
- [11] 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算法 [J]. 光学学报, 2020, 40(18): 1806003.
- 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.
- [12] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 2012, 42(2): 513-529.
- [13] 陈勇, 巫杰, 刘焕淋, 等. 基于隐马尔可夫模型的可见光与惯导融合室内定位系统 [J]. 中国激光, 2020, 47(12): 1206001.
- Chen Y, Wu J, Liu H L, et al. Visible light and inertial navigation fusion indoor positioning system based on hidden Markov model [J]. *Chinese Journal of Lasers*, 2020, 47(12): 1206001.
- [14] Amsters R, Holm D, Joly J, et al. Visible light positioning using Bayesian filters [J]. *Journal of Lightwave Technology*, 2020, 38(21): 5925-5936.
- [15] 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 H Y, Yu H Y, Chen L L. Indoor visible light location using adaptive pollination receiving signal strength indication based on reverse learning strategy [J]. *Chinese Journal of Lasers*, 2021, 48(1): 0106001.
- [16] Shi C Q, Niu X, Li T, et al. Exploring fast fingerprint construction algorithm for unmodulated visible light indoor localization [J]. *Sensors*, 2020, 20(24): 7245.
- [17] Bakar A H A, Glass T, Tee H Y, et al. Accurate visible light positioning using multiple-photodiode receiver and machine learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 7500812.
- [18] Huang L, Gan X L, Yu B G, et al. An innovative fingerprint location algorithm for indoor positioning based on array pseudolite [J]. *Sensors*, 2019, 19(20): 4420.
- [19] Mao W C, Xie H Y, Tan Z Q, et al. High precision indoor positioning method based on visible light communication using improved Camshift tracking algorithm [J]. *Optics Communications*, 2020, 468: 125599.
- [20] Amsters R, Demeester E, Stevens N, et al. In-depth analysis of unmodulated visible light positioning using the iterated extended Kalman filter [J]. *Sensors*, 2019, 19(23): 5198.
- [21] 刘开华, 鄢书丹, 宫青霖. 基于稀疏训练点和指纹重构的室内可见光三维定位算法 [J]. 中国激光, 2021, 48(3): 0306003.
- Liu K H, Yan S D, Gong X L. Indoor 3D visible light positioning algorithm based on fingerprint reconstruction and sparse training nodes [J]. *Chinese Journal of Lasers*, 2021, 48(3): 0306003.
- [22] 徐岩, 王昕昕. 多层 ELM 分区域可见光室内定位算法 [J]. 湖南大学学报(自然科学版), 2019, 46(10): 125-132.
- Xu Y, Wang X X. Indoor positioning algorithm of subregional visible light based on multilayer ELM [J]. *Journal of Hunan University (Natural Sciences)*, 2019, 46(10): 125-132.

Indoor Visible Light Localization System Based on Genetic Algorithm-Optimized Extreme Learning Machine Neural Network

Qin Ling, Wang Dongxing, Shi Mingquan, Wang Fengying, Hu Xiaoli^{*}

School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010,
Inner Mongolia, China

Abstract

Objective Recently, with the advancement of science and technology, public desire for indoor positioning services has grown significantly. Thus, most researchers have turned their attention to indoor positioning technology. Visible light is harmless to the human body, does not interfere with other electronic devices, and has a low effect by multipath reflection; it can be employed as the information carrier of the indoor positioning system. Thus, visible light positioning is one of the most promising indoor positioning technologies. LED lights are frequently employed in indoor positioning studies because of their high cost performance, high broadband, and long service life. With the maturation of machine learning technology, the application of machine learning algorithms to indoor visible light localization has become the focus of several scholars' research, and good localization results have been obtained. To further enhance the accuracy and stability of indoor visible light localization, this study proposes an indoor visible light localization system based on a genetic algorithm-optimized extreme learning machine (ELM) neural network. The genetic algorithm can efficiently enhance the stability of the ELM neural network, which in turn improves the global localization accuracy.

Methods First, the fingerprint database was constructed. In this research, 441 sets of data were selected as the training set and 225 sets of data were employed as the test set. Second, the training set was employed as the ELM neural network input, which was fed into the neural network for training. Since the ELM neural network was prone to local optimum and instability, its weights and thresholds were sought out using a genetic algorithm during training, and the optimal weights and thresholds were found and assigned to the ELM neural network after selection, crossover, and variation operations. Then, the test set was sent into the trained neural network, which predicted coordinate points. Finally, the error between the actual and predicted locations was computed to examine the localization performance of the system.

Results and Discussions The average localization errors of the receiver were 1.39, 2.23, 3.75, and 6.64 cm at the test heights of 0.2, 0.4, 0.6, and 0.8 m, respectively, and the maximum localization errors were 6.86, 11.04, 16.41, and 24.11 cm, respectively. As the height of the receiver increases, the channel gain decreases because of the increasing emission angle of the LEDs as well as the reception angle of the receiver, which causes the optical signal to fade and decreases the optical power received by the receiver, thereby decreasing localization accuracy. In the experimental situation, the indoor localization system based on a genetic algorithm-optimized ELM neural network (GA-ELM) achieved an average localization error of 0.9214 cm and a maximum localization error of 3.9192 cm. Compared with the findings obtained from the indoor positioning system based on the ELM neural network, which show an improvement of 86.1% on the average localization error and 70.16% on the maximum localization error, the average localization error of the GA-ELM positioning algorithm reached the millimeter level. Furthermore, this research compares the algorithm with the BP neural network, support vector machine (SVM), and GA-BP algorithms. The maximum and average localization errors of the proposed algorithm are significantly smaller than those of the other three algorithms. Finally, the average localization time of the GA-ELM algorithm is compared with the other three algorithms to illustrate the timeliness of the GA-ELM algorithm, and the average localization time needed by the GA-ELM algorithm is 0.04235 s. Compared with the SVM, BP, and GA-BP algorithms, the localization time of the proposed algorithm is shortened dramatically, indicating that the proposed algorithm is better in terms of timeliness.

Conclusions In this research, a multi-LED light localization system with a genetic algorithm-optimized ELM neural network is employed to obtain indoor high-precision localization. The received optical power value of PD is measured through the direct line-of-sight link to establish the fingerprint database in the offline stage. In the online stage, the fingerprint data are introduced into the optimized ELM neural network to complete the localization. In this study, the performance simulation and experiments of the localization algorithm are performed in a space of $4\text{ m} \times 4\text{ m} \times 3\text{ m}$. The simulation findings reveal that the average localization error of the localization algorithm employed in this study increases as the receiver height increases, and the experimental findings reveal that the average localization error of the localization algorithm employed in this research is 0.9214 cm and the maximum localization error is 3.9192 cm, which is comparable

to ELM, GA-BP, SVM, and BP, improves the localization accuracy, and has broader range of application than ELM, GA-BP, SVM, and BP. From the domestic and international investigation studies over the past 1 or 2 years, there are substantial enhancements in localization accuracy using various localization algorithms in various environments, which are highly applicable. The investigation in this paper is at a high level in terms of localization accuracy, and a significant improvement is observed in the stability of the system.

Key words detectors; genetic algorithm; extreme learning machine; visible light localization; neural network; fingerprint database