

多层 ELM 分区域可见光室内定位算法

徐岩,王昕昕[†]

(天津大学 电气自动化与信息工程学院,天津 300072)

摘要:在漫反射光信道中,可见光室内定位受一阶反射、噪声信号等的影响,边界区域的定位误差相比内部区域较大,针对此问题,提出一种基于多层极限学习机的分区域定位算法,并通过仿真实验验证了算法的有效性.首先,对整体的实验区域建立第 1 层极限学习机神经网络,计算出整体的定位误差.其次,根据定位误差的大小和分布特征建立第 2 层极限学习机神经网络,将整体实验区域划分为边界区域和内部区域.对提取出的边界区域建立第 3 层极限学习机神经网络,计算出边界区域的定位误差.最后将边界区域的定位误差更新到整体的定位误差中,以实现定位.实验结果表明,该算法的整体平均定位误差为 2.79 cm.与接收信号强度算法和反向传播神经网络相比,该算法的平均定位误差分别降低了 13 倍和 55.36%.与单层极限学习机算法相比,边界区域的平均定位误差降低了 65.66%,整体的平均定位误差降低了 23.77%.该算法边界区域的定位误差明显降低,具有更高的定位精度和鲁棒性能,可适用于不同的定位场景.

关键词:室内定位系统;可见光通信;极限学习机;分区域;接收信号强度

中图分类号:TN929.1

文献标志码:A

Indoor Positioning Algorithm of Subregional Visible Light Based on Multilayer ELM

XU Yan, WANG Xinxin[†]

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: In a diffuse optical channel, the visible light indoor positioning is affected by first-order reflection and noise, and thus the positioning error in boundary region is relatively larger than that in interior region. To solve this problem, a positioning algorithm of subregional visible light indoor based on multilayer Extreme Learning Machine (ELM) was proposed in this paper, and the effectiveness of the proposed algorithm was verified by simulation experiments. Firstly, the first layer ELM based on the entire experimental region was established to calculate the entire positioning error. Secondly, the second layer ELM based on the magnitude and distribution characteristics of positioning error was established, and the entire experimental region was divided into boundary subregion and interior subregion. Thirdly, the third layer ELM based on the extracted boundary subregion was established to calculate the boundary positioning error. Lastly, the entire error with updated boundary error was used to realize the positioning. The experimental results show that the entire average positioning error of the proposed algorithm is 2.79 cm. Com-

* 收稿日期:2018-10-22

基金项目:国家自然科学基金资助项目(61372145), National Natural Science Foundation of China(61372145);青海省 2017 年基础研究计划项目(2017-ZJ-753), Fundamental Research Projects of Qinghai Province in 2017(2017-ZJ-753)

作者简介:徐岩(1977—),女,辽宁大连人,天津大学副教授,博士

[†] 通讯联系人, E-mail: wangxinxin@tju.edu.cn

pared with the Received Signal Strength(RSS) and Back Propagation(BP) neural networks, the average positioning error is reduced by 13 times and 55.36%, respectively. Compared with the single-layer ELM, the boundary average positioning error is reduced by 65.66%, the entire average positioning error is reduced by 23.77%. Experimental results indicate that the boundary positioning error of the proposed algorithm is obviously decreased, which means the proposed algorithm has higher positioning accuracy and robustness, and is suitable for various positioning applications.

Key words: indoor positioning systems; visible light communication; extreme learning machine; divided region; received signal strength

随着位置服务的发展,室内定位成了热门的研究领域.全球定位系统(Global Positioning System, GPS)广泛应用于室外定位,定位精度可达到几米,但在室内不能满足定位需求^[1].目前有许多技术应用于室内定位,如无线(Wireless Local Area Network, WLAN)、超宽带(Ultra-wideband, UWB)、射频识别(Radio Frequency Identification, RFID)等^[2],但这些技术存在定位精度不高、电磁干扰及设备昂贵等问题.基于发光二极管(Light Emitting Diode, LED)的可见光通信(Visible Light Communication, VLC)可用于数据通信、智能交通系统、定位等领域,具有成本低、不受限制的可见光频谱资源、无电磁干扰等优点.相对于其他的定位技术^[3],基于VLC的室内定位得到了发展.

根据接收端的不同,可见光室内定位技术分为基于光电探测器(Photodetector, PD)和基于图像传感器(Image Sensor, IS)的定位.当PD为接收端时,基础的定位方法有接收信号强度法(Received Signal Strength, RSS)、到达角度差法(Angle Difference of Arrival, ADOA)、到达时间差法(Time Difference of Arrival, TDOA)^[4-6]等.当IS为接收端时,利用LED在传感器上的成像和图像测量原理进行定位^[7-10].因此,从系统设备和定位精度综合考虑,采用了以PD为接收端,利用RSS进行定位.

文献[11]提出了基于VLC的异步定位算法,利用RSS和线性最小二乘法估计发送端和接收端的距离,但只考虑了视距传播的情况.文献[12]提出了在漫反射光信道中,基于反向传播(Back Propagation, BP)神经网络的可见光定位算法,建立RSS和位置的训练测试模型进行定位,但边界区域定位误差较大.文献[13]针对边界定位误差大的问题,提出了边界校正算法,在最小二乘法得到发送端和接收

端的距离中引入测量误差,利用牛顿迭代算法使距离误差的残差函数足够小,提高了整体的平均定位误差.

在此基础上,本文提出了一种基于多层极限学习机(Extreme Learning Machine, ELM)的分区域可见光室内定位算法.首先利用ELM回归算法对整体的实验区域建立第1层神经网络,进行整体的定位.针对边界区域定位误差大的问题,将整体实验区域划分为边界区域和内部区域,利用ELM分类算法建立第2层神经网络.将提取出来的边界区域利用ELM回归算法建立第3层神经网络,计算出边界区域的定位误差.将边界区域误差进行更新,以得到最终的定位.实验结果表明,建立3层神经网络,可提高整体的定位精度.

1 系统模型

可见光通信利用可见光信号在空间传播传递信息.发送端将LED的位置信息通过调制、编码以及对LED进行驱动,将电信号转换为光信号.在接收端,光信号通过光学集中器、滤波器和PD将光信号转换为电信号,通过解调解码得到发送端LED的位置.基于LED的可见光定位利用LED的位置信息以及PD接收到的功率相对发送端功率的变化实现接收端PD的定位.本文提出的算法用于定位阶段.

假设可见光在空间传播符合朗伯发射模型,存在视距传播、一阶反射、二阶反射等形式.视距传播的影响远大于反射传播的影响,且二阶反射在光信道中的脉冲响应所占比例较低,可忽略不计^[14].光信道的直流增益 $H(0)$ 表示为:

$$H(0) = \begin{cases} \frac{(m+1)A}{2\pi D_1^2} \cos^m(\phi) T_s(\psi) g(\psi) \cos(\psi), & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases} \quad (1)$$

式中: A 为 PD 的物理面积; m 为朗伯阶数; D_1 为发送端和接收端之间的距离; ϕ 和 ψ 分别为发送端的辐射角和接收端的入射角; ψ_c 为接收端的视场角; $T_s(\psi)$ 为光学滤波器的增益; $g(\psi)$ 为光学集中器的增益,其可表示为:

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

式中: n 为折射指标.

光信道一阶反射的直流增益 $H_{\text{ref}}(0)$ 表示为:

$$H_{\text{ref}}(0) = \begin{cases} \frac{(m+1)A}{2\pi^2 D_1^2 D_2^2} \rho dA_{\text{wall}} \cos^m(\phi) \cos(\alpha) \\ \cos(\beta) g(\psi) T_s(\psi) \cos(\psi), & 0 \leq \psi \leq \psi_c \\ 0, & \psi > \psi_c \end{cases} \quad (3)$$

式中: D_1 为发送端到反射点间的距离; D_2 为反射点到接收端的距离; ρ 为反射因子; dA_{wall} 为反射区域的面积; ϕ 和 α 分别为反射点的辐射角和入射角; β 和 ψ 分别为接收端的辐射角和入射角.

当 PD 接收到光信号时,能够将光功率转换为电功率,电功率表示为:

$$P_{\text{rs}} = \{RP_1[H(0) + H_{\text{ref}}(0)]\}^2 + \sigma_{\text{noise}}^2 \quad (4)$$

式中: R 为接收端 PD 的响应度; P_1 为 LED 的发射功率; σ_{noise}^2 为总噪声方差,包含热噪声方差和散粒噪声方差.散粒噪声方差和接收端接收功率相关,假设背景电流来自直射太阳光^[14],将这两项噪声均假设为加性高斯白噪声 (Additive White Gaussian Noise, AWGN)^[15].在对 LED 进行调制时,当速率为 200 kbps 时,码间串扰很小可以忽略^[15].各噪声方差可表示为:

$$\sigma_{\text{noise}}^2 = \sigma_{\text{thermal}}^2 + \sigma_{\text{shot}}^2 \quad (5)$$

$$\sigma_{\text{thermal}}^2 = \frac{8\pi k T_k}{G} \eta A I_2 B^2 + \frac{16\pi^2 T_k \Gamma}{g_m} \eta^2 A^2 I_3 B^3 \quad (6)$$

$$\sigma_{\text{shot}}^2 = 2qR_p P_r B + 2qI_{\text{bg}} I_2 B \quad (7)$$

式中: $\sigma_{\text{thermal}}^2$ 为热噪声方差; σ_{shot}^2 为散粒噪声方差; k 为玻尔兹曼常数; T_k 为绝对温度; G 为开环电压增益; η 为 PD 上每单位面积的固定电容; I_2 为噪声带宽因子; P_r 为接收的光功率; B 为等效噪声带宽; q 为电荷量; I_{bg} 为背景电流; Γ 为 FET 信道噪声因子;

g_m 为 FET 跨导.故系统的信噪比可表示为:

$$\text{SNR} = 101 \lg \frac{P_r^2}{\sigma_{\text{noise}}^2} = 101 \lg \frac{\{RP_1[H(0) + H_{\text{ref}}(0)]\}^2}{\sigma_{\text{noise}}^2} \quad (8)$$

式中: P_r^2 为接收端的信号功率.

2 算法

2.1 ELM 算法

ELM^[16-17] 是基于单隐藏层前馈神经网络 (Single-hidden Layer Feedforward Neural Networks, SLFNs) 的算法,该算法由输入层、隐藏层、输出层组成.随机产生输入层和隐藏层间的连接权值矩阵和隐藏层神经元的阈值矩阵,且在训练过程中保持不变.只需要设置隐藏层的个数和隐藏层神经元间的激活函数,通过计算隐藏层的输出矩阵及其广义逆矩阵,便可求得隐藏层和输出层间的连接权值矩阵,进而求得输出,SLFNs 可以无限逼近训练样本.该算法具有设置参数少,训练时间短,学习速度快,良好的泛化性能等优点,可用于分类和回归拟合^[18].

假设具有 N 个训练样本 $(\mathbf{x}_i, \mathbf{t}_i)$, 其中 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^m$, n 和 m 分别为输入层和输出层神经元的个数.具有 L 个隐藏层节点的标准 SLFNs 表达式为:

$$\sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + \mathbf{b}_i) = \mathbf{o}_j, j = 1, \dots, N \quad (9)$$

式中: $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ 表示输入层第 i 个神经元和隐藏层间的连接权值矩阵; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 表示隐藏层第 i 个神经元和输出层间的连接权值矩阵; \mathbf{b}_i 是第 i 个隐藏层神经元的阈值矩阵.当激活函数无限可微时,具有 L 个隐藏层节点的标准 SLFNs 可以零均值误差逼近 N 个训练样本,即

$$\sum_{i=1}^L \|\mathbf{o}_j - \mathbf{t}_j\| = 0 \quad (10)$$

$$\sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + \mathbf{b}_i) = \mathbf{t}_j, j = 1, \dots, N \quad (11)$$

上式可表示为矩阵的形式:

$$\mathbf{H}\beta = \mathbf{T} \quad (12)$$

式中: \mathbf{H} 为隐藏层神经元的输出矩阵; β 为隐藏层神经元与输出层神经元之间的连接权值矩阵; \mathbf{T} 为期望输出矩阵.

隐藏层与输出层间的连接权值矩阵 β 可通过求解以下方程组的最小二乘解获得:

$$\min_{\beta} \|\mathbf{H}\beta - \mathbf{T}\| \quad (13)$$

其解为:

$$\hat{\beta} = H^+T \quad (14)$$

式中: H^+ 为隐藏层输出矩阵 H 的广义逆矩阵. 进一步求得输出:

$$o_j = H\hat{\beta} \quad (15)$$

当 ELM 神经网络用于回归时, 定位误差表示为:

$$err = |o_j - T| \quad (16)$$

当 ELM 神经网络用于分类时, 对应的类标为:

$$label(x) = \arg \max_{1 \leq i \leq m} (o_i) \quad (17)$$

式中: m 为样本的类别总数.

2.2 基于多层 ELM 的分区域可见光定位算法

可见光信号在传播过程中, 随着距离的增加信号会逐渐衰减, 在边界处信号强度较弱, 而一阶反射和噪声信号在边界处的信号强度较强, 从而相对内部区域, 边界区域的一阶反射和噪声信号对直射信号的影响较大, 故边界处定位误差较大. 针对边界区域存在的此问题, 将整体实验区域划分为边界区域和内部区域, 采用 3 层神经网络进行定位, 进一步提高整体的定位效果.

总的算法流程图如图 1 所示. 第 1 层神经网络对整体实验区域进行初步定位. 首先根据上述的光

信道增益, 利用 PD 采集来自每一个 LED 的总电功率, 将总电功率归一化到 $[-1, 1]$ 区间, 以归一化的电功率为输入, 对应的位置坐标为输出, 建立训练和测试样本集数据 1. 利用 ELM 回归算法对训练样本 1 建立神经网络模型, 将测试样本 1 输入到训练好的神经网络中以实现对接收端的定位, 分别根据式(16)计算训练和测试样本的定位误差.

第 2 层神经网络利用 ELM 分类算法实现了整体区域的划分. 综合考虑第 1 层神经网络得到的训练和测试样本的定位误差大小和分布特征, 将靠近墙体且定位误差大于平均定位误差的区域定义为边界区域, 其他区域定义为内部区域, 其可表示为:

$$I(err) = \begin{cases} 1, & \text{if } err > ave \\ 0, & \text{if } err < ave \end{cases} \quad (18)$$

式中: ave 为样本的平均定位误差. 划分区域流程图如图 2 所示. 将第 1 层神经网络训练阶段 PD 采集的总电功率和位置坐标归一化后作为输入, 边界区域和内部区域的分类作为输出, 即为训练样本集 2, 建立神经网络模型. 将第 1 层神经网络测试阶段 PD 采集的总电功率和位置坐标归一化后作为输入, 分类作为输出, 建立测试样本集 2, 输入到该神经网络中, 根据式(17)实现分类.

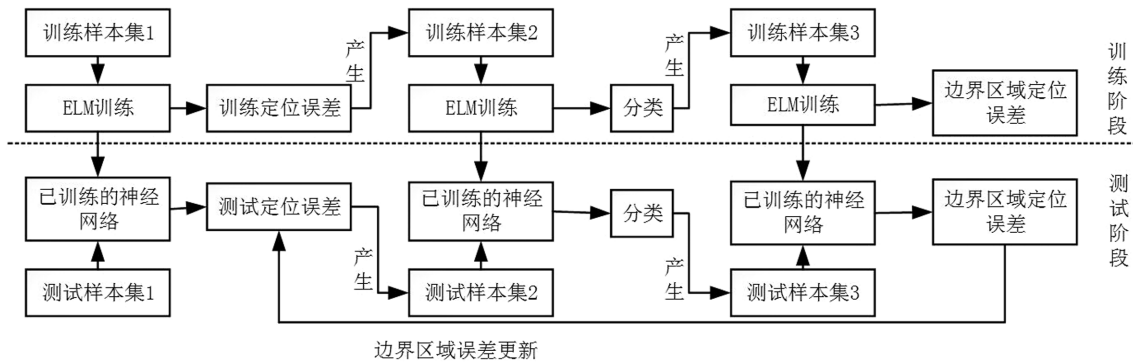


图 1 总算法流程图

Fig.1 Flow chart of proposed final algorithm




图 2 划分区域流程图

Fig.2 Flow chart of divide region

第 3 层神经网络利用 ELM 回归算法对边界区域进行定位. 将第 2 层神经网络分类得到的训练样本边界区域的总电功率作为输入, 对应的位置坐标作为输出, 即为训练样本集 3, 建立训练模型. 将分类得到的测试样本边界区域的总电功率作为输入, 对应的位置坐标作为输出, 建立测试样本集 3, 输入到训练好的神经网络中, 由式(15)(16)实现边界区域的定位. 最后将第 3 层神经网络得到的边界区域的定位误差更新到原始的整体定位误差中, 以实现对整个的定位.

3 实验设计

为了验证多层 ELM 分区域的定位性能, 基于室内环境进行仿真, 仿真模型图如图 3 所示. 实验场地为 5.0 m × 5.0 m × 3.0 m 的房间, 4 个 LED 灯组固定于天花板上, 位置坐标分别为 (-1.25, -1.25, 3), (-1.25, 1.25, 3), (1.25, -1.25, 3), (1.25, 1.25, 3), 其中地板中心坐标为 (0, 0, 0). 每个 LED 灯组由 60 × 60 个发射功率为 20 mW 的 LED 组成, 其半功率角为 70°. 对 LED 采用频分复用的方式进行调制, 并通过编码的方式携带各自的位置信息. 接收端利用滤波器区分各个 LED 信号, PD 将光信号转换为电信号, 并通过解调解码的方式分别得到每个 LED 携带的位置信息以及接收端功率. PD 在距离地面高度为 0.85 m 的平面上移动, 其中 PD 视场角为 70°, 面积为 1 cm², 光电转换效率为 0.54 A/W. 实验环境的仿真参数如表 1 所示. 在第 1 层神经网络中, 训练阶段将空间划分为密度为 5 cm × 5 cm 的区域, 采集每个接收端位置处来自各 LED 的电功率以及对应的位置坐标, 总共采集 10 000 组数据. 测试阶段将空间划分为密度为 2 cm × 2 cm 的区域, 采集每个接收端位置处来自各 LED 的电功率以及对应的位置坐标, 总共采集 62 500 组数据进行室内定位实验. 综合考虑定位误差大小、训练时间、区域划分的准确率等因素, 实验中设定第 1 层 ELM 神经网络中隐藏层神经元个数为 450, 第 2 层 ELM 神经网络中隐藏层神经元个数为 100, 第 3 层 ELM 神经网络中隐藏层神经元个数为 30, 激活函数 $g(x)$ 均为 sigmoidal 函数.




图 3 可见光室内定位仿真模型图
Fig.3 Simulation model of visible light positioning

表 1 仿真参数
Tab.1 Simulation parameter

符号	意义	数值
$T_s(\psi)$	光滤波器增益	1.0
n	PD 折射指标	1.5
G	开环电压增益	10
$\eta/(\text{pF} \cdot \text{cm}^{-2})$	PD 每单位面积的电容	112
g_m/mS	FET 跨导	30
Γ	FET 信道噪声因子	1.5
I_3	噪声带宽因子	0.086 8
B/kHz	等效噪声带宽	200
$I_{bg}/\mu\text{A}$	背景电流	5 100
I_2	噪声带宽因子	0.562
SNR/dB	信噪比	10, 20, 30

4 实验结果及分析

4.1 实验结果

根据仿真的信号功率和噪声功率大小可知, 该仿真下的室内定位结果是在信噪比为 26~34 dB 的情况下测得. 利用多层 ELM 算法对 5.0 m × 5.0 m × 3.0 m 的区域进行二维空间定位. 经过第 1 层 ELM 神经网络训练, 训练数据的平均定位误差为 2.45 cm, 误差的最大值为 26.8 cm, 误差的最小值为 0.09 cm. 测试数据的平均定位误差为 3.66 cm, 误差的最大值为 31.34 cm, 误差的最小值为 0.07 cm. 由第 1 层 ELM 神经网络训练数据定位误差图 4 和测试数据定位误差图 5 可知, 两者的定位误差具有相似分布特征, 即靠近墙体的区域定位误差较大, 靠近中心的区域定位误差较小. 因此, 综合考虑训练数据和测试数据的定位误差分布形态, 将靠近墙体大于 3.66 cm 的区域定义为边界区域, 其他的区域定义为内部区域,

实现了整体实验区域的划分,单独对误差大的边界区域进行训练.经过3层 ELM 神经网络训练后,边界区域误差的最大值由 31.34 cm 降为 20.14 cm,平均误差由 11.24 cm 降为 3.86 cm,且大部分误差集中在 8 cm 以下.整体误差的最大值由 31.34 cm 降为 20.14 cm,平均误差由 3.66 cm 降为 2.79 cm.测试数据定位误差分布如图 6 所示,由此可见,边界区域的定位误差明显降低,整体的定位误差低于 3.66 cm,逼近了划分的边界,该算法具有良好的定位效果.




图 4 第 1 层 ELM 神经网络训练数据定位误差
Fig.4 Training positioning error of first layer ELM neural network

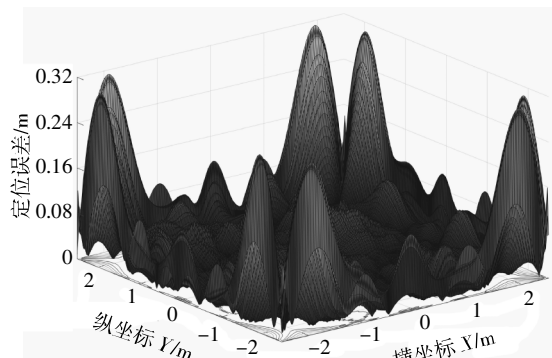


图 5 第 1 层 ELM 神经网络测试数据定位误差
Fig.5 Testing positioning error of first layer ELM neural network

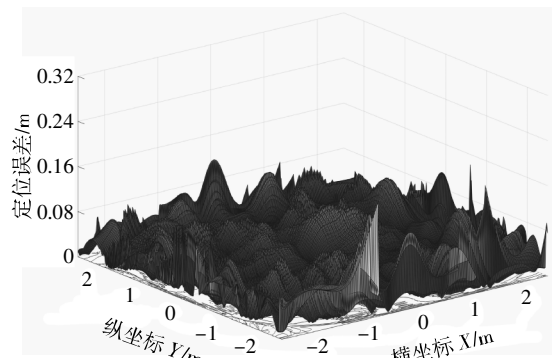


图 6 多层 ELM 神经网络测试数据定位误差
Fig.6 Testing positioning error of multilayer ELM neural network

4.2 实验分析

以下实验分析均是在信噪比为 26~34 dB 的情况下测得的.文献[11]提出了典型的 RSS 定位算法.在每一个接收端位置处,本实验数据采用从 4 个 LED 中选取接收功率相对较大的 3 个 LED,利用最小二乘法测得的最大误差为 1.15 m,平均定位误差为 36.31 cm,其定位误差较大,定位误差分布如图 7 所示.文献[12]提出建立 BP 神经网络模型进行可见光定位,采用本实验数据测得的最大误差为 51.34 cm,平均定位误差是 6.25 cm,定位误差分布如图 8 所示.单层 ELM 算法的最大误差为 31.34 cm,平均定位误差为 3.66 cm,定位误差分布如图 5 所示.和 RSS 定位算法相比,本文提出的多层 ELM 定位算法的最大误差降低了 5.7 倍,平均定位误差降低了 13 倍.和 BP 神经网络相比,平均定位误差降低了 55.36%,且边界处的误差明显降低.和单层 ELM 神经网络相比,边界处的平均定位误差降低了 65.66%,整体平均误差降低了 23.77%.由实验结果可以看出,本文提出的通过多层 ELM 降低边界区域定位误差的算法可进一步提高整体的定位精度.




图 7 RSS 算法定位误差
Fig.7 Positioning error of RSS algorithm

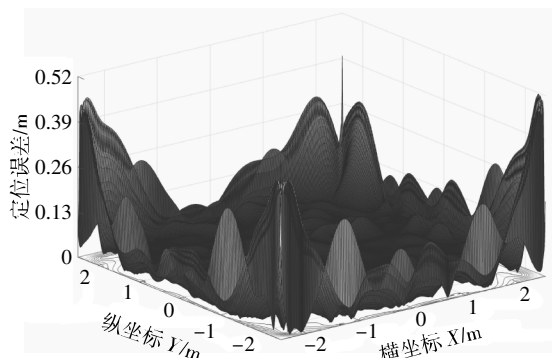


图 8 BP 神经网络测试数据定位误差
Fig.8 Testing positioning error of BP neural network

为了进一步表示多层 ELM、单层 ELM、BP 以及

RSS 算法的定位性能, 比较了它们各误差值的累积分布函数 (Cumulative Distribution Function, CDF). 从图 9 可以看出, 多层 ELM 的定位精度优于其他算法. 单层 ELM 误差小于 5 cm 的概率是 81.738%, BP 神经网络定位误差小于 5 cm 的概率是 64.994%, RSS 误差小于 5 cm 的概率是 4%, 而多层 ELM 误差小于 5 cm 的概率是 86.54%, 定位精度较高.




图 9 各算法定位误差的累积分布函数

Fig.9 CDF of the positioning error of different algorithms

神经网络的性能受隐藏层个数的影响, 图 10 表示了多层 ELM、单层 ELM、BP 以及 RSS 算法随隐藏层个数变化的平均距离误差 (Average Distance Error, ADE) 和均方根误差 (Root Mean Square Error, RMSE). 其中, 隐藏层个数为 0 时, 代表 RSS 定位算法. 从图中可看出, RSS 算法的 ADE 和 RMSE 值最高, 表示其定位性能最差. 随着隐藏层个数的增加, 多层 ELM、单层 ELM、BP 的定位性能逐渐提高并趋于稳定, 且多层 ELM 算法的 ADE 和 RMSE 值最小, 其定位性能优于 RSS、单层 ELM 和 BP 算法. 当隐

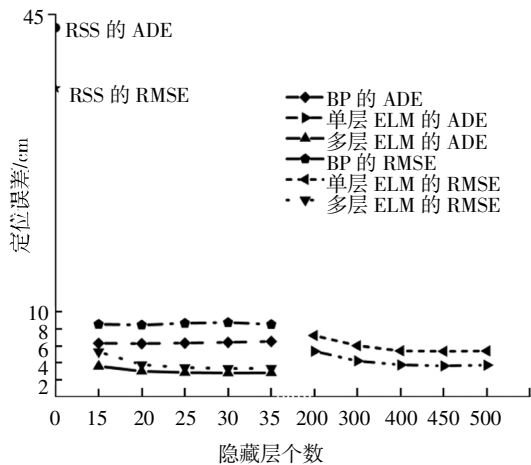


图 10 不同隐藏层个数的定位误差

Fig.10 Positioning error with different number hidden layer

藏层个数为 30 时, 多层 ELM 的定位性能最好, 此时 ADE 为 2.79 cm, RMSE 为 3.32 cm. 隐藏层个数为 20 时, BP 的定位性能最好, 此时 ADE 为 6.25 cm, RMSE 为 8.44 cm. 而隐藏层个数为 450 时, 单层 ELM 的定位性能最好, 此时 ADE 为 3.66 cm, RMSE 为 5.35 cm. 其中本文的第 1 层 ELM 神经网络即基于此数据.

ELM 算法只需要设置隐藏层个数和激活函数, 训练时间复杂度低. 以下算法测试时间均是在最佳隐藏层个数以及 62 500 组数据下计算所得, 取 10 次实验的平均时间作为其时间复杂度. 其中 3 层 ELM 神经网络总的平均测试时间为 1.504 9 s; 单层 ELM 神经网络平均测试时间为 0.968 8 s; BP 神经网络的平均测试时间为 0.125 0 s; RSS 算法定位时间为 2.843 8 s. 虽然 BP 测试时间最短, 但其定位精度不及多层 ELM 算法.

在实际环境中, 信号容易受到各种噪声的影响, 为了评估所提算法的鲁棒性, 图 11 表示了在不同的信噪比水平下各种算法的定位性能. 随着信噪比的降低, 多层 ELM、单层 ELM、BP 定位算法对噪声容忍高, 具有较好的定位效果, 且多层 ELM 定位精度最高. 但 RSS 算法的定位性能明显降低.

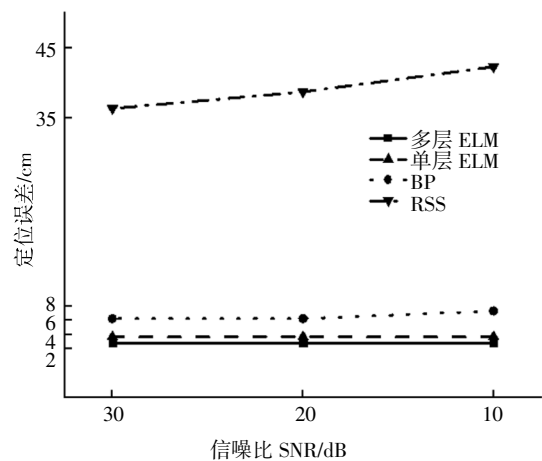


图 11 不同信噪比下的定位误差

Fig.11 Positioning error with different SNR

由以上分析可知, 多层 ELM 分区域定位算法的定位精度较高, 优于传统的 RSS 算法、单层 ELM 和 BP 神经网络, 且鲁棒性较强. 时间复杂度上虽不是最低, 但所需时间较少. 因此综合考虑算法的定位误差、时间复杂度和鲁棒性, 该算法与上述算法相比, 能够满足室内定位的需求, 且能适应于噪声较大的不同的场景中, 如室内、走廊、展厅、博物馆等.

5 结论

本文针对漫反射光信道中,边界区域定位误差大的问题,提出一种多层 ELM 的分区域可见光室内定位算法.由理论分析和仿真实验可得:

1)所提算法能够实现可见光室内定位,平均定位误差为 2.79 cm,具有良好的定位效果,且鲁棒性较强.

2)受一阶反射和噪声信号的影响,边界区域定位误差较大,该算法通过建立 3 层 ELM 神经网络,降低了边界区域误差,提高了定位精度.

3)该算法具有 ELM 原有的设置参数少,学习速度快,泛化能力强等优点,无需求解复杂的非线性方程组.

4)与传统的 RSS 定位算法和 BP 神经网络相比,平均定位误差分别降低了 13 倍和 55.36%,和 ELM 神经网络相比,边界区域定位误差降低 65.66%,整体平均定位误差降低 23.77%,进一步证明了该算法的有效性.

本文的研究结果表明,该算法具有较好的定位性能,且训练测试时间较少,解决了边界区域定位误差较大的问题,具有较强的鲁棒性,对于可见光室内定位的应用具有一定的参考意义.

参考文献

- [1] OH J,UM J. Acoustic signal-based indoor global coordinates system for smartphones [J]. IEEE Sensors Journal,2018,18(8): 3248—3254.
- [2] YASSIN A,NASSER Y,AWAD M,*et al.* Recent advances in indoor localization: a survey on theoretical approaches and applications [J]. IEEE Communications Surveys & Tutorials,2017,19(2): 1327—1346.
- [3] 郎宪明,李平,曹江涛,等.基于非平衡数据处理的管道泄漏检测与定位研究[J].湖南大学学报(自然科学版),2018,45(2): 110—118.
LANG X M,LI P,CAO J T,*et al.* Study on pipeline leak detection and location based on imbalance data processing [J]. Journal of Hunan University (Natural Sciences),2018,45(2): 110—118. (In Chinese)
- [4] ZHU B C,CHENG J,WANG Y J. Three-dimensional VLC positioning based on angel difference of arrival with arbitrary tilting angel of receiver [J]. IEEE Journal on Selected Areas in Communications,2018,36(1): 8—22.
- [5] 徐琨,刘宏立,马子骥,等.一种用于室内定位的线性规划算法[J].湖南大学学报(自然科学版),2016,43(8): 115—119.
XU K,LIU H L,MA Z J,*et al.* A linear programming algorithm for indoor localization in wireless sensor networks [J]. Journal of Hunan University (Natural Sciences),2016,43(8): 115—119. (In Chinese)
- [6] 吴楠,王旭东,胡晴晴,等.基于多 LED 的高精度室内可见光定位方法[J].电子与信息学报,2015,37(3): 727—732.
WU N,WANG X D,HU Q Q,*et al.* Multiple LED based high accuracy indoor visible light positioning scheme [J]. Journal of Electronics & Information Technology,2015,37(3): 727—732. (In Chinese)
- [7] FANG J B,YANG Z,LONG S,*et al.* High-speed indoor navigation system based on visible light and mobile phone [J]. IEEE Photonics Journal,2017,9(2): 8200711.
- [8] LI Z P,JIANG M,ZHANG X N,*et al.* Miller-coded asynchronous visible light positioning system for smart phones [C]// IEEE 85th Vehicular Technology Conference. Sydney:IEEE,2017: 1—6.
- [9] IFTHEKHAR M S,SAHA N,JANG Y M. Neural network based indoor positioning technique in optical camera communication system [C]//2014 International Conference on Indoor Positioning and Indoor Navigation. Busan,Korea:IEEE,2015: 431—435.
- [10] 李鹏,王延江.基于 ORB 特征点匹配的多目标跟踪算法[J].湖南大学学报(自然科学版),2017,44(10): 139—149.
LI P,WANG Y J. Multi-target tracking algorithm based on ORB feature points matching [J]. Journal of Hunan University (Natural Science),2017,44(10):139—149. (In Chinese)
- [11] ZHANG W Z,CHOWDHURY M I S,KAVEHRAD M. Asynchronous indoor positioning system based on visible light communications [J]. Optical Engineering,2014,53(4): 045105.
- [12] HUANG H Q,YANG A Y,FENG L H,*et al.* Artificial neural-network-based visible light positioning algorithm with a diffuse optical channel [J]. Chinese Optical Letters,2017,15(5): 050601.
- [13] ZHENG H H,XU Z W,YU C Y,*et al.* A 3-D high accuracy positioning system based on visible light communication with novel positioning algorithm [J]. Optics Communications,2017,396: 160—168.
- [14] KOMINE T,NAKAGAWA M. Fundamental analysis for visible-light communication system using led lights [J]. IEEE Transactions on Consumer Electronics,2004,50(1): 100—107.
- [15] GU W J,AMINIKASHANI M,DENG P,*et al.* Impact of multipath reflections on the performance of indoor visible light positioning systems [J]. Journal of Lightwave Technology,2016,34(10): 2578—2587.
- [16] HUANG G B,ZHU Q Y,SIEW C K. Extreme learning machine: theory and applications [J]. Neurocomputing,2006,70(1): 489—501.
- [17] LU X X,ZOU H,ZHOU H M,*et al.* Robust extreme learning machine with its application to indoor positioning [J]. IEEE Transactions on Cybernetics,2016,46(1):194—205.
- [18] 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 (Cybernetics),2012,42(2):513—529.