

# 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

张慧颖\*, 于海越, 王凯, 卢宇希, 梁誉

吉林化工学院信息与控制工程学院, 吉林 吉林 132022

**摘要** 针对室内可见光定位接收光功率不均匀、定位精度低等问题, 提出一种自适应花授粉定量式灯源优化方案结合改进径向基函数(RBF)的神经网络接收信号强度指示(RSSI)可见光定位方法。所提方法采用自适应花授粉算法优化发射器的光照强度; 通过基于改进RBF神经网络的RSSI定位方法处理接收到的均匀光信号, 实现精确有效定位。利用核主成分分析K-means++(KPCA-K-means++)聚类模型对RSSI样本值进行预处理, 得到最优聚类数目和聚类中心, 作为隐含层神经元个数和中心值。通过遗传算法-最小均方(GA-LMS)模型对RBF神经网络参数进行寻优。仿真结果表明, 在9 m×12 m×3.5 m的室内环境中, 接收光功率为-28.6 dBm~-25.1 dBm, 定位误差小于0.1 m。因此, 所提改进后的可见光定位方法具有定位精度更高、实用性更强等优点。

**关键词** 光通信; 可见光定位; 自适应花授粉; 接收信号强度指示; RBF神经网络; 核主成分分析K-means++模型; 遗传算法-最小均方模型

中图分类号 TN929.12

文献标志码 A

doi: 10.3788/AOS202141.1906001

## Indoor Visible Light Positioning of Improved RBF Neural Network Based on KPCA-K-means++ and GA-LMS Model

Zhang Huiying\*, Yu Haiyue, Wang Kai, Lu Yuxi, Liang Yu

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

**Abstract** Aiming at the nonuniformity of the received optical power and low positioning precision in the indoor visible light positioning, a received signal strength indicator (RSSI) visible light positioning method is proposed based on adaptive flower pollination quantitative light source optimization scheme combined with improved radial basis function (RBF) based neural network. The adaptive flower pollination algorithm optimizes the light intensity of the transmitter processing the received uniform optical signal using an improved RBF-based neural network RSSI positioning method, resulting in accurate and effective positioning. The kernel principal component analysis K-means++ (KPCA-K-means++) clustering model is used to preprocess the received RSSI sample value. The optimal cluster number and cluster center are obtained as the number and central value of the hidden layer neurons. The genetic algorithm and least mean square (GA-LMS) model is used to optimize the parameters of the RBF neural network. According to simulation results, the received optical power ranges from -28.6 dBm to -25.1 dBm in an indoor space of 9 m×12 m×3.5 m. Moreover, the positioning error is less than 0.1 m. Therefore, the proposed improved visible light positioning method has higher positioning accuracy and stronger practicability advantages.

**Key words** optical communications; visible light positioning; adaptive flower pollination; received signal strength indication; RBF neural network; kernel principal component analysis K-means++ model; GA-LMS model

**OCIS codes** 060.4510; 230.3670; 220.2549; 120.6650

收稿日期: 2021-01-04; 修回日期: 2021-03-28; 录用日期: 2021-04-16

基金项目: 吉林省自然科学基金(YDZJ202101ZYTS189)、吉林化工学院博士启动项目(2018003)

通信作者: \*yingzi1313@163.com

## 1 引言

随着定位技术发展越来越成熟,人们不再满足于在室外环境下进行定位,室内定位技术也逐渐被专家关注<sup>[1]</sup>。现有的室内定位技术包括全球卫星定位系统(GPS)、红外室内定位技术、蓝牙室内定位技术、超声波室内定位技术、射频识别(RFID)室内定位技术等,且大多存在定位精度低、穿透障碍物能力弱、发射距离短、受电磁干扰等缺点。基于可见光通信(VLC)技术的室内定位方法是解决室内定位的新方向,与传统的室内定位技术相比,具有保密性好、不易受多径干扰、定位精度高、成本低等优点<sup>[2-6]</sup>。在可见光定位中,灯源排布至关重要,直接决定定位性能。Hao 等<sup>[7]</sup>提出基于多输入多输出的一阶反射系统模型,但该模型仿真空间小,仿真结果不具有普遍性,并且照明强度低,无法满足工作照明要求。胡建宇<sup>[8]</sup>提出基于神经网络的灯源排布方案,但该方案灯源排布混乱,不适合在室内使用。周中山等<sup>[9]</sup>提出基于 Convex 最优化的室内可见光通信灯源排布方案,但是该方案无法保证得到的最优理论解是单个 LED 功率的整数倍。灯源排布在保障光照强度和接收光功率的同时,也应兼顾灯源排布的合理性。Hou 等<sup>[10]</sup>提出一种 angle of arrival (AOA)结合接收信号强度指示(RSSI)的室内定位算法,该算法结合两种算法的优势提高定位精度,但复杂程度变高,导致成本增加。卞国龙等<sup>[11]</sup>提出一种粒子群结合反向传播(BP)神经网络的定位算法,但神经网络训练时间较长,使得定位速度慢,定位精度不高。付思源等<sup>[12]</sup>使用和声搜索算法优化神经网络,和声搜索算法可以优化输入样本值,但在迭代中易陷入局部最优困局,得到的中心值对优化径向基函数(RBF)神经网络的作用不大。Zheng 等<sup>[13]</sup>提出一种基于改进快速聚类算法的 RBF 神经网络定位算法,该算法对数据进行预处理分类,但并未改进 RBF 参数,使得整体泛化性下降。

基于以上问题,本文在合理灯源排布方案下,采用改进花授粉算法(FPA)优化发射光照强度,保证接收光功率均匀,实现空间各个角落的定位性能基本一致;针对文献中 RBF 神经网络输入层样本值未处理和参数值未优化问题,采用核主成分分析 K-means++(KPCA-K-means++)模型对 RSSI 数据进行预处理,采用遗传算法-最小均方(GA-LMS)模型优化 RBF 神经网络的参数(宽度值和连接权值)。仿真结果表明,与传统室内可见光定位方案相

比,所提室内可见光定位(VLP)方案具有通用性好、精度高等优点。

## 2 室内可见光定位系统

### 2.1 室内可见光信道模型

在室内设置 4 盏 LED 作为发射器,并等间隔对称分布,将灯源安置在距离地面  $h$  的室内空间顶部,在距离空间底部  $h'$  处放置光电二极管(PD)作为接收器,如图 1 所示。




图 1 可见光定位系统模型

Fig. 1 Model of visible light positioning system

室内环境中,墙面和物体会对光信号造成反射,在只考虑直射链路(LOS)的情况下,PD 能够接收的光功率  $P_r(R_j)$  和发射端的发射功率  $P_i$  之间的关系为

$$P_r(R_j) = P_i H_{\text{LOS}}(0; S_i, R_j), \quad (1)$$

式中:  $H_{\text{LOS}}(0)$  为直射链路的信道增益;  $S_i$  为第  $i$  个 LED;  $R_j$  为第  $j$  个接收器。  $H_{\text{LOS}}(0)$  可表示为

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

式中:  $A$  为 PD 的有效接收面积;  $d$  为 LED 到 PD 的相对距离;  $\psi$  为接收器的接收角;  $\psi_c$  为 PD 视场角;  $\varphi$  为发散角;  $T_s(\psi)$  为 PD 的光滤波器增益;  $g(\psi)$  为光学集中器增益;  $m$  为朗伯散射系数。LED 发光强度分布服从朗伯光源模型<sup>[14]</sup>:

$$I_\theta = I_0 \cos^m \theta, \quad (3)$$

式中:  $I_\theta$  为发射角  $\theta$  方向的发光强度;  $I_0$  为垂直于发光面的发光强度。

$$m = \frac{-\ln 2}{\ln(\cos \theta_{1/2})}. \quad (4)$$

### 2.2 RSSI 定位原理

采用三边定位法对待定位点进行求解。设置 3

个 LED 发射器, LED 坐标分别为  $o_1=(x_1, y_1, h)$ ,  $o_2=(x_2, y_2, h)$ ,  $o_3=(x_3, y_3, h)$ , 待定位点坐标为  $o=(x, y, z)$ , 则三边定位算法表达为

$$\begin{cases} (x_1-x)^2+(y_1-y)^2+(h-z)^2=d_1^2 \\ (x_2-x)^2+(y_2-y)^2+(h-z)^2=d_2^2 \\ (x_3-x)^2+(y_3-y)^2+(h-z)^2=d_3^2 \end{cases} \quad (5)$$

式中:  $z$  设置为 0。(5)式化简为

$$AC=B, \quad (6)$$

式中:  $A = \begin{bmatrix} x_2-x_1 & y_2-y_1 \\ x_3-x_1 & y_3-y_1 \end{bmatrix}$ ;  $B = \frac{1}{2} \times$

$\begin{bmatrix} d_1^2-d_2^2-x_1^2-y_1^2+x_2^2+y_2^2 \\ d_1^2-d_3^2-x_1^2-y_1^2+x_3^2+y_3^2 \end{bmatrix}$ ;  $C=[x \ y]^T$ 。待定位点坐标可表示为

$$C=(A^T A)^{-1} A^T B. \quad (7)$$

理想情况下, 可求出待定位点的坐标, 但室内环境复杂导致三边定位算法不准确并产生误差。3 个圆不会严格交于一点, 部分重叠在一起形成误差, 如图 2 所示。因此采用最小二乘法等其他算法继续计算最优解, 从而得到位置坐标<sup>[15-16]</sup>。




图 2 测距误差

Fig. 2 Distance measurement error

### 3 自适应花授粉定量光源设计

#### 3.1 室内均匀光功率优化方案

以吉林化工学院实验室为例, 实际尺寸为  $9 \text{ m} \times 12 \text{ m} \times 3.5 \text{ m}$ 。将室内天花板均匀划分, 形成  $4 \times 3$  的网格形式, 每个网格中放置一个 LED 灯组, 每个 LED 灯组由  $7 \times 7$  LED 组成矩形阵列, 如图 3 所示, 实验室光源既要满足学生正常照明使用要求, 同时也要满足通信要求。由于光源传播时会受到多径效应、噪声干扰, 对 LED 光照强度进行优化, 使接收光功率均匀, 保障室内各个位置的通信功率和照明分布几乎相同, 提高室内定位精度。

在(1)式中引入独立比例因子  $k_i (0 \leq k_i \leq 1)$ <sup>[17]</sup>, 则接收器接收到的光功率为




图 3 光源排布

Fig. 3 Light source layout

$$P_r(R_j) = \sum_{i=1}^I \left[ k_i \sum_{i=1}^N P_i H_{\text{LOS}}(0; S_i, R_j) \right], \quad (8)$$

式中:  $I$  为 LED 光源阵列的数量;  $N$  为每个阵列中 LED 数量。若得到一组最优  $k_1, k_2, \dots, k_I$ , 则接收器可获得相同光功率。

采用改进的 FPA 对  $k$  值进行寻优。定义种群  $T$  由  $n$  个花粉个体  $K_v=(k_1, k_2, k_3, \dots, k_n) \in \Gamma[\Gamma$  为搜索空间,  $v \in (1, 2, 3, \dots, n)]$  组成, 每个花粉个体代表一种候选方案, 设定目标函数为

$$\Delta K_v = \left[ \frac{\max P_r(K_v) - \min P_r(K_v)}{\max P_r(K_v)} \right], \quad (9)$$

式中:  $\max P_r(K_v)$  为一个接收器接收光功率最大值;  $\min P_r(K_v)$  为一个接收器接收光功率最小值。若室内光功率分布均匀, 则目标函数为 0。根据所提自适应 FPA 对目标函数不断进行迭代、搜索, 得到全局最优  $K_v$ , 从而计算出接收器的光功率波动。

#### 3.2 自适应花授粉算法设计

依据文献[18], 花朵转换概率是  $p$  时, FPA 选择异花授粉; 花朵转换概率是  $1-p$  时, FPA 选择自花授粉。异花授粉和自花授粉相应的公式<sup>[19-20]</sup>为

$$\begin{cases} K_v^{t+1} = K_v^t + L(K_v^t - g) \\ K_v^{t+1} = K_v^t + \epsilon(K_j^t - K_k^t) \end{cases}, \quad (10)$$

式中:  $K_v^t$  为花粉个体第  $t$  代的解;  $K_v^{t+1}$  为花粉个体第  $t+1$  代的解;  $K_j^t$  与  $K_k^t$  为同品种的不同两支花朵的花粉;  $g$  为全局最优解;  $\epsilon$  为  $[0, 1]$  上服从均匀分布的随机数;  $L$  为 Lévy 飞行的步长参数。  $L$  的计算公式为

$$L \sim \frac{\lambda \Gamma(\lambda) \sin(\pi\lambda/2)}{\pi} \times \frac{1}{s^{1+\lambda}} (s \gg s_0 > 0), \quad (11)$$

式中:  $\lambda$  为缩放因子, 依据文献[21]设置  $\lambda = 1.5$ ;  $\Gamma(\lambda)$  为标准的伽马函数;  $s$  为移动步长;  $s_0$  为起始步长值, 即  $s \gg s_0 > 0$  为  $s \rightarrow \infty$ 。Lévy 飞行帮助算法

偏离局部最优,但由于  $p$  转换概率的限制,FPA 执行较少的全局搜索,导致飞行以小步长进行局部运动。因此,引入自适应移动因子

$$\delta(v) = \sqrt{e^{-v} + \frac{1}{\gamma}}, \quad (12)$$

式中: $\gamma$  为当前子群进化次数; $v = 1 + \frac{\gamma}{\gamma_Q}$ ,其中  $\gamma_Q$  为当前全局进化次数。根据局部搜索和全局搜索, $K_{\text{best}}$  为花粉个体最优解,设计种群更新公式为

$$K'_v = p[K_v + \text{rand}(K_{\text{best}} - K_v)] + (1-p)K_v + \delta L(g - K_v), \quad (13)$$

式中: $\delta$  为自适应移动因子。 $\delta(t)$  随移动步长的增加而减小,有利于全局广泛搜索,并可快速实现对独立比例因子  $k_i$  最优组的寻找。

## 4 改进的 RBF 神经网络定位模型设计

### 4.1 基于 RSSI 的 RBF 神经网络

根据可见光定位需求,建立基于 RSSI 定位算法的 RBF 神经网络,如图 4 所示。




图 4 RBF 神经网络结构

Fig. 4 RBF neural network structure

由图 4 可看出:输入层包含  $n'$  个节点,输入值为  $\text{RSSI}_1, \text{RSSI}_2, \text{RSSI}_3, \dots, \text{RSSI}_{n'}$ ,表示每个接收器接收到 LED 灯组的 RSSI 值;隐含层由  $r$  个神经元组成; $w_{ij}$  是隐含层到输出层的各连接权值;输出层  $G_1, G_2$  为目标点估计坐标  $(x, y)$ 。向 RBF 神经网络输入  $q$  个训练样本,误差函数定义为目标函数  $E$ ,表达式为

$$E = \frac{1}{2} \sum_{q'=1}^q (d_e - d'_{q'})^2, \quad (14)$$

式中: $d_e$  为期望输出值; $d'_{q'}$  为实际输出值。根据  $b = d_{\text{max}} / \sqrt{2r}$  (其中  $d_{\text{max}}$  为所选取的点到中心点的最大距离)计算得到 RBF 的宽度  $b$ ,再使用最小二乘法对连接权值进行求解,建立 RBF 神经网络。但在实际应用中,当 RSSI 与 RBF 神经网络结合时,

RSSI 前期数据较多,会造成 RBF 神经网络出现学习困难的情况,并且无法确定神经网络中隐含层的神经元最优个数,同时定位性能也会由于参数(中心值、宽度、连接权值)的不准确而下降。因此提出 KPCA-K-means++ 模型来计算最优聚类数目和最优聚类中心,从而提高 RBF 神经网络性能。

### 4.2 KPCA-K-means++ 聚类模型构建

针对 RSSI 前期数据较多的问题,使用 KPCA 法对每个接收端获得的 RSSI 值在高维特征空间中进行非线性映射,原始数据  $X = \{x_1, x_2, \dots, x_t\}$  在高维特征空间中的映射数据集为  $\Phi(X) = [\phi(x_1), \phi(x_2), \dots, \phi(x_t)]$ ,  $W' = (w'_1, w'_2, \dots, w'_d)$  为高维空间中的特征向量,关系为

$$\Phi(X)\Phi(X)^T w'_i = \xi w'_i. \quad (15)$$

特征向量和核函数为

$$\begin{cases} w'_i = \Phi(X)\chi \\ \Phi = \Phi(X)\Phi(X)^T \end{cases} \quad (16)$$

化简得到  $\Phi\chi = \xi\chi$ ,取  $\Phi$  最大特征值对应的特征向量得到映射后的数据代替原始数据,对映射后的数据集进行主成分分析。

KPCA 将前期较为繁杂的数据简化,将映射后得到的数据放入输入层进行学习。K-means++ 聚类算法<sup>[22]</sup>对处理过的 RSSI 数据进行分类,便于设置后期隐含层中的神经元个数。首先从经 KPCA 预处理得到的数据集中选择  $k$  个初始聚类中心值,进行分组、重新分配、更新分组,得到的中心值要在规定的误差范围内,对数据进行分类的主要计算步骤如下。

1) 从 KPCA 处理后的数据集中随机选取一个样本作为初始聚类中心  $k_1$ 。

2) 计算每个样本到当前已有的聚类中心的最短距离  $D_{\text{min}}$ ,累计得到  $\sum D_{\text{min}}$ 。

3) 计算备选中心点的概率  $P_c = \frac{D_f}{\sum_{f=1}^F D_f}$ ,最优神经元样本作为最新聚类中心。

4) 重复步骤 1)~3),直至选择出  $k$  个最优中心点。

通过 KPCA-K-means++ 聚类算法确定 RBF 神经网络的神经元个数和神经元中心值,KPCA-K-means++ 聚类模型优化 RBF 神经网络神经元中心值的具体步骤如下。

1) 通过 KPCA 对数据进行映射,得到映射到特征空间降维后的数据。



- 2) 将预处理后的数据放入 K-means++ 聚类中。
- 3) 随机选择初始中心。
- 4) 根据中心点概率公式计算最新聚类中心, 得到当前神经元。
- 5) 跳转到步骤 4), 直至满足  $k$  个最优中心点。

### 4.3 GA-LMS 模型构建

由于宽度参数和权值参数严重影响改进后 RBF 神经网络模型的学习过程, 因此所提方法通过遗传算法 (GA) 对 RBF 神经网络中的宽度参数进行不断迭代寻优, 直至找到 RBF 神经网络中宽度参数最优个体。在 RBF 神经网络中宽度参数  $\{b_1, b_2, b_3, \dots, b_r\}$ , 对宽度参数进行编码, 设染色体  $Z = \{z_1, z_2, z_3, \dots, z_r\}$ 。适应度函数为

$$F(z) = \sum_{u=1}^q (p_u - p'_u), \quad (17)$$

式中:  $p_u$  为期望输出值;  $p'_u$  为真实输出值。GA 通过选择、交叉、变异 3 个步骤, 最终得到最优个体, 在选择算子中, 所提方法采用轮盘赌选择法。得到优化后的宽度, 先应用最小二乘法对 RBF 神经网络中的连接权值进行计算。由于过度学习、模型复杂、数据量小等原因发生过拟合现象, 因此在调整权值训练过程中, 所提方法提出改进的最小均方 (LMS) 学习规则, 除对输入样本进行中误差计算外, 加入由直接计算法得到的 6 个输出值, 防止过度计算, 得到的目标函数结果越小越好。目标函数公式为

$$G = \sqrt{\frac{p_u - p'_u}{n}} + \sqrt{\frac{\rho_u - \rho'_u}{6}}, \quad (18)$$

式中:  $\rho_u$  为真实值;  $\rho'_u$  为直接法得到的输出值。LMS 越小, 输出值越好。通过 GA-LMS 模型对 RBF 神经网络进行优化, 从而提高 RBF 神经网络性能。

### 4.4 改进 RBF 室内算法设计

改进的 RBF 神经网络算法首先利用设计的 KPCA-K-means++ 模型对接收端收集到的 RSSI 数据进行聚类, 得到最优聚类数目和聚类中心, 分别作为隐含层的神经元个数和神经元中心; 构建 RBF 神经网络后, 采用提出的 GA-LMS 模型得到较为准确的宽度和连接权值。改进 RBF 室内算法流程如图 5 所示。

## 5 仿真与结果分析

### 5.1 光强度分布与接收光功率仿真

为评估所提定量式灯源排布接收功率优化方案

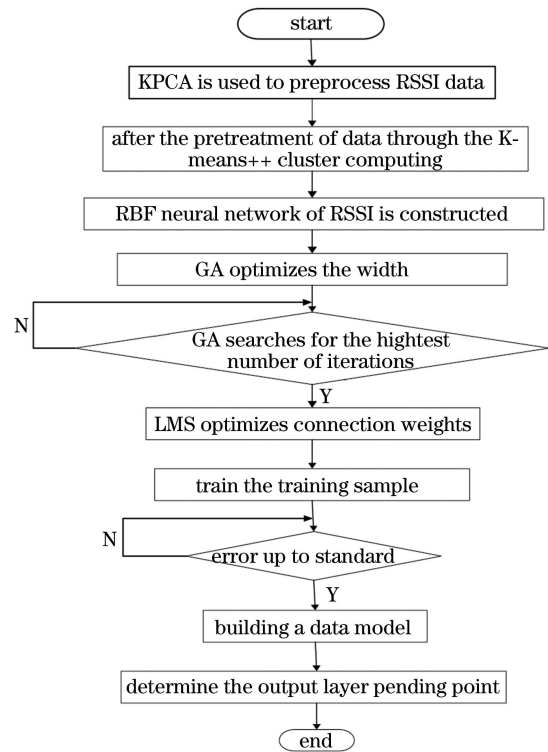


图 5 改进 RBF 神经网络算法流程

Fig. 5 Flow chart of improved RBF neural network algorithm

的效果, 以吉林化工学院某一实验室实地为参考依据进行仿真实验。实验室长、宽、高分别为 9 m、12 m、3.5 m, 实验室内灯源排布方案为  $4 \times 3$  的网格型灯源排布, 并将室内底部同样划分  $4 \times 3$  网格型, 在网格中每一格四个角都放置接收器, 并在网格内随机设置 6 个待定位点。对比常规网格灯排布的光照强度与所提改进 FPA 优化灯源排布方案的光照强度, 仿真结果如图 6 所示。仿真过程中仿真参数如表 1 所示。

表 1 仿真参数表

Table 1 Simulation parameter table

Parameter	Value
Room height / m	3.5
Gain of optical filter	1
Receiving plane height / m	0.5
Effective received area of PD / $\text{cm}^2$	1
LED emission power / W	1
Field of view / $^\circ$	55
Half-power $\Phi_{1/2}$ / $^\circ$	80
Initial central luminescence intensity / cd	23.81
Single LED initial emitting light power / W	1

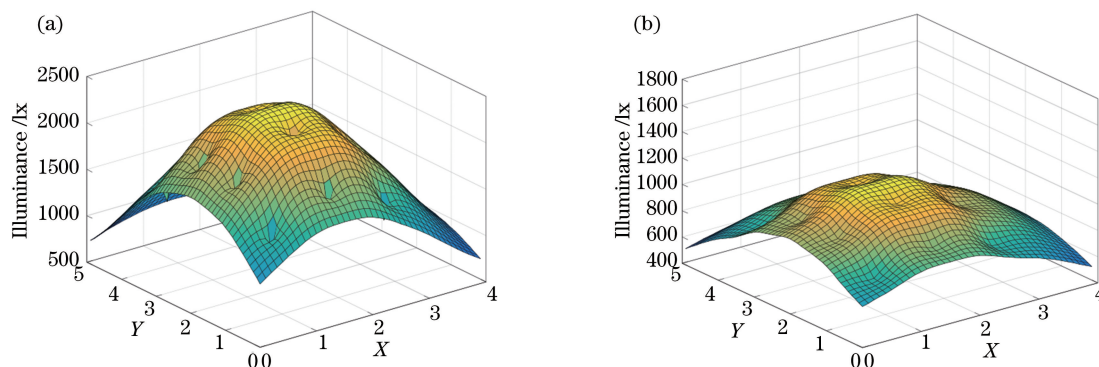


图 6 光照强度分布对比。(a)未优化的光强;(b)优化后的光强

Fig. 6 Comparison of the light intensity distribution. (a) Unoptimized light intensity; (b) optimized light intensity

图 6(a)是未优化时的光强度分布,水平照度为 918.53~2017.13 lx,照度波动较大,在室内空间四角照度较低,空间中部照度较高,无法实现光源均匀分布,导致通信平坦性差,不能实现任意角落接收到相同光信号。图 6(b)是改进 FPA 优化后的照度,虽然无法完全消除阴影问题,但水平照度相比于未改进时更均匀,在室内空间中,照度为 600~700 lx,接收照度波动明显减小。根据

ISO 国际标准,办公环境所需要的照度应为 300~1500 lx,因此改进 FPA 优化后得到的照度范围符合国际标准,均匀照明率大于 0.7。因此,优化照度后的照明分布率更均匀、接收光功率更平坦,实现了室内空间照明均匀分布,通信平坦性和光信号传输得到优化。室内各角落接收端接收的光功率分布仿真结果如图 7 所示。

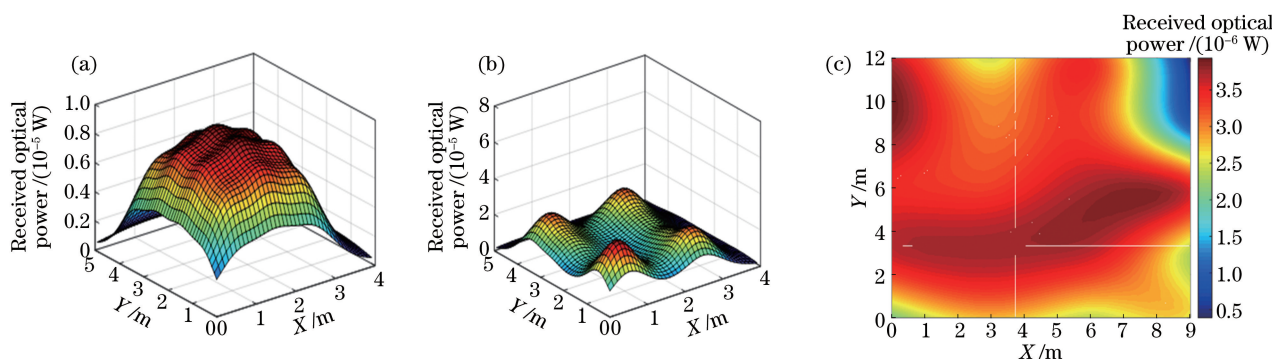


图 7 接收光功率分布。(a)未优化的光功率;(b)优化后的光功率;(c)优化后的光功率云图

Fig. 7 Power distributions of received light. (a) Unoptimized received optical power; (b) optimized received optical power; (c) optimized received optical power nephogram

图 7(a)为未优化时室内接收光功率的分布图,可看出接收光功率波动较大,波动范围为 -29.9 dBm~-20.96 dBm,无法在室内各个位置实现光信号的完整传输、保障通信的平坦性,导致接收光功率较弱的地方定位精度低。图 7(b)是优化后得到的接收光功率分布图,接收光功率为 -28.6 dBm~-25.1 dBm,明显看出波动范围减小、通信平面上接收光功率均匀,保证室内各位置定位精度不受影响。图 7(c)直观体现接收光功率在室内分布的效果,可看出室内空间中各个角落接收到的光功率几乎相等,实现室内光功率均匀分布。

### 5.2 基于 RSSI 的 RBF 神经网络测试点分布

实验场地为吉林化工学院的一个实训实验室,

实验室内有实验设备、精密仪器和台式电脑。在实验室内放置 35 个样本点,每个样本点之间间隔 2 m 左右。采集训练样本 RSSI 值数据作为数据库,对改进 RBF 神经网络进行训练,再对放置的 6 个测试点进行定位,得到测试点坐标。实验室测试点和样本点情况如图 8 所示。

从图 8 可看出,在实验室中均匀分布 35 个样本点分别收集接收光功率数据,收集的数据通过 KPCA-K-means++ 模型得到最优聚类数目和聚类中心,建立基于 RSSI 的 RBF 神经网络模型,再通过 GA-LMS 对宽度和连接权值进行计算,得到训练后的改进 RBF 神经网络。




图 8 实验室测试点、样本点分布示意图

Fig. 8 Schematic diagram of laboratory test points and sample point distribution

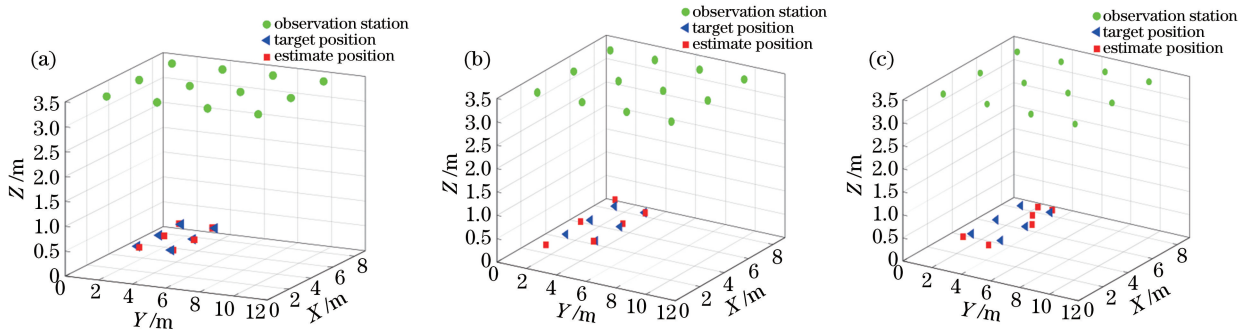


图 9 定位效果对比。(a)改进 RBF 神经网络定位算法;(b)未改进的 RBF 神经网络定位算法;(c)传统 LS 定位算法

Fig. 9 Comparison of positioning effect. (a) Improved RBF neural network location algorithm; (b) RBF neural network location algorithm; (c) traditional LS location algorithm

最大误差为 2.137 m,最小误差为 0.672 m,平均误差为 1.8137 m。相比于传统定位算法,改进 RBF 神经网络定位算法对 6 个测试点的定位预测误差均小于 0.1 m,因此所提改进 RBF 神经网络定位算法定位误差明显降低。

图 10 为不同算法得到的待定位点坐标,与改进 RBF 定位算法相比,传统 LS 定位算法和 RBF 定位算法得到的定位与测试点偏差较大。改进 RBF 定位算法的定位精度相较于传统 LS 定位算法和 RBF 定位算法分别提高了 11.31%和 38.96%,测试点与改进 RBF 神经网络算法得到的定位点更为接近。

### 5.4 定位误差仿真对比分析

对 6 个测试点分别采用改进 RBF 神经网络定位算法、RBF 神经网络定位算法及传统 LS 定位算法进行 10 组定位测试,对每个测试点取 10 次误差计算平均值,仿真结果如图 11 所示。

由图 11 可看出,改进 RBF 神经网络定位算法的 6 个定位点误差平均值在 0.1 m 左右,最小平均误差可达到毫米级;RBF 神经网络定位算法的平均定位误差在 1 m 以内,且 6 个测试点中,最大误差和最小误差相差 0.5447 m,定位精度不高;传统 LS 定位算法的定位误差浮动很大,定位精度很低。

### 5.3 定位性能对比分析

在测试空间内,随机选取 6 个测试点,分别采用改进 RBF 神经网络定位算法、未改进 RBF 神经网络和传统最小二乘(LS)定位算法进行仿真分析,仿真结果如图 9 所示。

从图 9(a)可看出,所提改进 RBF 神经网络定位算法中 6 个测试点的误差,最大为 0.0929 m,最小为 0.008 m,平均误差为 0.08513 m;图 9(b)是未改进 RBF 神经网络定位算法的定位效果,最大误差为 1.0423 m,最小误差为 0.2014 m,平均误差为 0.7679 m;图 9(c)是传统 LS 定位算法的定位效果,

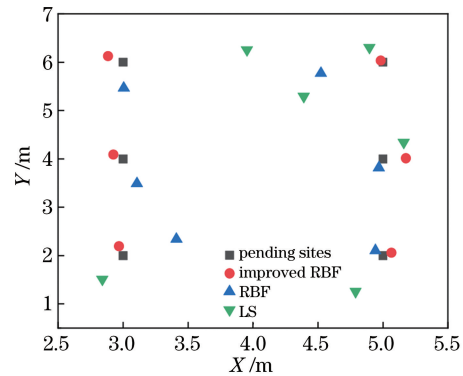


图 10 不同定位算法计算的待定位点坐标

Fig. 10 Coordinates of points to be located calculated by different positioning algorithms

3 种定位算法在 10 组计算中定位误差的最大值、最小值及平均误差对比如表 2 所示。

在相同的环境下,对 6 个待测点分别采用 3 种定位算法进行 10 次测试,得到在 0~0.1 m、0.1~0.2 m、0.2~0.3 m、>0.3 m 这 4 个误差区间内 3 种算法误差所占比例,如图 12 所示。由图 12 看出:在 10 组定位测试中,改进后的 RBF 神经网络定位算法误差在 0~0.1 m 的误差区间内占比为 41%,在 0.1~0.2 m 误差区间内占比为 33%,在 0.2~0.3 m



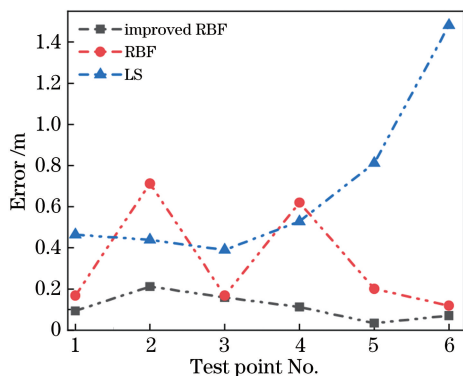


图 11 定位误差比较

Fig. 11 Positioning error comparison

表 2 定位仿真结果

Table 2 Location simulation results unit: m

Location method	Maximum error	Minimum error	Average error
Improved RBF location algorithm	0.0929	0.008	0.18513
RBF location algorithm	1.0423	0.2014	0.7679
LS location algorithm	2.137	0.672	1.8137

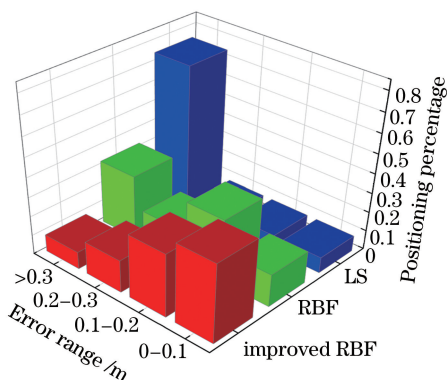


图 12 不同算法定位误差所占比例直方图

Fig. 12 Proportion histogram of positioning error of different algorithms

误差区间内占比为 17%，在 0.3 m 以上误差区间内占比为 9%，整体误差稳定在 0~0.1 m 内；而 RBF 神经网络定位算法定位误差不稳定，定位误差多数集中在 0.1~0.2 m 和 >0.3 m 的误差区间内；传统定位算法定位误差大多集中在 >0.3 m 误差区间上，误差占比为 75.1%，因此后两种定位算法误差大、定位精度低，无法满足大型室内场所的定位要求。

为进一步验证所提改进 RBF 神经网络定位算法定位精度更高、稳定性更强，对 3 种定位算法的误差累积分布进行对比，如图 13 所示。

从图 13 可以看出：所提改进 RBF 神经网络定

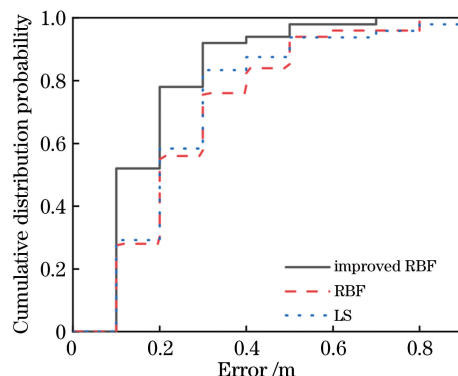


图 13 不同算法的定位误差累积分布对比

Fig. 13 Comparison of cumulative distribution of positioning errors for different algorithms

位算法在误差为 0.5 m 左右时误差累积分布概率达到 1；而 RBF 神经网络定位算法在 0.8 m 左右时误差累积分布概率达到 1；传统定位算法在误差为 0.9 m 左右时误差累积分布概率达到 1。通过累积分布线对比明显看出：改进 RBF 神经网络定位算法的累积分布概率更快接近 1。对改进 RBF 神经网络定位算法、RBF 神经网络定位算法、传统定位算法进行多次定位仿真测试得知，在相同条件下，所提改进 RBF 神经网络定位算法在平均误差和定位精度稳定方面均优于其他两种定位算法。因此，所提改进神经网络的定位算法结合优化接收光功率方案可以实现室内可见光定位，所提方法具有定位精度高、接收光功率均匀、光照强度均匀等优点，更适用于大型室内场所。

## 6 结 论

采用网格型光源布局方案结合自适应 FPA 实现定量式光源排布设计，解决室内空间接收光功率波动大等问题；采用 RSSI 方法结合改进 RBF 神经网络方法，实现室内可见光定位方案设计；采用 KPCA-K-means++ 模型对 RSSI 数据进行聚类计算，将得到的最优聚类中心和最优聚类数目作为神经元中心和个数，利用所提 GA-LMS 模型对宽度和连接权值进行寻优，防止过拟合现象发生。经过仿真验证，所提改进 FPA 结合定量式光源排布方案可有效减小接收光功率波动，波动范围为 -28.6 dBm~25.1 dBm，有效提高室内定位接收光功率稳定性，满足室内均匀接收光功率和照明条件的需求。与 RBF 神经网络和传统定位算法相比，所提改进 RBF 神经网络定位算法误差稳定在 0.1 m 内，定位精度相比 RBF 神经网络提高了 38.96%。因此，所提改



进后的 RBF 神经网络定位算法泛化性强,定位误差更小且通用性高。本实验组设计的室内可见光定位算法更适合大型场所的高精度定位。研究内容为可见光室内定位提供了理论支撑。

## 参 考 文 献

- [1] Deng Z L, Yu Y P, Yuan X, et al. Situation and development tendency of indoor positioning[J]. China Communications, 2013, 10(3): 42-55.
- [2] Saab S S, Nakad Z S. A standalone RFID indoor positioning system using passive tags [J]. IEEE Transactions on Industrial Electronics, 2011, 58(5): 1961-1970.
- [3] Xu S W, Wu Y, Su G D. Fingerprint matching and localization algorithm based on orthogonal frequency division multiplexing modulation for visible light communication [J]. Laser & Optoelectronics Progress, 2019, 56(9): 090601.  
徐世武, 吴怡, 苏国栋. 基于正交频分复用调制的可见光通信指纹匹配定位算法[J]. 激光与光电子学进展, 2019, 56(9): 090601.
- [4] Jung S Y, Hann S, Park C S. TDOA-based optical wireless indoor localization using LED ceiling lamps [J]. IEEE Transactions on Consumer Electronics, 2011, 57(4): 1592-1597.
- [5] 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.  
陈勇, 巫杰, 刘焕淋, 等. 基于隐马尔科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.
- [6] Cao Y P, Li X J, Hu Y Y. Visible light fingerprint-based high-accuracy indoor positioning method [J]. Laser & Optoelectronics Progress, 2019, 56(16): 160601.  
曹燕平, 李晓记, 胡云云. 基于可见光指纹的室内高精度定位方法 [J]. 激光与光电子学进展, 2019, 56(16): 160601.
- [7] Hao H G, Zhang D D, Tang S. Analysis of the LED lamp arrangement for uniformity of illumination in indoor VLC system[J]. Journal of the Optical Society of Korea, 2014, 18(6): 663-671.
- [8] Hu J Y. Research on indoor lighting source layout based on neural network [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019.  
胡建宇. 基于神经网络的室内光源布局的研究 [D]. 南京: 南京邮电大学, 2019.
- [9] Zhou Z S, Ye W P. Convex optimization based LED lamps arrangement for visible light communication [J]. Microcomputer & Its Applications, 2016, 35(12): 70-72.  
周中山, 叶蔚萍. 基于 Convex 最优化的室内可见光通信灯排布 [J]. 微型机与应用, 2016, 35(12): 70-72.
- [10] Hou Y N, Xue Y K, Chen C, et al. A RSS/AOA based indoor positioning system with a single LED lamp[C]//2015 International Conference on Wireless Communications & Signal Processing (WCSP), October 15-17, 2015, Nanjing, China. New York: IEEE Press, 2015: 1-4.
- [11] Bian G L, Huang H S, Wang A Y, et al. Optimization of wireless sensor network positioning based on PSO-BP algorithm[J]. Telecommunication Engineering, 2017, 57(2): 139-144.  
卞国龙, 黄海松, 王安忆, 等. 基于 PSO-BP 算法的无线传感器网络定位优化 [J]. 电讯技术, 2017, 57(2): 139-144.
- [12] Fu S Y, Wang H D. Indoor positioning of wireless network based on harmony search algorithm optimizing neural network [J]. Journal of Nanjing University of Science and Technology, 2017, 41(4): 428-433.  
付思源, 王华东. 和声搜索算法优化神经网络的无线网络室内定位 [J]. 南京理工大学学报, 2017, 41(4): 428-433.
- [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] Nadeem U, Hassan N U, Pasha M A, et al. Indoor positioning system designs using visible LED lights: performance comparison of TDM and FDM protocols [J]. Electronics Letters, 2015, 51(1): 72-74.
- [15] Meng H, Yuan F, Yan T H, et al. Indoor positioning of RBF neural network based on improved fast clustering algorithm combined with LM algorithm[J]. IEEE Access, 2019, 7: 5932-5945.
- [16] 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.
- [17] Ding J P. Visible light communications indoor channel modeling & performance optimization [D]. Beijing: Beijing University of Posts and Telecom, 2013.  
丁举鹏. 可见光通信室内信道建模及性能优化 [D]. 北京: 北京邮电大学, 2013.
- [18] Jamil M, Yang X S. A literature survey of benchmark functions for global optimisation problems [J]. International Journal of Mathematical Modelling

- and Numerical Optimisation, 2013, 4(2): 150-194.
- [19] Yang X S. Flower pollination algorithm for global optimization [M]//Durand-Lose J, Jonoska N. Unconventional computation and natural computation. Lecture notes in computer science. Heidelberg: Springer, 2012, 7445: 240-249.
- [20] Zhou Y Q, Wang R, Luo Q F. Elite opposition-based flower pollination algorithm [J]. Neurocomputing, 2016, 188: 294-310.
- [21] Zhao C Y. Application research of flower pollination algorithm [D]. Nanning: Guangxi University for Nationalities, 2017.  
赵程檐. 花授粉算法的研究及应用[D]. 南宁: 广西民族大学, 2017.
- [22] Chicco G. Overview and performance assessment of the clustering methods for electrical load pattern grouping[J]. Energy, 2012, 42(1): 68-80.