

基于 Circle 混沌映射的 ISSA-ELM 神经网络室内可见光定位方法

赵霞, 张君毅*, 龙倩倩

北京邮电大学电子工程学院, 北京 100876

摘要 针对传统室内可见光定位精度较低、基于神经网络的室内可见光定位收敛速度慢且泛化能力弱等问题,提出一种结合基于 Circle 混沌映射的优化麻雀搜索算法-极限学习机(ISSA-ELM)神经网络和接收信号强度指示(RSSI)的室内可见光定位方法,在考虑天花板、墙壁和地板反射作用的情况下,将每个参考点处的 RSSI 和光电探测器的真实位置坐标作为训练集数据,对优化后的 ISSA-ELM 神经网络模型进行训练,建立室内可见光定位预测模型,并利用测试集对定位模型进行测试。仿真结果表明,优化后的 ISSA-ELM 神经网络的训练时间为 0.0454 s,平均定位时间为 3.5 ms,在 5 m×5 m×3 m 的室内环境,对位于 0、0.5、1.0、1.5 m 高度参考点的平均定位误差分别为 1.01、1.14、1.36、3.87 cm,相比极限学习机(ELM)神经网络的定位精度分别提高了 20.47%、19.72%、37.91%、42.32%。因此,所提的室内可见光定位方法具有定位速度快、定位精度高、系统性能稳定等优点。

关键词 光通信; Circle 混沌映射; 麻雀搜索算法; ELM 神经网络; 室内定位

中图分类号 TN929.1

文献标志码 A

DOI: 10.3788/AOS0206004

1 引言

随着第五代移动通信和物联网技术的迅猛发展以及公共室内环境数量的急剧增加,位置估计与追踪领域的研究表现出极大的现实意义^[1-3],目前主流定位系统为基于卫星通信的全球定位系统(GPS)^[4],但卫星信号传输会因障碍物的阻隔而中断,从而无法实现室内的精准定位。为解决这一问题,研究者提出了多种基于射频通信的室内无线定位技术,如 WiFi 定位^[5]、蓝牙定位^[6]、射频识别(RFID)^[7]、超宽带(UWB)定位^[8]、红外定位^[9]等技术,但射频通信存在频谱资源缺乏、抗干扰能力差、安全性低、成本高等缺点,而新兴的可见光通信(VLC)具有高速、环保、节能、安全、经济等性能优势,因而基于可见光通信的定位技术具有良好的应用前景,吸引了学界的广泛关注^[10]。

目前,室内可见光定位方法主要有三边测量法、场景分析法、邻近法、图像传感法等,其中基于接收信号强度指示(RSSI)的定位方法以高精度、低成本、无需时钟同步等优点被广泛应用^[11]。传统 RSSI 定位方法利用了可见光信道传输特性,将接收端的光照强度或光功率转换为发送端与接收端之间的距离,并利用圆周定位法和最小二乘法求解待定位点的坐标。然而传统 RSSI 定位方法的定位误差较大,不能完全满足实际

定位精度要求,对此,学界以传统 RSSI 定位方法为雏形,以提高定位精度为目的,提出了多种优化算法和改进方案。近年来,随着机器学习(ML)相关研究的深入,神经网络作为一种监督学习模型,表现出强大的非线性系统处理能力,已被应用到无线定位领域^[12],因此,基于神经网络的室内可见光定位研究成为大势所趋。Guan 等^[13]将人工神经网络与改进的遗传算法相结合,该系统仅利用人工神经网络预测光信号的传输距离,而定位坐标仍用最小二乘法计算。Zhang 等^[14]提出基于人工神经网络的 RSS/PDOA 混合三维室内可见光定位系统,在只考虑直射情况下提高了传统室内可见光定位系统在光信号强度变化下的鲁棒性,并降低了由建模不准确引起的失真。Zhang 等^[15]提出一种基于贝叶斯正则化的深度神经网络(BR-DNN)与稀疏对角训练数据集相结合的室内可见光定位技术,该技术在 LOS 链路下的平均定位精度小于 5 cm。秦岭等^[16-17]提出了基于极限学习机(ELM)神经网络的室内可见光定位方法,在单光源多接收器布局的房间内实现了平均定位误差为 7.13 cm、平均定位时间为 0.2400 s 的定位,在多光源单接收器布局的房间内实现了平均定位误差为 1.17 cm、平均定位时间为 0.0687 s 的定位。

以往基于神经网络的室内可见光定位研究多数只

收稿日期: 2022-06-06; 修回日期: 2022-07-02; 录用日期: 2022-07-21; 网络首发日期: 2022-07-31

通信作者: *zhangjy@bupt.edu.cn

考虑光线直射^[14-18],忽略了天花板、墙壁、室内物体等的反射作用。在实际环境中,光线除了直射到达接收器外,还会经过反射到达接收器,光的传播速度很快,在规模较小的室内环境,接收器很难辨别直射信号与反射信号,反射的存在会严重影响光信号传输,进而降低定位精度,如果还利用直射的思路考虑定位问题,无法满足实际需要。由于室内不同高度的光信号存在分布差异,定位误差会随着定位高度的改变而变化,不同高度的定位精度相差较大。同时,由于神经网络的初始权值和阈值的生成具有随机性,因此神经网络容易陷入局部最优,利用智能搜索算法确定神经网络的初始权值和阈值不仅能够克服局部最优问题,还能够加快网络的训练速度。

本文利用 Circle 混沌映射改进麻雀搜索算法^[19-20](SSA)优化 ELM 神经网络,在考虑天花板、墙壁和地面反射作用的情况下,提出一种结合基于 Circle 混沌映射优化的 ISSA-ELM 神经网络和 RSSI 的定位方法,实现了低时延、高精度的室内可见光定位。

2 室内可见光定位原理

2.1 室内可见光信道模型

室内可见光定位系统主要由 LED 光源、可见光信道和光电探测器(PD)三部分组成,在图 1 所示的直射(LOS)链路下,信号从光源直线传播到接收器,途中不受障碍物干扰。

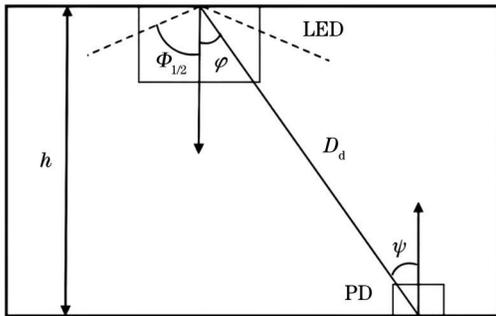


图 1 室内可见光通信信道直射链路传输模型

Fig. 1 Direct link transmission model of indoor visible light communication channel

可见光通信中的 LOS 链路的信道增益为

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

式中: m 为散射系数; A 为 PD 的面积; D_d 为光源到探测器的距离; φ 为光源的发散角; ψ 为 PD 的吸收角; $T_s(\psi)$ 为光滤波器增益; $g(\psi)$ 为聚光器增益; Ψ_c 为 PD 的最大视场角(FOV)。

散射系数 m 由 LED 的半功率强度角 $\Phi_{1/2}$ 决定,即

$$m = -\ln 2 / \ln(\cos \Phi_{1/2}). \quad (2)$$

聚光器增益 $g(\psi)$ 由材料折射率 n 和最大视场角 Ψ_c 决定,即

$$g(\psi) = \begin{cases} \frac{n^2}{\sin^2 \Psi_c}, & 0 \leq \psi \leq \Psi_c \\ 0, & \psi > \Psi_c \end{cases}. \quad (3)$$

实际 LED 信号在传输过程中可能会因反射形成非直射(NLOS)链路,本文考虑房间天花板、墙壁和地面的反射,将房间内 6 个表面分割成若干个独立的反射元,将 NLOS 链路分解为发射 LED 到反射元、反射元到反射元、反射元到接收元这三种 LOS 链路。由于高于三阶的反射响应已不足 LOS 链路响应的 1%,因此本文只考虑三次反射的情况,最终信道冲激响应为 LOS 链路和 NLOS 链路的信道增益总和,即

$$H(t_{\text{NLOS}}) = H_{\text{LOS}}(0) \cdot \delta\left(t_{\text{NLOS}} - \frac{D_d}{c}\right) + \int_{\text{walls}} H_{\text{NLOS}}(0) \cdot \delta\left(t_{\text{NLOS}} - \frac{D_{\text{NLOS}}}{c}\right) dt_{\text{NLOS}}, \quad (4)$$

式中: t_{NLOS} 为反射次数; D_{NLOS} 为光源经过各反射元之后到达探测器的距离; $\delta(\cdot)$ 为冲激函数; c 为光的传播速度。

假设 LED 光源的输出光功率为 P_t ,则 PD 接收到的光功率 P_r 为

$$P_r = H(t_{\text{NLOS}}) P_{t0}. \quad (5)$$

2.2 室内可见光定位模型

室内可见光定位模型如图 2 所示,其中, L 、 W 、 H 分别为房间的长、宽、高,LED $_i$ ($i=1, 2, \dots, M$) 为第 i 个 LED, h 为接收平面的高度, (x_k, y_k) 为训练集中第 k ($1 \leq k \leq N$) 个参考点的真实坐标, I_{RSSI_j} ($1 \leq j \leq M$) 为第 k 个参考点接收到的来自第 j 个 LED 光源信号的 RSSI, (x_t, y_t) 为测试集中第 t ($1 \leq t \leq T$) 个参考点的真实坐标, I_{RSSI_j} ($1 \leq j \leq M$) 为第 t 个参考点接收到的来自第 j 个 LED 光源信号的 RSSI。定位流程分为 3 个阶段:首先是 RSSI 数据采集,在房间天花板上布置 M 个 LED 光源,在接收平面利用 N 个 PD 分别接收并处理来自 M 个 LED 光源的光信号,得到 $N \times M$ 个接收功率作为 RSSI 数据;其次是神经网络训练,将 RSSI 数据作为神经网络的输入,对应 PD 的位置坐标作为神经网络的输出,训练神经网络并建立室内可见光定位的预测模型;最后是预测模型测试,利用定位误差对预测模型进行性能评估。

3 ISSA-ELM 神经网络室内可见光定位方法

3.1 基于 Cricle 混沌映射改进的 ISSA

SSA 是基于麻雀群体的捕食与反捕食行为的元启发式算法,麻雀种群包括发现者、跟随者、预警者三种角色,不同角色个体的行为以不同的位置更新方式

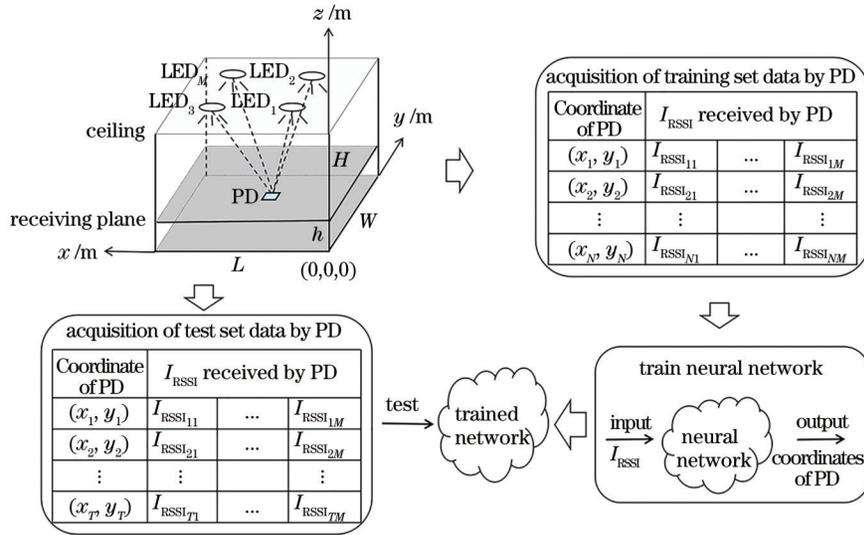


图 2 室内可见光定位模型
Fig. 2 Indoor visible light positioning model

模拟。

麻雀种群中发现者所占的比例为 10%~20%，位置更新公式为

$$X_{i,j}^{(t+1)} = \begin{cases} X_{i,j}^{(t)} \exp\left(-\frac{i}{\alpha \cdot i_{\max}}\right), & R_2 < S_T \\ X_{i,j}^{(t)} + QL, & R_2 \geq S_T \end{cases}, \quad (6)$$

式中：\$t\$ 为当前迭代数；\$i_{\max}\$ 为最大迭代次数；\$\alpha\$ 为 \$(0, 1]\$ 区间的随机数；\$R_2\$ 为安全值，\$R_2 \in [0, 1]\$；\$S_T\$ 为预警值，\$S_T \in [0.5, 1.0]\$；\$Q\$ 为服从正态分布的随机数；\$L\$ 为 \$1 \times d\$ 的矩阵，其中每个内部元素都为 1。

跟随者的位置更新公式为

$$X_{i,j}^{(t+1)} = \begin{cases} Q \exp\left[\frac{X_{\text{worst}} - X_{i,j}^{(t)}}{i^2}\right], & i > \frac{n}{2} \\ X_p^{(t+1)} + |X_{i,j}^{(t)} - X_p^{(t+1)}| A^+ L, & \text{otherwise} \end{cases}, \quad (7)$$

式中：\$X_{\text{worst}}\$、\$X_p^{(t+1)}\$ 分别为种群在第 \$t\$ 次迭代和第 \$t+1\$ 次迭代中处于第 \$j\$ 维最差位置与局部最优位置的个体；\$A\$ 表示内部元素为 1 或 -1 的多维矩阵。

预警者的位置更新公式为

$$X_{i,j}^{(t+1)} = \begin{cases} X_{\text{best}}^{(t)} + \beta |X_{i,j}^{(t)} - X_{\text{best}}^{(t)}|, & f_i > f_g \\ X_{i,j}^{(t)} + K \left[\frac{|X_{i,j}^{(t)} - X_{\text{worst}}^{(t)}|}{(f_i - f_w) + \epsilon} \right], & f_i = f_g \end{cases}, \quad (8)$$

式中：\$X_{\text{best}}^{(t)}\$ 为当前麻雀种群的全局最优位置的个体；\$\beta\$ 表示服从正态分布，均值为 0、方差为 1 的控制步长的参数；\$\epsilon\$ 为一个极小的常数，用于避免出现分母为 0 的情况；\$K \in [0, 1]\$ 用来控制麻雀的运动方向；\$f_i\$ 为当前个体 \$i\$ 的适应度值；\$f_g\$、\$f_w\$ 分别为当前麻雀种群的局部最优适应度值与最差适应度值。

SSA 在接近全局最优时，种群多样性程度降低，

容易陷入局部最优，为此对 SSA 中发现者的位置更新公式进行改进，即

$$X_{i,j}^{(t+1)} = \begin{cases} X_{i,j}^{(t)} \frac{c_1 [(u_b - l_b) c_2 + l_b]}{(1 + c_3) u_b}, & R_2 < S_T \\ X_{i,j}^{(t)} + Q, & R_2 \geq S_T \end{cases}, \quad (9)$$

式中：\$u_b\$ 和 \$l_b\$ 分别为解空间的上、下限值；\$c_1 = 2 \times \exp\left[-\left(\frac{4t}{i_{\max}}\right)^2\right]\$，可发挥全局搜索的作用；\$c_2\$ 和 \$c_3\$ 均为 \$[0, 1]\$ 区间的随机数。

此外，在初始化阶段随机生成麻雀个体的各个维度位置，容易造成麻雀个体局部聚集，因此引入 Circle 混沌映射来初始化麻雀种群，所用的混沌映射表达式为

$$x_{n+1} = \text{mod} \left\{ d_1 x_n + d_2 - \left[\frac{d_3}{d_1 \pi} \sin(d_1 \pi \cdot x_n) \right], 1 \right\}, \quad (10)$$

式中：\$n\$ 为解的维度；\$d_1\$、\$d_2\$、\$d_3\$ 为常数，可调整其取值来改变混沌映射的效果。

将基于 Circle 混沌映射和改进发现者位置更新公式后的 SSA 命名为优化的麻雀搜索算法 (ISSA)，图 3 所示为 ISSA 和 SSA 的寻优收敛曲线，可见优化后的麻雀搜索算法不易陷入局部最优，且具有更快的收敛速度。

3.2 ISSA 优化 ELM 神经网络

ELM 神经网络是一种典型的单隐层前向神经网络。与传统神经网络不同，ELM 神经网络随机初始化输入层到隐藏层的权值和隐藏层的阈值，并直接求解隐藏层到输出层的权值，因此 ELM 神经网络只需要设置隐藏层神经元的数量就能确定网络结构，避免了传统神经网络反复迭代的过程，极大地缩短了训练时间。ELM 神经网络结构如图 4 所示，输入层神经元输入信号，隐藏层神经元处理信号，输出层神经元输出信号。

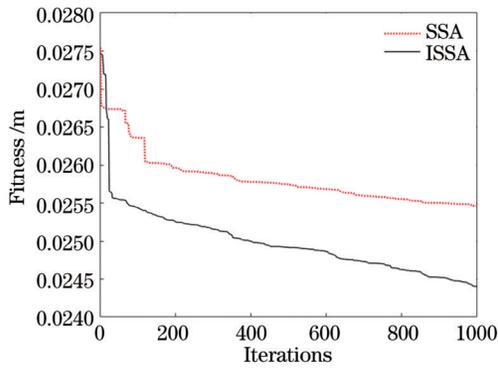


图 3 ISSA 和 SSA 的寻优收敛曲线
Fig. 3 Optimization convergence curves of ISSA and SSA

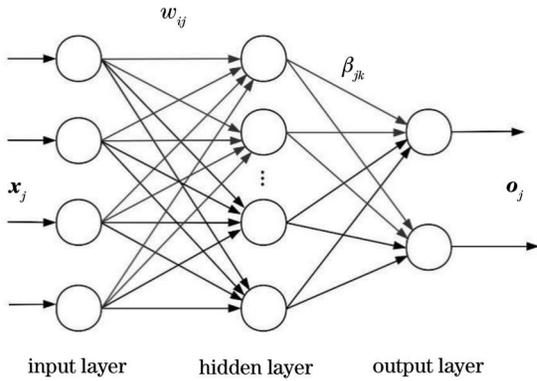


图 4 ELM 神经网络结构示意图
Fig. 4 Schematic of ELM neural network structure

ELM 神经网络的数学表达式为

$$o_j = \sum_{i=1}^L \beta_i g(\omega_i \cdot x_j + b_i), j = 1, \dots, K, \quad (11)$$

式中: x_j 为输入矩阵; ω_i 表示输入层第 i 个神经元和隐藏层间的连接权值矩阵; b_i 为第 i 个隐藏层的阈值矩阵; $g(\cdot)$ 为隐藏层神经元的激活函数; β_i 表示隐藏层第 i 个神经元和输出层间的连接权值矩阵; o_j 为输出矩阵; L 为隐藏层神经元的个数; K 为参考点总数。选取 sigmoidal 函数为激活函数, sigmoidal 函数的表达式为

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}. \quad (12)$$

若期望输出矩阵为 T , 则 ELM 神经网络的定位误差矩阵 e_{err} 可表示为

$$e_{\text{err}} = o_j - T. \quad (13)$$

使用 ISSA 优化 ELM 神经网络的初始权值和阈值, 避免参数的随机初始化对神经网络性能的影响, 提高网络训练阶段的收敛速度、增强网络的泛化性能。ISSA-ELM 神经网络综合 ELM 神经网络的强学习能力和 ISSA 的全局最优搜索能力, 将 ELM 神经网络的初始权值和阈值映射为 ISSA 种群中每个麻雀在不同维度的位置, 将 ELM 神经网络的均方根误差 (RMSE) 作为麻雀个体的适应度函数, 于是确定神经网络最优初始参数的问题即为选择最优麻雀的问题。ISSA-ELM 的算法流程如图 5 所示, 主要包括 ELM 神经网络初始化、SSA 寻优确定网络参数和 ELM 神经网络训练 3 个部分。具体的实现步骤如下:

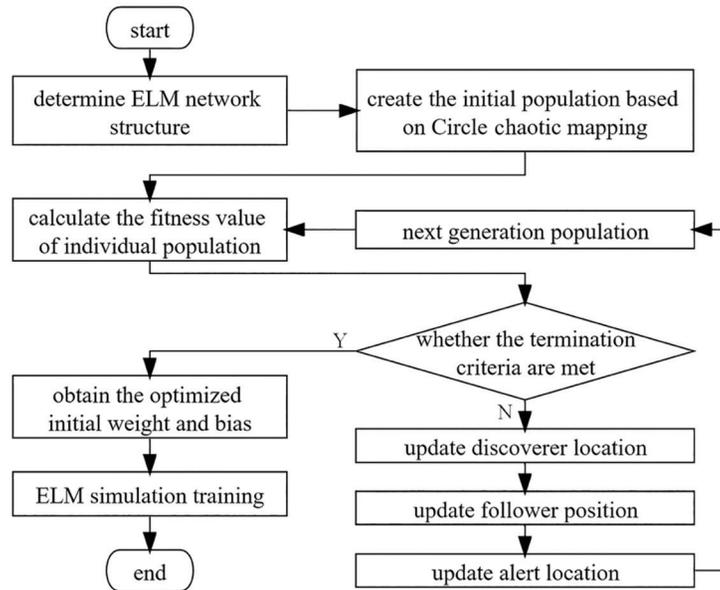


图 5 ISSA-ELM 的算法流程
Fig. 5 Algorithm flow of ISSA-ELM

1) 种群初始化。初始化 ELM 神经网络结构, 生成基于 Circle 混沌映射的麻雀初始种群, 个体的位置维度由 ELM 神经网络隐藏层输入权值与阈值的数量确定, 即 $D_{\text{in}} = (q + 1)L$, 其中 L 为隐藏层节点数, q 为输

入层神经元数量, 即输入向量维度。

2) 计算麻雀个体的适应度值。对于每一代麻雀种群中的任一个体, 计算 ELM 网络输出向量与参考向量的均方根误差, 并将其作为 ISSA 的目标函数。

3) 种群进化。根据麻雀个体的适应度,利用位置更新公式对个体进行优化,产生新的种群,直至满足约束条件,如达到最大进化代数或目标误差值时终止进化,得到最终的种群。

4) ELM 神经网络训练。将 ISSA 算法优化后的权值和阈值参数赋给 ELM 神经网络,使用训练集数据对 ELM 神经网络进行训练,得到网络预测模型。

3.3 创建数据集

在接收平面选取 N 个点作为训练集参考点,将参考点处接收并处理的来自 M 个 LED 光源的 RSSI 和对应参考点的坐标作为训练集数据,第 k ($1 \leq k \leq N$) 个参考点的训练数据为

$$D_k = F_k(k, x_k, y_k, I_{RSSI_{k1}}, I_{RSSI_{k2}}, \dots, I_{RSSI_{kM}}), \quad (14)$$

式中: (x_k, y_k) 为训练集中第 k 个参考点的真实坐标。

光源数量 M 决定了 ELM 神经网络的输入层神经元数量,神经网络输入矩阵为

$$I_{RSSI} = \begin{pmatrix} I_{RSSI_{11}} \\ I_{RSSI_{12}} \\ \vdots \\ I_{RSSI_{N1}} \\ I_{RSSI_{N2}} \\ \dots \\ I_{RSSI_{NM}} \end{pmatrix} = \begin{pmatrix} I_{RSSI_{11}} & I_{RSSI_{12}} & \dots & I_{RSSI_{1M}} \\ I_{RSSI_{21}} & I_{RSSI_{22}} & \dots & I_{RSSI_{2M}} \\ \vdots & \vdots & \ddots & \vdots \\ I_{RSSI_{N1}} & I_{RSSI_{N2}} & \dots & I_{RSSI_{NM}} \end{pmatrix}, \quad (15)$$

式中: $I_{RSSI_k} = (I_{RSSI_{k1}}, I_{RSSI_{k2}}, \dots, I_{RSSI_{kM}})$ 为训练集数据中第 k 个参考点接收的来自 M 个光源的 RSSI 值。

输出矩阵为

$$Q = \begin{pmatrix} Q_1 \\ Q_2 \\ \vdots \\ Q_N \end{pmatrix} = \begin{pmatrix} x_1 & y_1 \\ x_2 & y_2 \\ \vdots & \vdots \\ x_N & y_N \end{pmatrix}, \quad (16)$$

式中: $Q_k = (x_k, y_k)$ 为训练集数据中第 k 个参考点的真实坐标。

采用同样的方法,利用 $T \times M$ 的 RSSI 数据和 T 个参考点的真实坐标创建测试集数据。

4 仿真与分析

4.1 系统参数选取

为了评估基于 ISSA-ELM 神经网络定位方法的性能,首先利用 MATLAB 软件进行建模和仿真,将每个接收平面均匀分割成边长为 0.2 m 的 625 个网格,以其中 26×26 个格点作为参考点,将参考点的 RSSI 值和参考点坐标作为训练集数据来训练 ISSA-ELM 神经网络,建立室内可见光定位方法的预测模型。然后,选取和训练集参考点不同的 11×11 个参考点,将这些点的 RSSI 值和坐标作为测试集数据,测试得到的预测模型的性能,仿真参数如表 1 所示。

使用均方根误差函数 E_{RMSE} 和平均定位误差函数 $e_{error,av}$ 来评估定位系统的定位性能,它们的计算公式为

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{k=1}^N [(x_k - \hat{x}_k)^2 + (y_k - \hat{y}_k)^2]}, \quad (17)$$

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

Parameter	Value
Room size ($L \times W \times H$) / (m × m × m)	5 × 5 × 3
Position of LED _{<i>i</i>} (x, y, z) / m	LED ₁ : (1, 1, 3)
	LED ₂ : (1, 4, 3)
	LED ₃ : (4, 1, 3)
	LED ₄ : (4, 4, 3)
Power of each LED bulb / W	4
FOV of LED / (°)	90
Half-power angles of LED $\Phi_{1/2}$ / (°)	60
Effective area of PD A / cm ²	1
Gain of optical filter $T_s(\psi)$	1
Height of receiver / m	0, 0.5, 1.0, 1.5
Data transmission rate R / (Gbit·s ⁻¹)	1
Ceiling reflectance ρ_{ceil}	0.8
Wall reflectance ρ_{wall}	0.8
Floor reflectance ρ_{floor}	0.3
Sparrow population number	30
Early warning value S_T	0.6
Proportion of discoverers	0.2
Maximum iterations	1000

$$e_{error,av} = \frac{1}{N} \sum_{k=1}^N \sqrt{(x_k - \hat{x}_k)^2 + (y_k - \hat{y}_k)^2}, \quad (18)$$

式中: (x_k, y_k) 和 (\hat{x}_k, \hat{y}_k) 分别为训练集中的第 k 个参考点的真实坐标和预测坐标。

为找到使得定位效果最佳的隐藏层神经元数量,仿真了接收器高度 h 分别为 0、0.5、1.0、1.5 m 的 4 个接收平面,得到的 ELM 神经网络的定位 RMSE 随隐藏层神经元数量的变化曲线如图 6 所示。可以看出:当隐藏层神经元数量较少时, RMSE 随神经元数量的增加而减小;当神经元数量增加到 300 时, RMSE 不再减小,且几乎保持稳定。因此仿真采用的 ELM 神经网络隐藏层神经元数量为 300 个。

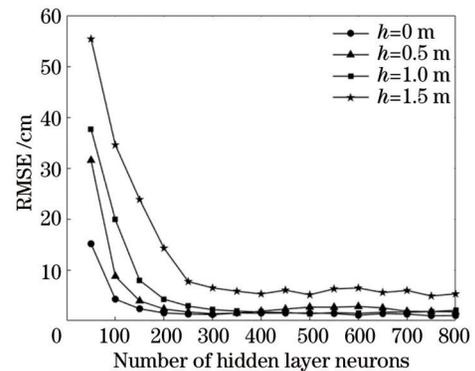


图 6 RMSE 与 ELM 神经网络隐藏层神经元个数的关系
Fig. 6 Relationship between RMSE and the number of neurons in the hidden layer of ELM neural network

4.2 定位结果分析

为测试所提定位方法在 PD 位于不同高度情况下的定位精度, 分别在 $h=0\text{ m}$ 、 $h=0.5\text{ m}$ 、 $h=1.0\text{ m}$ 和 $h=1.5\text{ m}$ 这 4 个接收平面选取训练集和测试集对神

经网络进行训练和测试, 得到的 11×11 个测试点和预测结果分布如图 7 所示, 定位误差分布如图 8 所示, 并在表 2 中记录最大、最小和平均定位误差。可以看到, 所提方法在 4 个接收高度的平均误差分别为 1.01、

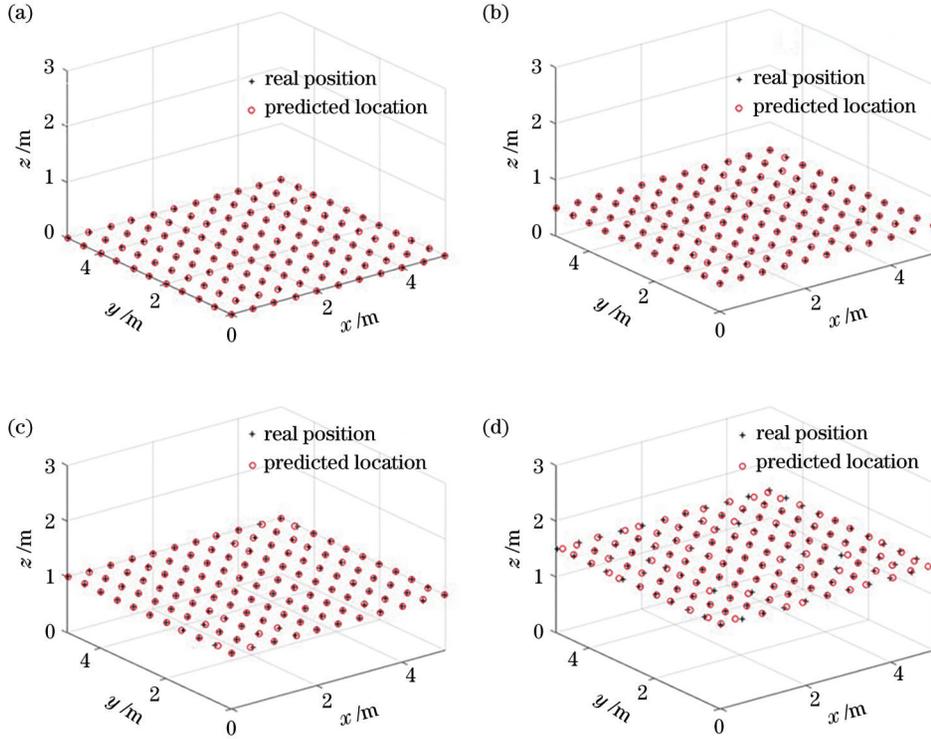


图 7 不同高度下接收平面的测试点和预测结果分布。(a) $h=0\text{ m}$; (b) $h=0.5\text{ m}$; (c) $h=1.0\text{ m}$; (d) $h=1.5\text{ m}$

Fig. 7 Distribution of test points and predicted results for different height receiving planes. (a) $h=0\text{ m}$; (b) $h=0.5\text{ m}$; (c) $h=1.0\text{ m}$; (d) $h=1.5\text{ m}$

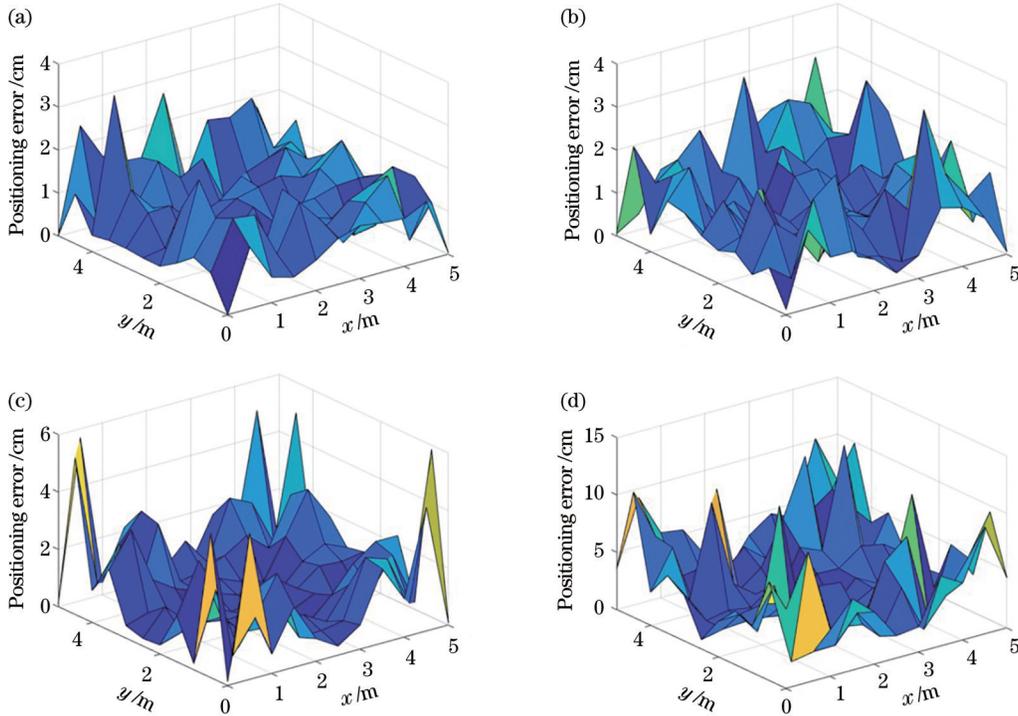


图 8 不同高度下接收平面的定位误差分布。(a) $h=0\text{ m}$; (b) $h=0.5\text{ m}$; (c) $h=1.0\text{ m}$; (d) $h=1.5\text{ m}$

Fig. 8 Distribution of positioning errors for different height receiving planes. (a) $h=0\text{ m}$; (b) $h=0.5\text{ m}$; (c) $h=1.0\text{ m}$; (d) $h=1.5\text{ m}$

表 2 不同高度下接收平面的最大、最小和平均定位误差

Table 2 Maximum, minimum, and average positioning errors for different height receiving planes

Receiving plane height h / m	0	0.5	1.0	1.5
Maximum positioning error / cm	3.50	3.60	5.31	12.79
Minimum positioning error / cm	8.8654×10^{-3}	5.9007×10^{-2}	9.9912×10^{-2}	0.3600
Average positioning error / cm	1.01	1.14	1.36	3.87

1.14、1.36、3.87 cm, 最大定位误差分别为 3.50、3.60、5.31、12.79 cm, 所有测试点的定位结果都较为精确, 能够满足室内定位的需求。

数据结果显示, 0~1.5 m 的平均定位误差逐渐增大, 在 1.0~1.5 m 范围内尤为显著, 这是因为随着接收高度的增加, 接收平面不同位置的接收功率值差异逐渐增大, 训练集数据的相似性逐渐减弱, 在神经网络训练时表现为同类数据集规模减小, 同时所提的 ISSA-ELM 神经网络隐藏层神经元数量较多, 神经网络训练容易出现过拟合, 导致测试集测试结果误差变大。对于室内定位系统而言, 需要考虑整体性能, 所提方法在接收器高度为 0~1.5 m 的范围内, 所得到的平均定位误差都小于 5 cm, 具有较高的定位精度。

将所提 ISSA-ELM 神经网络定位方法与使用三边测量、传统反向传播(BP)神经网络、基于 L-M 算法的 BP 神经网络、GA-BP 神经网络、SSA-BP 神经网络、ELM 神经网络、SSA-ELM 神经网络等的定位方法进行比较。为使 BP 神经网络展现最优的效果, 其隐藏层神经元数量设置为 50, 表 3 记录了使用包括所提方

法在内的 8 种定位方法在 4 个不同高度接收平面的平均定位误差。与传统的三边测量法、BP 神经网络定位方法和基于 L-M 算法的 BP 神经网络定位方法相比, 所提 ISSA-ELM 神经网络定位方法的定位精度提高了 90% 以上; 与 SSA-BP 神经网络定位方法相比, 在 $h=0$ m、 $h=0.5$ m、 $h=1.0$ m 和 $h=1.5$ m 4 个接收平面, 所提定位方法的定位精度分别提高了 30.34%、30.06%、48.48% 和 45.42%; 与 ELM 神经网络定位方法相比, 所提定位方法的定位精度分别提高了 20.47%、19.72%、42.86%、42.32%。由此可见, 所提 ISSA 算法具有明显的优化作用, 通过与其他 7 种定位方法的定位误差进行对比, 发现 ISSA-ELM 神经网络定位方法在定位精度方面表现出极大的优势。

为了更加直观地展示定位效果, 以接收器高度 $h=1.5$ m 为例, 所提方法和其他 7 种方法的测试点和预测结果分布如图 9 所示。同时, 图 10 展示了定位精度较高 (<10 cm) 的 GA-BP、SSA-BP、ELM、SSA-ELM、ISSA-ELM 神经网络定位方法的定位误差累计概率分布。可以看到, 所提定位方法的 90% 定位点误

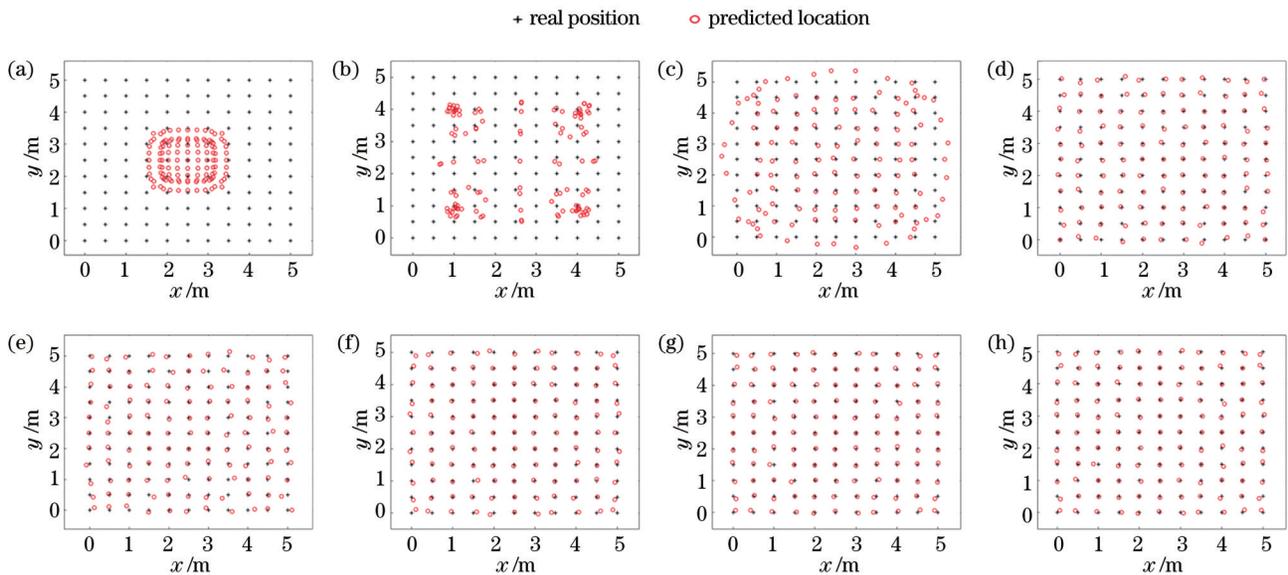


图 9 接收器高度为 1.5 m 时 8 种定位方法的测试点和预测结果分布。(a) 三边测量法; (b) BP 神经网络定位方法; (c) 基于 L-M 的 BP 神经网络定位方法; (d) GA-BP 神经网络定位方法; (e) SSA-BP 神经网络定位方法; (f) ELM 神经网络定位方法; (g) SSA-ELM 神经网络定位方法; (h) ISSA-ELM 神经网络定位方法

Fig. 9 Distribution of test points and prediction results of eight positioning methods when the receiver height is 1.5 m. (a) Trilateral measurement method; (b) positioning method using BP neural network; (c) positioning method using BP neural network based on L-M; (d) positioning method using GA-BP neural network; (e) positioning method using SSA-BP neural network; (f) positioning method using ELM neural network; (g) positioning method using SSA-ELM neural network; (h) positioning method using ISSA-ELM neural network

表 3 8 种定位方法在不同高度接收平面的平均定位误差
Table 3 Average positioning errors of eight positioning methods at different height receiving planes

Positioning method	Average positioning error /cm			
	$h=0$	$h=0.5\text{ m}$	$h=1.0\text{ m}$	$h=1.5\text{ m}$
Trilateration	124.24	123.18	125.14	132.38
BP	22.84	26.83	44.66	74.66
BP(L-M)	13.10	14.11	15.46	18.03
GA-BP	1.66	1.93	3.12	7.25
SSA-BP	1.45	1.63	2.64	7.09
ELM	1.27	1.42	2.38	6.71
SSA-ELM	1.20	1.33	2.10	4.59
ISSA-ELM	1.01	1.14	1.36	3.87

差小于 7.32 cm, 而 GA-BP、SSA-BP、ELM、SSA-ELM 这 4 种定位方法的 90% 定位误差分别小于 14.17、11.62、10.54、9.23 cm, 可见所提 ISSA-ELM 定位方法的整体定位误差更小。

表 4 对比了包括 ISSA-ELM 在内的 7 种神经网络定位方法的训练时间和平均定位时间, 可以看出: BP 神经网络训练时间较长, 即使利用 L-M、GA、SSA 等算法对其进行优化, 其训练时间仍大于 20 s, 该量级的延时是实际应用无法接受的; ELM 神经网络的训练时间为 0.0700 s, 其性能远优于 BP 神经网络, 利用 ISSA 优化后的 ELM 神经网络训练时间仅为 0.0454 s, 相比 ELM 降低了 35.14%。由此可见, ISSA-ELM 神经网络在训练时间方面具有明显的优势。此外, ISSA-ELM 神经网络定位方法的平均定位时间为 3.5 ms, 定位延时短, 符合实际定位需求。

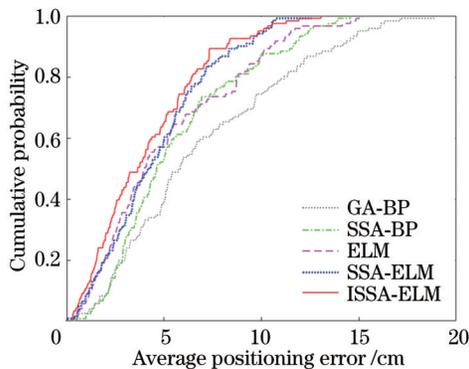


图 10 接收器高度为 1.5 m 时不同定位方法的定位误差累积分布
Fig. 10 Cumulative distribution of positioning errors of different positioning methods when the receiver height is 1.5 m

5 结 论

提出一种基于 Circle 混沌映射优化的 ISSA-ELM 神经网络室内可见光定位方法。该方法首先利用 ISSA 算法确定 ELM 神经网络的初始权值和阈值, 有效避免了由权值和阈值的随机初始化带来的神经网络

表 4 7 种神经网络定位方法的训练时间和平均定位时间
Table 4 Training time and average positioning time of seven positioning methods based on neural network

Positioning method	Training time /s	Average positioning time /s
BP	67.0620	0.4356
BP(L-M)	52.6223	0.2416
GA-BP	38.6951	0.0592
SSA-BP	23.5812	0.0157
ELM	0.0700	0.0071
SSA-ELM	0.0480	0.0038
ISSA-ELM	0.0454	0.0035

泛化能力弱的问题, 一定程度上加快了 ELM 神经网络的训练速度; 其次在考虑房间内部天花板、墙壁和地面反射的情况下, 搭建基于 ISSA-ELM 神经网络的室内可见光定位系统, 在 5 m×5 m×3 m 的房间内实现了神经网络训练时间为 0.0454 s、平均定位时间为 3.5 ms、平均定位误差小于 4 cm 的低延时、高精度的室内可见光定位; 最后, 将所提的 ISSA-ELM 方法与其他 7 种经典室内可见光定位方法进行比较, 结果表明, 所提定位方法的定位性能优越, 在 0、0.5、1.0、1.5 m 这 4 个高度, 所提方法的定位误差相比 ELM 神经网络分别提高了 20.47%、19.72%、37.91%、42.32%, ISSA 算法起到了明显的优化作用。综上, 所提方法定位速度快、定位精度高, 能够满足室内大多数应用场景的定位需求。

参 考 文 献

- [1] Hassan N U, Naeem A, Pasha M A, et al. Indoor positioning using visible LED lights: a survey[J]. ACM Computing Surveys, 2015, 48(2): 20.
- [2] Rahman A B M M, Li T, Wang Y. Recent advances in indoor localization via visible lights: a survey[J]. Sensors, 2020, 20(5): 1382.
- [3] Zhuang Y, Hua L C, Qi L N, et al. A survey of positioning systems using visible LED lights[J]. IEEE Communications Surveys & Tutorials, 2018, 20(3): 1963-1988.
- [4] Kaplan E D, Hegarty C J. Understanding GPS: principles and applications[M]//Understanding GPS: principles and applications. Norwood: Artech House Publishers, 2005: 1-19.
- [5] Liu F, Liu J, Yin Y Q, et al. Survey on WiFi-based indoor positioning techniques[J]. IET Communications, 2020, 14(9): 1372-1383.
- [6] Faragher R, Harle R. Location fingerprinting with bluetooth low energy beacons[J]. IEEE Journal on Selected Areas in Communications, 2015, 33(11): 2418-2428.
- [7] Zou H, Wang H T, Xie L H, et al. An RFID indoor positioning system by using weighted path loss and extreme learning machine [C]//2013 IEEE 1st International Conference on Cyber-Physical Systems, Networks, and Applications, August 19-20, 2013, Taipei, China. New York: IEEE Press, 2013: 66-71.
- [8] Liu F, Zhang J X, Wang J, et al. An UWB/vision fusion scheme for determining pedestrians' indoor location[J]. Sensors, 2020, 20(4): 1139.
- [9] Raharijaona T, Mawonou R, Nguyen T V, et al. Local positioning system using flickering infrared LEDs[J]. Sensors,

- 2017, 17(11): 2518.
- [10] Do T H, Yoo M. An in-depth survey of visible light communication based positioning systems[J]. *Sensors*, 2016, 16(5): 678.
- [11] Liu H, Darabi H, Banerjee P, et al. Survey of wireless indoor positioning techniques and systems[J]. *IEEE Transactions on Systems, Man, and Cybernetics C*, 2007, 37(6): 1067-1080.
- [12] Tran H Q, Ha C. Machine learning in indoor visible light positioning systems: a review[J]. *Neurocomputing*, 2022, 491: 117-131.
- [13] 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.
- [14] 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.
- [15] Zhang H Q, Cui J H, Feng L H, et al. High-precision indoor visible light positioning using deep neural network based on the Bayesian regularization with sparse training point[J]. *IEEE Photonics Journal*, 2019, 11(3): 7903310.
- [16] 秦岭, 张崇泰, 郭瑛, 等. 基于 Elman 神经网络的可见光室内定位算法研究[J]. *光学学报*, 2022, 42(5): 0506002.
Qin L, Zhang C T, Guo Y, et al. Research on visible light indoor localization algorithm based on Elman neural network[J]. *Acta Optica Sinica*, 2022, 42(5): 0506002.
- [17] 秦岭, 王东星, 王凤英, 等. 基于极限学习机神经网络的室内可见光定位方法[J]. *激光与光电子学进展*, 2022, 59(3): 0304002.
Qin L, Wang D X, Wang F Y, et al. Indoor visible light positioning method based on extreme learning machine neural network[J]. *Laser & Optoelectronics Progress*, 2022, 59(3): 0304002.
- [18] 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 H Y, Yu H Y, Wang K, 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.
- [19] Xue J K, Shen B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [20] 宋立钦, 陈文杰, 陈伟海, 等. 基于混合策略的麻雀搜索算法改进及应用[J/OL]. *北京航空航天大学学报*: 1-16[2022-06-03]. <https://doi.org/10.13700/j.bh.1001-5965.2021.0629>.
Song L Q, Chen W J, Chen W H, et al. Improvement and application of hybrid strategy-based sparrow search algorithm[J/OL]. *Journal of Beijing University of Aeronautics and Astronautics*: 1-16[2022-06-03]. <https://doi.org/10.13700/j.bh.1001-5965.2021.0629>.

Indoor Visible Light Positioning Method Using ISSA-ELM Neural Network Based on Circle Chaotic Mapping

Zhao Xia, Zhang Junyi*, Long Qianqian

School of Electronic Engineering, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract

Objective With the rapid development of the fifth-generation (5G) mobile communication and Internet of Things (IoT) technologies and the dramatic increase in the number of public indoor environments, research in the field of location estimation and tracking has shown great practical significance. The current mainstream global positioning system (GPS) and other various indoor wireless positioning technologies based on radio frequency communication cannot realize indoor precision positioning. Visible light communication (VLC) has attracted widespread attention from the academic community because of its performance advantages such as spectrum without authentication, high speed, environmental protection, energy saving, safety, economy. Therefore, visible light positioning technology has a broad application prospect. Specifically, the positioning method based on received signal strength indication (RSSI) is widely used for indoor visible light positioning with the advantages of high accuracy, low cost, and no clock synchronization. In recent years, research on machine learning (ML) and neural networks has developed rapidly, and various optimization algorithms and improvement schemes for indoor visible positioning have been proposed by integrating neural networks and RSSI positioning methods. Most of the previous studies on indoor visible light positioning based on neural networks only consider direct light and ignore the reflection of ceilings, walls, and indoor objects. In the actual environment, the existence of reflection will seriously affect the transmission of light signals and thus reduce the positioning accuracy, which cannot meet the actual needs when direct radiation is used to consider the positioning problem. At the same time, due to the difference in the distribution of light signals at different heights in the room, the height of a receiver will also directly affect the positioning accuracy and positioning error. In addition, the randomness of the initial weights and thresholds of the neural network can easily make the neural network fall into a local optimum. Using the intelligent search algorithm to determine the initial weights and thresholds of the neural network can both solve this problem well and accelerate the training speed of the network. In summary, this paper uses Circle chaotic mapping to improve the sparrow search

algorithm (SSA) and optimize the extreme learning machine (ELM) neural network, and the paper proposes a positioning method combining ISSA-ELM neural network and RSSI based on Circle chaotic mapping optimization to achieve indoor visible light positioning with low latency and high accuracy. This method has taken into account the role of ceiling, wall, and ground reflections.

Methods This study establishes an indoor visible light positioning model based on ISSA-ELM neural network and divides the positioning process into three stages. The first stage is the RSSI data acquisition stage, which establishes an indoor visible light positioning channel model based on the principle of VLC, arranges multiple LED light sources on the ceiling of the room, and uses multiple photoelectric detectors (PDs) in the receiving plane to receive and process RSSI signals from each LED light source respectively, and the real coordinates of the receiver are combined to determine the training set and test set of the neural network. The second stage is the neural network training stage. In this paper, we use an optimized ISSA based on Circle chaotic mapping optimization to determine the initial weights and thresholds of the ELM neural network, and the optimized SSA is not easy to fall into a local optimum and has a faster convergence speed. The neural network training uses the training set collected in the first stage, takes the RSSI data as the input of the neural network and the position coordinates corresponding to the PDs as the output of the neural network, trains the neural network, and establishes a prediction model for indoor visible light positioning. The third stage is the prediction model testing stage, in which the RSSI data are used as the input of the neural network using the test set selected in the first stage, and the predicted coordinates of the neural network are compared with the real coordinates of the test points, and the performance of the prediction model is evaluated using the positioning error and root mean square error function.

Results and Discussions In this study, the neural network is trained and tested by selecting training and testing sets in four receiving planes with a height of 0 m, 0.5 m, 1.0 m, and 1.5 m, respectively, and the average errors of the four receiving heights are 1.01 cm, 1.14 cm, 1.36 cm, and 3.87 cm, respectively. The maximum positioning errors are 3.50 cm, 3.60 cm, 5.31 cm, and 12.79 cm, which can meet the demand for indoor positioning. Comparing the ISSA-ELM neural network positioning method proposed in this paper with the traditional three-sided measurement method, BP neural network, and that based on the L-M algorithm, the positioning accuracy is improved by more than 90%. At four different receiving planes with different heights, the ISSA-ELM neural network positioning method improves the positioning accuracy by 30.34%, 30.06%, 48.48%, and 45.42%, respectively, compared with the SSA-BP neural network, and it improves the positioning accuracy by 20.47%, 19.72%, 42.86%, and 42.32%, respectively, compared with the ELM neural network. The ISSA-ELM neural network positioning method shows great advantages in terms of positioning accuracy. By comparing the cumulative probability distribution of positioning errors of different methods, it is found that 90% of the positioning points of the positioning method proposed in this paper have an error of less than 7.32 cm, and the overall positioning error is significantly lower than that of other methods. In addition, the training time of the optimized ELM neural network using ISSA is only 0.0454 s, which is 35.14% lower than that of ELM, and thus the method has obvious advantages in terms of training time. The average positioning time of the ISSA-ELM neural network positioning method is 3.5 ms, which indicates a low positioning delay and meets the actual positioning requirements.

Conclusions In this study, an ISSA-ELM neural network-based indoor visible light positioning method is proposed. The method firstly uses the ISSA algorithm to determine the initial weights and thresholds of the ELM neural network, which effectively avoids the problem of the weak generalization ability of the neural network brought by random initialization of weights and thresholds and speeds up the training speed of the ELM neural network to some extent. Secondly, considering the reflection of ceilings, walls, and floors inside the room, an indoor visible light positioning system based on the ISSA-ELM neural network is built. In a room of 5 m × 5 m × 3 m, it achieves low latency and high accuracy positioning with a neural network training time of 0.0454 s, average positioning time of 3.5 ms, and average positioning error of less than 4 cm. Finally, the ISSA-ELM method proposed in this paper is compared with seven other classical indoor visible light positioning methods. The results show that the positioning performance of the proposed method is superior, and the positioning error is reduced by 20.47%, 19.72%, 37.91%, and 42.32% in terms of four heights of 0 m, 0.5 m, 1.0 m, and 1.5 m, respectively, compared with the ELM neural network. The ISSA algorithm plays an obvious optimization role. In summary, the method proposed in this paper has fast positioning speed and high positioning accuracy, which can meet the positioning requirements of most indoor application scenarios.

Key words optical communications; Circle chaotic mapping; sparrow search algorithm; ELM neural network; indoor positioning