

光学学报

基于并行全连接卷积神经网络模型的室内可见光信道的最优光源布局

张慧颖*, 卢宇希, 梁誉, 王凯

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LED光源光强分布不平坦、传统Lambert模型未考虑非直射信道、环境中噪声和干扰、障碍物遮挡、室内边界及不规则房间布局等问题,提出基于并行全连接-卷积神经网络(PFCNN)模型的室内可见光定位(VLP)最优光源布局方案。通过采集现场光源坐标、功率和朝向角等光源信息及其对应的接收平面光强分布构建指纹库数据集,并用蒙特卡罗方法衡量光强分布平坦度参数;提出采用全连接神经网络和并行全连接神经网络建立可见光信道模型;基于PFCNN模型构建光强平坦度预测模型;采用动量粒子群优化K-Means++(Mot-PSO-K-Means++)算法实现最优光源布局。仿真分析可知:并行全连接神经网络相比全连接神经网络精确度提升84.69%;在5 m×5 m×3 m的室内空间中,4-LED布局下光强平坦度达到92.00%,光强范围为340~440 lx;12-LED布局下光强平坦度达到91.00%,光强范围为980~1120 lx。该方案有更高的平坦度、较强适用性,可应用于实际室内VLP场景,为室内VLP深入研究提供理论支撑。

关键词 光通信; 室内可见光信道; 最优光源布局; 全连接神经网络; 并行全连接-卷积神经网络; 蒙特卡罗方法; Mot-PSO-K-Means++; 可见光定位

中图分类号 TN929.12

文献标志码 A

DOI: 10.3788/AOS202242.1306001

Optimal Light Source Layout for Indoor Visible Light Channel Based on Parallel Fully Connected Convolutional Neural Network Model

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

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

Abstract Indoor light-emitting diode (LED) light sources are with non-flat light intensity distribution, and the conventional Lambert model fails to take indirect channels, noise and interference in the environment, obstruction, interior borders, and irregular room layouts into account. To address these problems, this paper proposes an optimal light source layout scheme based on a parallel fully connected convolutional neural network (PFCNN) model for indoor visible light positioning (VLP). The datasets in the fingerprint database are constructed by collecting light source information, such as the coordinates, power, and orientation angle of the light source, and the corresponding light intensity distribution on the receiving plane. The parameter characterizing the flatness of light intensity distribution is measured by a Monte Carlo method, and a fully connected neural network and a parallel fully connected neural network are utilized to build a visible light channel model. A prediction model for light intensity flatness is then developed by the proposed PFCNN model, and an optimal light source layout is achieved by the momentum particle swarm optimization K-Means++ (Mot-PSO-K-Means++) algorithm. Simulation analysis shows that parallel fully connected neural networks improve accuracy by 84.69% compared with that of fully connected neural networks. In the 5 m×5 m×3 m indoor space, light intensity flatness reaches 92.00% under the 4-LED layout, and light intensity ranges from 340 lx to 440 lx. Those under the 12-LED layout are, respectively, 92.00% and 980-1120 lx. Therefore, the proposed scheme, with higher flatness and applicability, can be applied to actual indoor VLP scenes, and it can provide theoretical support for in-depth research of indoor VLP.

Key words optical communications; indoor visible light channel; optimal light source layout; fully connected neural

收稿日期: 2021-11-12; 修回日期: 2021-12-18; 录用日期: 2021-12-27

基金项目: 吉林省自然科学基金联合基金(YDZJ202101ZYTS189)、吉林化工学院科研项目(2021050)

通信作者: *yingzi1313@163.com

network; parallel fully connected convolutional neural network; Monte Carlo method; Mot-PSO-K-Means++ ; visible light positioning

1 引言

现有主流的定位技术全球卫星定位系统(GPS)^[1]的定位虽能够提供较高精度,但在卫星信号不良的场所难以提供可靠定位。基于可见光通信(VLC)的VLP^[2-5]弥补了GPS定位缺陷,但传统光源布局接收面光照强度不均匀,导致室内可见光定位(VLP)精度较低。周中山等^[6]在分析基于Convex最优化的室内VLC灯排布中发现接收光照平坦度与通信性能正相关,但提出的优化方案无法保证得到最优理论解是单个LED灯功率的倍数;杨智群等^[7]发现通过改善接收光功率分布均匀性,可保证处于室内不同方位的多个用户均能够获得良好的通信质量,但采用蚁群算法优化功率时容易陷入局部最优;王加安等^[8]采用粒子群(PSO)算法获取最优光源布局,但该方法仅针对功率进行调整,布局方式仍然采用传统圆形排布方式;胡建宇^[9]提出基于神经网络的灯源布局方案,但神经网络模型过于简单,特征空间维度较低;翟长鑫等^[10]提出在椭圆形布局下采用鱼群算法优化光功率分布,但该方案仅对灯源功率值进行优化,并未对布局实现优化;韩雨等^[11]提出采用鲸鱼优化算法优化灯源布局,但其光源参数不可调,且光照均匀度有待提高;Wang等^[12]采用优化人工鱼群算法寻找最优光源布局,但该算法的适应度函数易使结果陷入局部最优;Zhai等^[13]提出采用多种群遗传算法优化灯源布局,将灯源的位置、功率和角度等信息作为优化目标,但其模型和布局不适用于现实中的复杂场景;Zhang等^[14]通过分析多种噪声、光源布局方案下的VLP性能,发现灯源布局寻优过程要兼顾噪声;Ding等^[15]采用进化算法优化灯源功率分布,但该方案需大量LED且不适用较大场景;Liu等^[16]提出一种基于基因密度改进的遗传算法来优化灯源布局,但Lambert模型^[17]仅考虑一次反射且忽略噪声影响,仍需对其进行改进。

基于以上问题,本文采用全连接神经网络和并行全连接神经网络(PFCNN)建立室内VLC信道模型,在并行全连接神经网络模型基础上串接卷积神经网络以构建PFCNN模型,结合蒙特卡罗方法建立由灯源布局信息预测光照平坦度参数的模型;采用基于动量

因子、反向卷积网络和K-Means++优化传统PSO的Mot-PSO-K-Means++算法,对初始种群进行优化以解决传统PSO迭代速度慢的问题;提出采用Mot-PSO-K-Means++算法建立PFCNN平坦度预测模型下的最优光源布局方案,解决传统Lambert模型中难以考虑的非直射信道、环境中噪声和干扰、障碍物遮挡、室内边界及不规则房间布局等问题,以获取更符合实际室内空间场景、光强分布更均匀的最佳光源布局方案。该方案适用于实际室内VLP系统,通用性较强。

2 光强分布模型及指纹库构建

在5 m×5 m×3 m的室内环境下设置n个LED光源作为信号发射器,将其坐标映射到二维张量。LED参数张量为 $[Z_1, Z_2, \dots, Z_n]$ [下文中记为Light_info⁽ⁿ⁾],其中 $Z_1=[x_1, y_1, z_1, \omega_1, \varphi_1, \psi_1, P_1]$, $Z_2=[x_2, y_2, z_2, \omega_2, \varphi_2, \psi_2, P_2]$, $Z_n=[x_n, y_n, z_n, \omega_n, \varphi_n, \psi_n, P_n]$, ω_i 和 φ_i 为第i个LED的水平朝向角, ψ_i 为LED的发射角, P_i 为LED的光强值, (x_i, y_i, z_i) 为灯源位置,i代表第i个灯源,取值范围为 $[0, n]$ 。将距地面高度为h处平面作为接收平面。本文中n取4和12,h取0.85 m。光强分布模型如图1所示。




图1 光源布局方式
Fig. 1 Light source layout

提出一种节点反射模型以优化NLOS(Non Line of Sight)信道,如图2(a)所示。由直射节点和灯源位置计算墙面反射点,得到灯源至墙面的直射强度及由墙面反射至节点处的反射光强。传统NLOS信道模




图2 反射模型。(a)节点反射模型;(b)传统反射模型
Fig. 2 Reflection models. (a) Node reflection model; (b) traditional reflection model

型如图 2(b)所示,由于反射节点与直射节点不重合,计算量及误差较大。本文方法得到的光强可与直射模型的光强直接进行线性组合,相较于传统模型计算量更小,精确度更高。

已知光源 $X(x_1, y_1, z_1)$ 和节点 $Y(x_2, y_2, z_2)$, 通过反射节点位置公式得到墙面反射点 $A(0, y_a, z_a)$, $B(5, y_b, z_b)$, $C(x_c, 0, z_c)$, $D(x_d, 5, z_d)$, 如图 3(a)

所示。

反射点计算原理如图 3(b)所示。将点 X, Y, A 所在平面方程与墙面方程联立, 求解出投影直线方程 L ; 采用空间点线距离公式计算 X, Y 在 L 上的投影点 $I_1(x_{p1}, y_{p1}, z_{p1}), I_2(x_{p2}, y_{p2}, z_{p2})$, 因入射角与反射角相等, 由余弦公式有 XA 模长和 I_1A 模长的比值与 YA 模长和 I_2A 模长的比值相等, 即




图 3 反射节点位置。(a)反射点位置;(b)反射点计算原理

Fig. 3 Reflection node positions. (a) Reflection point positions; (b) calculation principle of reflection points

$$L: \begin{cases} \begin{vmatrix} x-x_1 & y-y_1 & z-z_1 \\ x_2-x_1 & y_2-y_1 & z_2-z_1 \\ x_3-x_1 & y_3-y_1 & z_3-z_1 \end{vmatrix} = 0 \\ y=0 \end{cases} \quad (1)$$

$$\frac{\sqrt{(x_2-x_1)^2 + y_1^2 + (z_2-z_1)^2}}{\sqrt{(x_2-x_{p1})^2 + y_{p1}^2 + (z_2-z_{p1})^2}} = \frac{\sqrt{(x_3-x_2)^2 + y_3^2 + (z_3-z_2)^2}}{\sqrt{(x_2-x_{p2})^2 + y_{p2}^2 + (z_2-z_{p2})^2}}$$

将 LED 灯源的位置、角度、功率等信息作为输入数据, 在接收平面上构建等间距的 11×11 网格, 放置接收器对信号数据进行采样。用 $\text{Power_info}^{(n)}$ 表示

$\text{Light_info}^{(n)}$ 布局下的接收平面光强分布。其中节点反射 Lambert 模型的指纹库数据集如表 1 所示。

表 1 节点反射 Lambert 模型指纹库

Table 1 Node reflection Lambert model fingerprint library

Number	4-LED information	Power distribution for 4-LED	12-LED information	Power distribution for 12-LED
1	$\text{Light_info}_1^{(4)}$	$\text{Power_info}_1^{(4)}$	$\text{Light_info}_1^{(12)}$	$\text{Power_info}_1^{(12)}$
2	$\text{Light_info}_2^{(4)}$	$\text{Power_info}_2^{(4)}$	$\text{Light_info}_2^{(12)}$	$\text{Power_info}_2^{(12)}$
\vdots	\vdots	\vdots	\vdots	\vdots
1000	$\text{Light_info}_{1000}^{(4)}$	$\text{Power_info}_{1000}^{(4)}$	$\text{Light_info}_{1000}^{(12)}$	$\text{Power_info}_{1000}^{(12)}$

发射端信号经过可见光信道传输后, 接收端采用光电探测器 (PD) 接收到的信噪比为

$$\begin{cases} \sigma_{\text{shot}}^2 = 2qRP_r B + 2qI_{\text{dc}} \zeta_2 B \\ \sigma_{\text{thermal}}^2 = 8\pi k T_k \eta A \zeta_2 B^2 / G + 16\pi^2 k \Gamma T_k \eta^2 A^2 \zeta_3 B^3 / g_m \\ R_{\text{SN}} = (RP_r)^2 / \left\{ \sigma_{\text{shot}}^2 + \sigma_{\text{thermal}}^2 + [RP_{r(\text{ISI})}]^2 \right\} \end{cases} \quad (2)$$

式中: σ_{shot}^2 和 $\sigma_{\text{thermal}}^2$ 分别为散粒噪声和热噪声方差; B 为等效噪声带宽; A 为 PD 检测面积; R 为 PD 的响应率; $P_{r(\text{ISI})}$ 为码间干扰功率; P_r 为 LED 功率; q 为电荷量; I_{dc} 为暗电流; ζ_2 和 ζ_3 为噪声带宽因子; k 为玻尔兹曼常数;

T_k 为绝对温度; η 为光电探测器电容; G 为开环电压增益; Γ 为信道噪声因子; g_m 为场效应晶体管 FET (Field Effect Transistor) 跨导。

3 神经网络信道及平坦度预测模型建立

3.1 全连接神经网络信道模型构建

神经网络^[18]具有拟合输入至输出映射过程的功能。通过搭建适当网络结构, 采用指纹库数据对网络进行训练后得到神经元的权重、偏置矩阵, 实现多元、多变量的非线性回归, 由灯源信息计算接收面光强矩

阵,实现室内可见光信道模型建立。

由指纹库中数据集建立全连接层(Dense Layer)神经网络,如图 4 所示。图中的输入层输入数据为灯源信息,其中包含不同 LED 灯源布局下的所有 LED 的位置信息、朝向角信息和功率信息,将其平铺后作为

输入。 $w^{(i)}=[w_{11}^{(i)},w_{12}^{(i)},\dots,w_{mn}^{(i)}]$ 为第 i 层隐藏层权重信息, $b^{(i)}=[b_1^{(i)},b_2^{(i)},\dots,b_n^{(i)}]$ 为第 i 层偏置量。经过深层神经网络得到不同 LED 分布对应的光强分布矩阵平铺数据。 P_n 为第 n 个 LED 的光强值。




图 4 全连接神经网络模型

Fig. 4 Fully connected neural network model

第 p 层隐藏层的输入 $L_i^{(p)}$ 为

$$L_i^{(p)} = w^{(p-1)} L_o^{(p-1)} + b^{(p-1)}, \quad (3)$$

式中: $w^{(p-1)}$ 为第 $p-1$ 层的权重; $b^{(p-1)}$ 为第 $p-1$ 层的偏置; $L_o^{(p-1)}$ 为第 $p-1$ 层隐藏层的输出,表达式为

$$L_o^{(p)} = \text{Activation}[L_i^{(p)}], \quad (4)$$

式中:Activation(\cdot)为采用的激活函数,用于为映射过程添加非线性因子。通过式(2)、(3)得到由输入层(input layer)到输出层(output layer)的张量计算,该输入至输出的映射即室内可见光信道模型。其变量为隐藏层中的权重 $w^{(i)}$ 和偏置 $b^{(i)}$,更新后有

$$w^{(i)} = w^{(i)} - \mu \frac{\partial F_{\text{cost}}}{\partial w^{(i)}} = w^{(i)} - \frac{\mu}{M} \sum_{i=1}^M \frac{\partial f_{\text{Loss}}}{\partial w^{(i)}}, \quad (5)$$

$$b^{(i)} = b^{(i)} - \mu \frac{\partial F_{\text{cost}}}{\partial b^{(i)}} = b^{(i)} - \frac{\mu}{M} \sum_{i=1}^M \frac{\partial f_{\text{Loss}}}{\partial b^{(i)}}, \quad (6)$$

式中: $w^{(i)}$ 为 $w^{(i)}$ 更新后的权重; $b^{(i)}$ 为 $b^{(i)}$ 更新后的偏置; f_{Loss} 为损失函数,即预测的输出与实际输出的误差; F_{cost} 为代价函数; μ 为学习率; M 为训练集样本数。通过采用指纹库数据集对该全连接神经网络模型进行训练,并由灯源布局预测光强分布,得到符合实际环境的室内可见光信道模型。

3.2 并行全连接神经网络信道模型

为使神经网络信道模型符合实际复杂场景,通过对网络纵向扩展来增加神经元,以提升精确度,因此本文构建并行全连接神经网络,通过将输出标签切分成 n 份,使输出维度 m 小于等于输入维度,将输入分别对 n 份输出标签进行映射,最后将结果进行拼接,得到预测结果。并行全连接神经网络结构如图 5 所示。

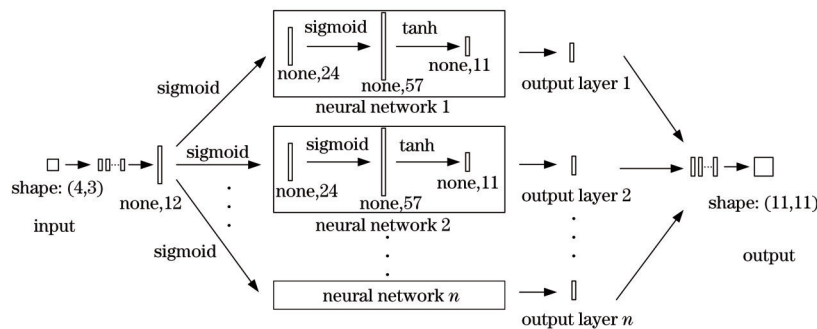


图 5 并行全连接神经网络模型

Fig. 5 Parallel fully connected neural network model

图 5 中输入层与原全连接层相同,采用灯源信息张量作为输入,输出层将原本的 11×11 维 label 划分为

n 份,分别作为每个 output layer 的训练标签;每层 hidden layer 选用全连接神经网络。由于每个 neural

network 接收到的输入数据和输出数据具有相同的特征维度,选取相同的网络结构。通过调节 neural network 个数 n ,使每层 output layer 的数据维度改变为采样网格点个数。随着 n 的增大,神经网络的计算量增大,预测精度提升, n 的取值范围为 $[1, M_{\text{mesh}}]$, M_{mesh} 为 meshgrid 节点个数。

本文选用的节点个数为 11×11 ,故选取 $n=11$ 作为 neural network 个数。并行神经网络的个数 n 取值较大,且其压缩输出特征后信息维度降低。为实现并行计算,将输入、输出数据及隐藏层权重和偏置在矩阵中列向广播,构建新的权重和偏置矩阵:

$$B^{(p)} = [b_1^{(p)}, b_2^{(p)}, \dots, b_n^{(p)}]^T, \quad (7)$$

$$W^{(p)} = [w_1^{(p)}, w_2^{(p)}, \dots, w_n^{(p)}]^T, \quad (8)$$

式中: $b_n^{(p)}$ 为第 n 个神经网络第 p 个隐藏层的偏置量; $w_n^{(p)}$ 为第 n 个神经网络第 p 个隐藏层的权重。

得到第 i 层的输出结果 $o_{\text{output}}^{(i)}$ 为

$$o_{\text{output}}^{(i)} = W^{(i-1)} i_{\text{input}} + B^{(i-1)}, \quad (9)$$

式中: i_{input} 为第 i 层的输入量。

相较于全连接神经网络,采用并行全连接神经网络能够获取更准确的预测结果,即更准确的信道模型。




图 6 卷积-空洞卷积模型

Fig. 6 Convolution-Dilated Convolution model

为保证卷积层的输出张量中每层维度相同,对卷积和空洞卷积设置相同大小和个数的卷积核。为使经过卷积后的数据能够堆叠,采用边缘填充(padding)保证空洞卷积输出维度与卷积输出维度相同,填充大小与空洞卷积间隔大小相同。

输入层数据分别经过不同比率的空洞卷积运算后,得到两个形状完全相同的张量在第一个维度上的叠加,即

$$C_{\text{Convolution } x,y} = \sum_{a=0}^{p \times q} w_a v_a + \sum_{b=0}^{m \times n} w_b v_b, \quad (11)$$

式中: a 为全卷积卷积核滑动扫描的感受野; b 为空洞卷积卷积核滑动扫描的感受野; w_a, v_a 分别为第 a 个张量和全卷积核的参数; w_b, v_b 分别为第 b 个张量和空洞卷积核参数。

由于实际光强分布为连续可微曲面,为去除冗余数据、扩大提取特征范围,采用池化层,则有

$$O_{x',y'} = \frac{\sum_{\delta x, \delta y \in \Omega} F(I)_{x+\delta x, y+\delta y} I_{x+\delta x, y+\delta y}}{\sum_{\delta x, \delta y \in \Omega} F(I)_{x+\delta x, y+\delta y}}, \quad (12)$$

3.3 卷积神经网络平坦度预测模型

为构建 One-Stage 结构神经网络以实现快速预测,采用卷积网络^[19]实现光照平坦度预测。

将光强分布作为卷积神经网络的输入,将光强平坦度作为标签构建卷积神经网络。为使平坦度参数符合实际场景,采用蒙特卡罗^[20]方法计算光强分布平坦度参数,通过将平坦度值计算转化为光强矩阵计算中满足区间 $[\bar{p} - (p_{\text{max}} - p_{\text{min}})\xi, \bar{p} + (p_{\text{max}} - p_{\text{min}})\xi]$ 的概率值,该概率值作为平坦度参数用于神经网络训练。其中, $\bar{p}, p_{\text{max}}, p_{\text{min}}, \xi$ 分别表示光强均值、最大光强、最小光强、区间阈值,区间阈值取 0.3。

卷积层进行特征提取,其中 $p \times q$ 为张量维度, w_i, v_i 分别为第 i 个张量和卷积核参数,则卷积层提取的特征为

$$C_{\text{Convolution } x,y} = \sum_i^{p \times q} w_i v_i \quad (10)$$

本文提出的卷积-空洞卷积模型(Conv2D-Dilated Conv2D)在张量数据经过卷积压缩后依然有较好的信息表现能力,避免传统卷积易丢失信息和感受野较小的问题,如图 6 所示。

式中: $F(I)_{x+\delta x, y+\delta y}$ 为池化函数,本文选取平均池化,即
$$F(I)_{x+\delta x, y+\delta y} = \frac{1}{\delta x + \delta y} \sum_{x, y}^{x+\delta x, y+\delta y} I_{x, y}; I_{x+\delta x, y+\delta y}$$
 为卷积核滑动到的窗口上对应的输入张量; $O_{x', y'}$ 为输出张量在 (x', y') 位置上的值。

将经过多次卷积和池化操作后得到的特征数据平铺并映射到全连接层的特征空间,从而得到光强平坦度值。由误差反向更新每层中的卷积核等参数,迭代后得到学习结果。更新池化层和池化层参数的过程如下:

1) 池化层误差更新,即从池化层得到的结果反推池化层输入,对其进行上采样操作:

$$\delta^{(l-1)} = \text{Upsample}[\delta^{(l)}] \odot \sigma[z^{(l-1)}], \quad (13)$$

式中: Upsample(\cdot) 代表上采样操作; \odot 代表卷积运算; $\delta^{(l)}$ 为第 l 层池化层输出张量; $\sigma[z^{(l-1)}]$ 为 $z^{(l-1)}$ 经过激活函数的导数; $z^{(l-1)}$ 为第 $l-1$ 层池化层输入张量。

2) 卷积层误差更新:

$$\delta^{(l-1)} = \delta^{(l)} \frac{\partial z^{(l)}}{\partial z^{(l-1)}} = \delta^{(l)} \text{rot180}[w^{(l)}] \odot \sigma[z^{(l-1)}], \quad (14)$$

式中: $\text{rot}180(\cdot)$ 为将张量旋转 180° 。

3) 对卷积核权重 \boldsymbol{w} 和偏置 \boldsymbol{b} 进行梯度更新:

$$\frac{\partial J(\boldsymbol{w}, \boldsymbol{b})}{\partial \boldsymbol{w}^{(l)}} = \frac{\partial J(\boldsymbol{w}, \boldsymbol{b})}{\partial \boldsymbol{z}^{(l)}} \cdot \frac{\partial \boldsymbol{z}^{(l)}}{\partial \boldsymbol{w}^{(l)}} = \delta^{(l)} \text{rot}180[\boldsymbol{a}^{(l-1)}], \quad (15)$$

$$\frac{\partial J(\boldsymbol{w}, \boldsymbol{b})}{\partial \boldsymbol{b}^{(l)}} = \sum_{u,v} [\delta_{u,v}^{(l)}], \quad (16)$$

式中: $\boldsymbol{a}^{(l-1)}$ 为第 $l-1$ 层张量; $J(\boldsymbol{w}, \boldsymbol{b})$ 为关于 \boldsymbol{w} 和 \boldsymbol{b} 的代价函数; $\delta_{u,v}^{(l)}$ 为误差 δ 的各子张量。

并行全连接神经网络和卷积神经网络均在 Python 环境中实现, 将两个神经网络的输入和预测结果封装成函数, 采用嵌套的方式将并行全连接神经网络与卷积神经网络进行串联, 得到 PFCNN, 实现由灯

源布局信息预测接收面光强分布和光照平坦度。

4 LED 灯源最优布局建模

在给定室内环境内任意灯源布局下的光强模型和平坦度预测时, 将其映射关系表示为 $N([\boldsymbol{x}_1, \dots, \boldsymbol{P}_1], [\boldsymbol{x}_2, \dots, \boldsymbol{P}_2], \dots, [\boldsymbol{x}_n, \dots, \boldsymbol{P}_n]) = P$ (下文用 $\boldsymbol{\theta}$ 表示输入变量, $\boldsymbol{\theta}_i$ 表示第 i 个灯源输入变量, \boldsymbol{x}_n 为第 n 个灯源的位置信息, \boldsymbol{P}_n 为第 n 个灯源的光强信息), 其中, $N(\cdot)$ 代表神经网络映射关系。光照平坦度值 P 越接近 1 越平坦, 取映射关系 $|N(\boldsymbol{\theta})|$ 作为目标映射。由于映射后的变量为二维变量, 利用二维张量下的带动量 PSO (Mot-PSO) 寻找最优布局解:

$$P = N([\boldsymbol{x}_1, \dots, \boldsymbol{P}_1], [\boldsymbol{x}_2, \dots, \boldsymbol{P}_2], \dots, [\boldsymbol{x}_n, \dots, \boldsymbol{P}_n]) = N(\boldsymbol{\theta}). \quad (17)$$

适应度函数值 $F(\boldsymbol{\theta}_i)$ 为

$$F(\boldsymbol{\theta}_i) = N(\boldsymbol{\theta}_i) - 1. \quad (18)$$

当前位置张量 \boldsymbol{P}_k 更新策略为

$$\boldsymbol{P}_{k+1} = \boldsymbol{P}_k + \boldsymbol{V}_k, \quad (19)$$

式中: \boldsymbol{V}_k 为速度张量。

速度张量的更新策略为

$$\boldsymbol{V}_{k+1} = \boldsymbol{V}_k + C_1 \times \boldsymbol{\xi} \times \text{random}(0, 1) \times (\boldsymbol{P}_i - \boldsymbol{P}_k) + C_2 \times (1 - \boldsymbol{\xi}) \times \text{random}(0, 1) \times (\boldsymbol{P}_g - \boldsymbol{P}_k), \quad (20)$$

式中: $\boldsymbol{\xi}$ 为指数加权平均移动法的动量因子; C_1 和 C_2 分别为自我学习因子和社会学习因子; \boldsymbol{P}_i 和 \boldsymbol{P}_g 分别为个体最优和全局最优位置张量; $\text{random}(0, 1)$ 为服从 0 到 1 均匀分布的随机数。本文取 C_1, C_2 和 $\boldsymbol{\xi}$ 分别为 1.5, 1.5, 0.8。结合 CNN 改进 K-Means++ 对 PSO^[21] 进行初始化, 从而提高迭代速率, 避免局部收敛。为降低输入参数量, 将 (x_i, y_i, z_i) 作为粒子群在空间中的位置参数。由于 $\boldsymbol{\theta}$ 中包含三轴方向, 故不再采用传统粒子群中的速度这一矢量参数, 采用标量数据速率作为其位置更新策略。其中 $\boldsymbol{\theta}_i = [[x_1, \dots, \boldsymbol{P}_1], [x_2, \dots, \boldsymbol{P}_2], \dots, [x_n, \dots, \boldsymbol{P}_n]]$ 为形状 $n \times m$ 的张量数据, n 为每个 LED 的参数个数, m 为 LED 个数。Mot-PSO-K-Means++ 算法和 K-Means++ 改进算法的流程分别如图 7 和图 8 所示。

如图 7 所示, 采用改进的 K-Means++ 算法对指纹库中平坦度参数值最高的 100 组数据进行聚类, 其聚类中心点作为 Mot-PSO 的初始种群, 计算每种灯源布局张量的适应度值 $F(\boldsymbol{\theta}_i)$, 更新局部最优位置 \boldsymbol{P}_i 和全局经历过的最优位置 \boldsymbol{P}_g 处的适应度值, 若未满足迭代结束条件, 更新速度张量 \boldsymbol{V} 和状态张量 \boldsymbol{K} , 并通过动量参数、学习因子和速度更新灯源布局种群位置, 重新计算 $F(\boldsymbol{\theta}_i)$, 更新 \boldsymbol{P}_i 和 \boldsymbol{P}_g , 直至最大迭代次数。相较于传统的 PSO, Mot-PSO-K-Means++ 算法增加 K-Means++ 搜索结果、增加动量因子、指定初始种群等步骤, 能更快搜寻到最优的灯源布局, 避免陷入局部最优。

K-Means++ 改进算法如图 8 所示, 采用指纹库

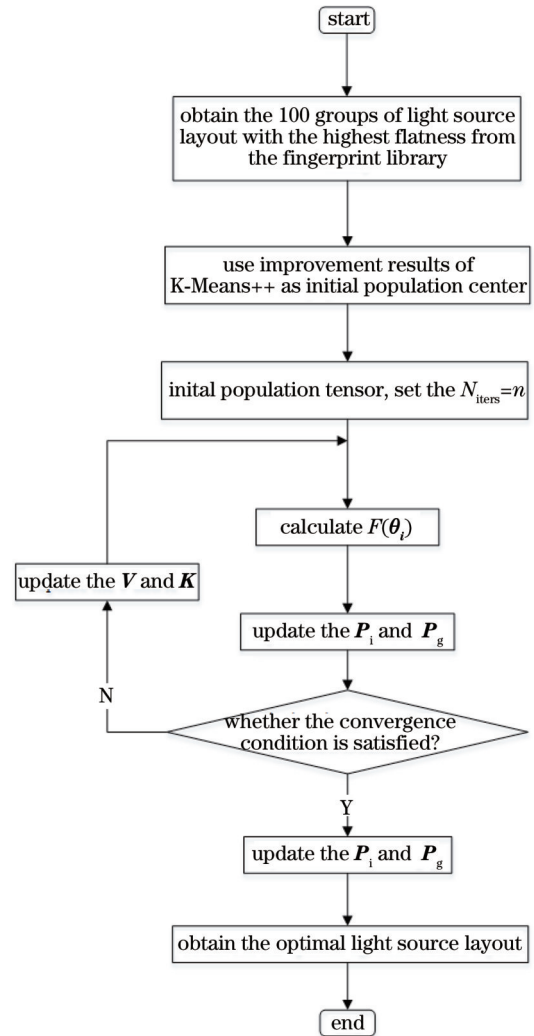


图 7 Mot-PSO-K-Means++ 流程图

Fig. 7 Flow chart of Mot-PSO-K-Means++

中的数据搭建由光强分布预测灯源布局的反向结构卷积神经网络。设置完全平坦的光强分布 (以 4-LED 为例, 每组光强分布的张量内所有元素值相等, 取值为

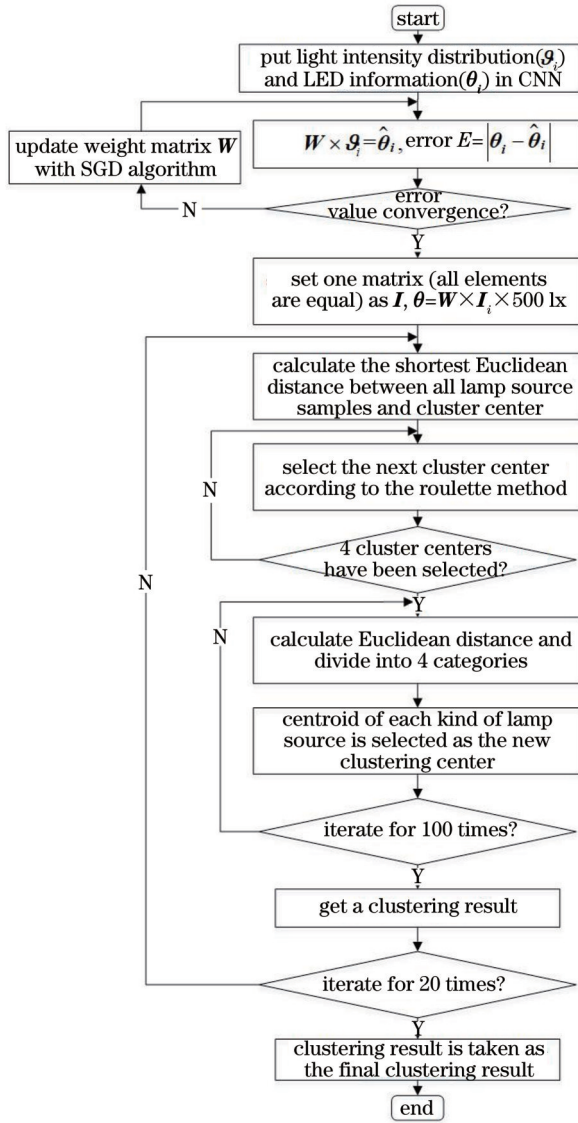


图 8 K-Means++改进流程图

Fig. 8 Flow chart of improvement of K-Means++

500 lx),采用反向结构的卷积网络,将光强分布预测模糊灯源布局信息作为初始化簇中心,计算每个种群与





图 9 损失值迭代曲线。(a) 4-LED 布局迭代曲线;(b) 12-LED 布局迭代曲线

Fig. 9 Loss value iteration curves. (a) Iteration curves of 4-LED; (b) iteration curves of 12-LED

5.2 并行全连接神经网络仿真分析

选用 meshgrid 节点个数为 11×11 ,故选取 $n=11$ 作为 neural network 个数。由于并行神经网络使用网络数量较多,且压缩输出特征后信息维度降低,通过表

簇中心的最短欧氏距离,并计算每个种群被选为下一聚类中心的概率,采用轮盘算法选取下一聚类中心,直到出现 4 个聚类中心,将所有个体到中心的距离分类到最小距离的类中,并在全部距离计算完成后采用均值更新聚类中心。本文在经典 K-Means++ 中增加反向结构的卷积网络以寻找模糊灯源信息作为初始簇中心的步骤,使聚类算法的迭代速度更快,同时使 Mot-PSO-K-Means++ 算法获取到更优初始种群。

5 仿真结果及分析

5.1 全连接神经网络仿真分析

构建结构如图 4 所示的全连接神经网络,神经网络的超参数如表 2 所示。Layer(type)表示顺序堆叠层的类型;Output shape 表示该层神经网络的输出数据各维度的尺度;Activation function 表示该层神经网络采用的非线性激活函数类型;Parameter No. 表示该层神经网络中含有的权重和偏置矩阵里的参数个数, None 表示张量第一维度为空。损失函数的迭代仿真结果如图 9 所示。

表 2 全连接神经网络的超参数

Table 2 Hyper-parameters of fully connected neural network

Layer (type)	Output shape	Activation function	Parameter No.
Dense	None, 32	Sigmoid	416
Dense	None, 64	tanh	2112
Dense	None, 80	None	5200
Dense	None, 121	None	9801

采用 4-LED 布局作为输入数据时的损失函数值迭代图如图 9(a)所示,迭代 15 次后损失函数值即平均绝对误差(MAE)收敛到 0.98。采用 12-LED 布局作为输入数据时损失函数值迭代图如图 9(b)所示,该神经网络是由低维到高维,难以实现特征提取,因此迭代 800 次后才收敛,损失函数值为 1.78。虽然通过增大指纹库、迭代次数能够降低误差,但效果较差。

2 所示的超参数,对并行神经网络结构进行配置。以 4-LED 布局为例,loss 值为最后 20 次迭代的损失函数均值。选取如表 3 所示的结构作为每个 neural network 的结构。需要注意的是,每个 neural network 仅有相同

表 3 并行 neural network 层超参数

Table 3 Hyper-parameters of parallel neural network

Layer (type)	Output shape	Activation function	Parameter No.
Dense	None, 24	Sigmoid	312
Dense	None, 57	tanh	1425
Dense	None, 11	None	638

的结构,其训练出的权重与偏置不同。

为降低并行神经网络的计算量,每个 neural network 的结构应选取在较低损失函数的前提下尽可能简单的结构,选用 3 层隐含层结构的神经网络以提升运算速度。图 10 为损失函数和神经元内核个数的关系曲线(MAE-NOK 曲线),神经网络隐含层内核个数为 57 时,表明损失函数值最低,室内可见光信道模型的精确度最高。

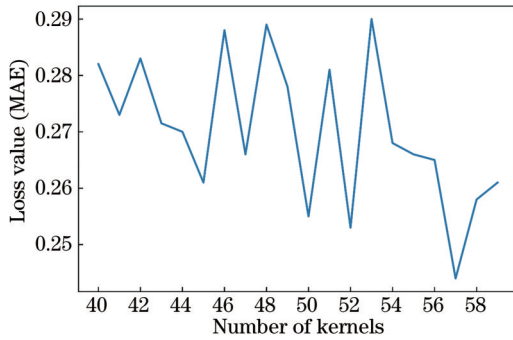


图 10 损失值-内核个数折线图

Fig. 10 Line graph of relation of MAE and number of kernels

图 11 为并行神经网络迭代的 MAE 曲线。4-LED 布局下采用并行神经网络相较于采用全连接神经网络的 MAE 从 0.98 降低至 0.15,精确度提升 84.69%。在 12-LED 布局下,由于并行神经网络的特征压缩特点是能更好地从高维度到低维度提取特征,迭代速度和精确度都显著提升。因此采用并行全连接网络建立的可见光信道模型相较于采用全连接神经网络有更高的精度、更快的训练和预测速度,可建立符合实际环境的室内可见光信道模型。




图 11 损失迭代曲线图

Fig. 11 Loss value iteration curves

5.3 PFCNN 仿真分析

在并行全连接神经网络之后串接超参数如表 4 所示的卷积神经网络,并对该神经网络采用卷积-空洞卷积进行特征提取。

表 4 卷积神经网络超参数

Table 4 Hyper-parameters of convolution neural network

Layer (type)	Output shape	Activation function	Parameter No.
Conv2D	None, 7, 9, 32	tanh	160
MaxPooling2D	None, 3, 4, 32	None	0
Conv2D	None, 2, 3, 64	Relu	8256
MaxPooling2D	None, 1, 1, 64	None	0
Dense	None, 32	Softmax	2080
Dense	None, 1	None	5

分别采用卷积神经网络和 PFCNN 预测光照平坦度值,仿真结果如图 12 所示。若基于卷积网络由灯源信息直接预测光照平坦度,网络在迭代 90 次后收敛,损失函数值为 0.20,预测精度较低,其迭代曲线如图 12(a)所示。由于使用的卷积神经网络缺少灯源信息到光照分布的映射,难以预测光照平坦度。采用 PFCNN 得到的损失函数值为 0.03,且 PFCNN 迭代 8 次后收敛,如图 12(b)所示。由此说明 PFCNN 迭代更快,预测精确度更高,相较于卷积神经网络预测精度提升 85%。

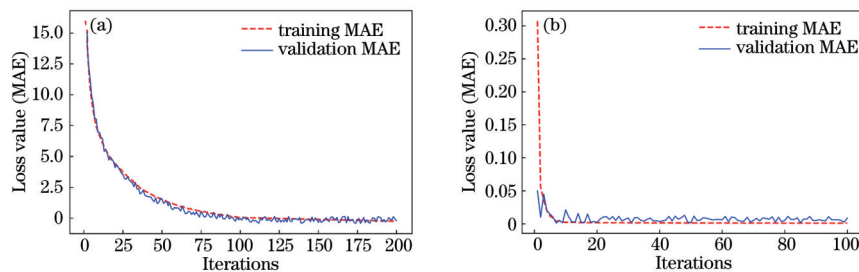


图 12 损失值迭代曲线。(a)卷积神经网络迭代曲线;(b) PFCNN 迭代曲线

Fig. 12 Loss value iteration curves. (a) Convolution neural network iteration curves; (b) PFCNN iteration curves

信道模型由灯源布局预测光照分布,若用灯源信息预测平坦度会导致参数缺失,网络维度不足;若构造较深的网络,则计算量极大。而 PFCNN 平坦度参数

来源是光照分布,本文提出的 PFCNN 具有迭代速度快、精度高的特点,能获取到更加精确的光照平坦度参数值。

5.4 Mot-PSO-K-Means++仿真分析

构建由光照分布预测灯源信息的卷积神经网络以得到平坦度较高的初始种群优化Mot-PSO。其损失函数如图13(a)所示。由图可知,损失函数值为0.07,精确度为93%;对该卷积网络输入100个完全平坦的光照分布,获取的100组预测灯源布局如图13(b)中的

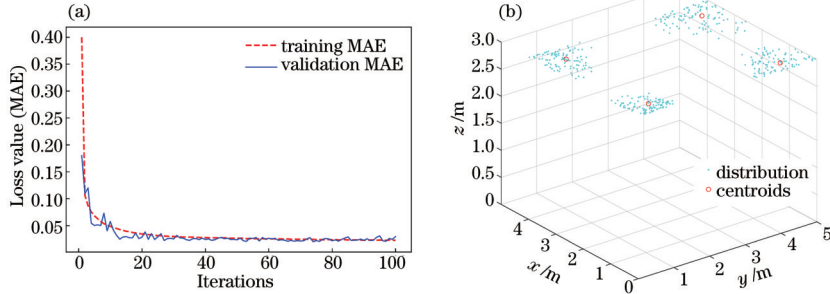


图 13 初始种群优化。(a)卷积神经网络迭代曲线;(b)改进K-Means++聚类中心

Fig. 13 Initial population optimization. (a) Iteration curves of convolution neural network; (b) clustering centers of improved K-Means++

采用 PSO、Mot-PSO 和 Mot-PSO-K-Means++ 三种算法寻找 PFCNN 信道模型的最优灯源布局信息,迭代 200 次的仿真结果如图 14 所示。由图 14 可知,PSO 迭代 80 次后才收敛,且最优灯源布局的平坦度为 0.60,说明陷入局部最优;Mot-PSO 在迭代至第 10、40 次时,在动量因子作用下跳出局部最优,使得寻找到的灯源布局结果更好,但由于初始种群不佳,




图 14 算法迭代曲线

Fig. 14 Algorithm iteration curves




图 15 基于方差参数的平坦度参数迭代曲线。(a) 4-LED 布局迭代曲线;(b) 12-LED 布局迭代曲线

Fig. 15 Flatness parameter iteration curves based on variance parameters. (a) 4-LED iteration curve; (b) 12-LED iteration curve

4-LED 的最优布局方式如图 16(a)所示,光照分布如图 16(b)所示,信噪比如图 16(c)所示。由仿真分

distribution 所示;对得到的 distribution 采用改进 K-Means++ 进行聚类,类中心如图 13(b)中的 centroids 所示。将聚类中心作为均值中心点,构建初始种群,使其服从正态分布,初始化种群张量,得到 Mot-PSO 的初始种群。

Mot-PSO 依然陷入局部最优,平坦度参数收敛于 0.76;Mot-PSO-K-Means++ 不仅迭代速度有所提升,且未陷入局部最优解,效果更好。相较于 PSO 和 Mot-PSO, Mot-PSO-K-Means++ 获取到的最优灯源平坦度更高,迭代速度更快,得到的最优平坦度参数为 0.86,即光照平坦度为 86%。

5.5 平坦度参数评估与最优灯源布局仿真

平坦度的衡量影响寻找的最优灯源布局。分别对基于方差的平坦度参数和基于蒙特卡罗方法的平坦度进行仿真分析,并对灯源布局优化前后的信噪比(SNR)进行分析。

5.5.1 基于方差的平坦度参数仿真

设置迭代参数为 200,平坦度参数为光照分布的方差,采用基于 K-Means++ 的改进带动量 PSO+ 算法迭代后,4-LED 布局和 12-LED 布局的迭代收敛曲线如图 15 所示。采用 4-LED 布局获取的最优平坦度参数为 0.848,即光照平坦度为 84.8%,采用 12-LED 布局获取的最优平坦度参数为 0.840,即光照平坦度为 84.0%。

析可知,光强分布的范围为 340~460 lx,光强波峰与波谷的差值为 120 lx;信噪比的范围为 9.4~11.5 dB,房

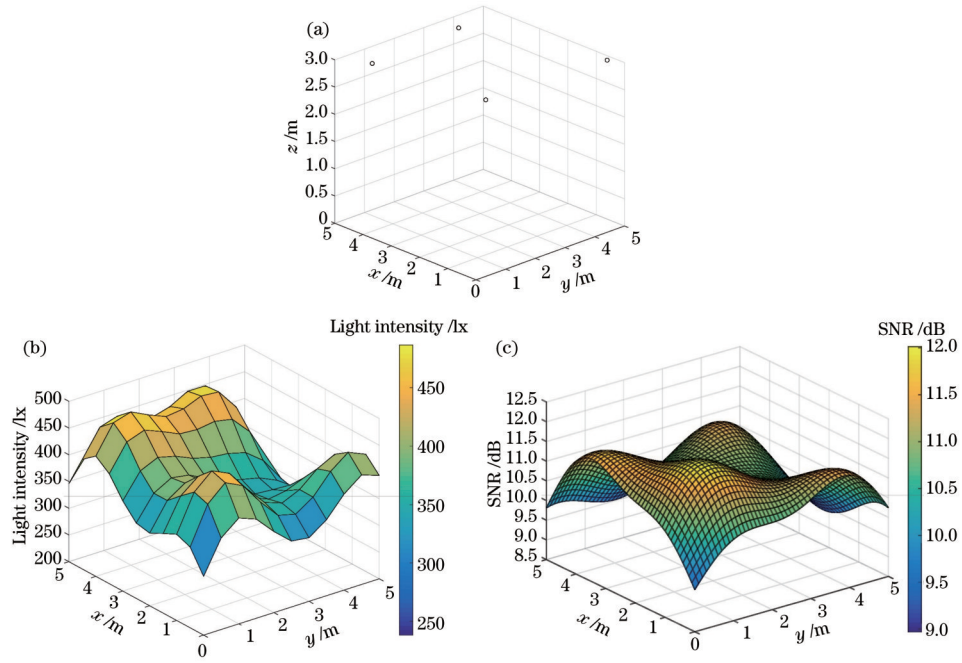


图 16 基于方差参数的 4-LED 最优布局。(a) 4-LED 最优位置；(b) 4-LED 光照分布；(c) 4-LED 信噪比分布
 Fig. 16 Optimal layouts of 4-LED based on variance parameters. (a) 4-LED optimal location; (b) intensity distribution of 4-LED; (c) SNR of 4-LED

间内接收信噪比的最大值和最小值的差值为 2.1 dB, 方差为 0.231, 在位置 $(x, y) = (3, 5)$ 处信噪比约为 9.4 dB。

12-LED 的最优布局方式如图 17(a) 所示, 光照分布如图 17(b) 所示, 信噪比如图 17(c) 所示。由图可知光强波动范围为 1000~1700 lx, 光强波峰与波谷的差值为 700 lx, 信噪比的范围为 10~17 dB, 房间内接收

信噪比最大值和最小值的差值为 7 dB, 方差为 3.731, 在位置 $(x, y) = (0, 0)$ 处信噪比约为 10 dB。群智能算法通过将多个 LED 重叠放置在边角处, 以接收面较大区域光强较低且平坦的方式投机获取最优灯源布局。该方法的最大光照值与最小光照值的偏差极大, 其原因在于采用的平坦度参数不合理。

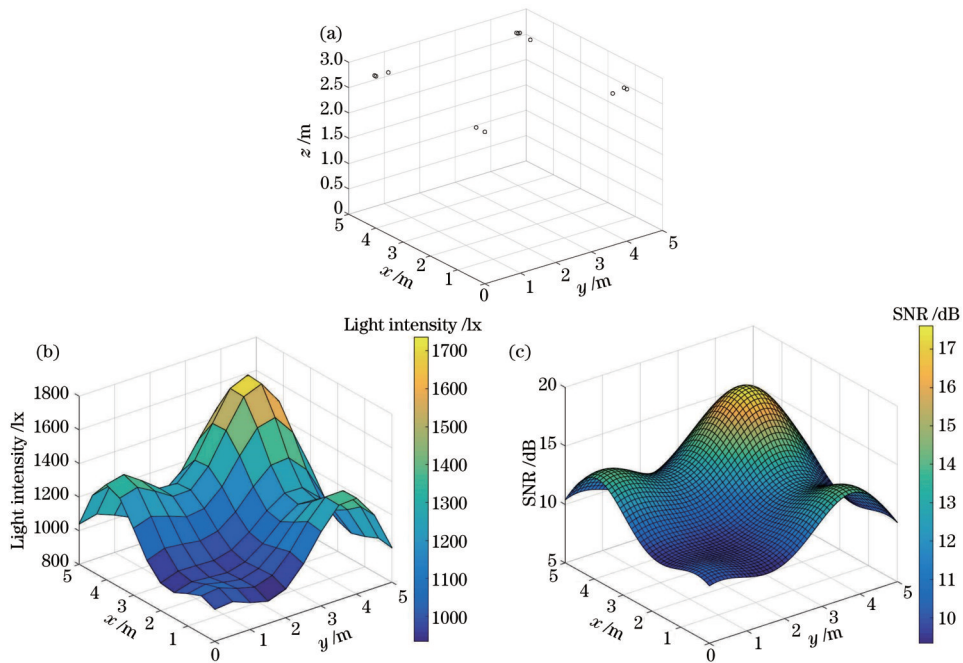


图 17 基于方差参数的 12-LED 最优布局。(a) 12-LED 最优位置；(b) 12-LED 光照分布；(c) 12-LED 信噪比分布
 Fig. 17 Optimal layouts of 12-LED based on variance parameters. (a) 12-LED optimal location; (b) intensity distribution of 12-LED; (c) SNR of 12-LED

5.5.2 蒙特卡罗方法的平坦度参数仿真

本文采用蒙特卡罗方法衡量光强平坦度,将计算光强分布平坦度问题转化为概率问题求解。采用蒙特

卡罗方法得到的参数作为优化目标,4-LED布局 and 12-LED布局的迭代收敛曲线如图 18 所示。




图 18 蒙特卡罗参数下的平坦度迭代曲线。(a) 4-LED 布局迭代曲线;(b) 12-LED 布局迭代曲线

Fig. 18 Flatness iteration curves under Monte Carlo parameters. (a) 4-LED iteration curve; (b) 12-LED iteration curve

由图 18(a)可知,4-LED 布局获取的最优平坦度参数为 0.92,即光照平坦度为 92%;由图 18(b)可知,12-LED 布局获取的最优平坦度参数为 0.91,即光照

平坦度为 91%。

4-LED 和 12-LED 布局的迭代结果和光照分布分别如图 19 和图 20 所示。

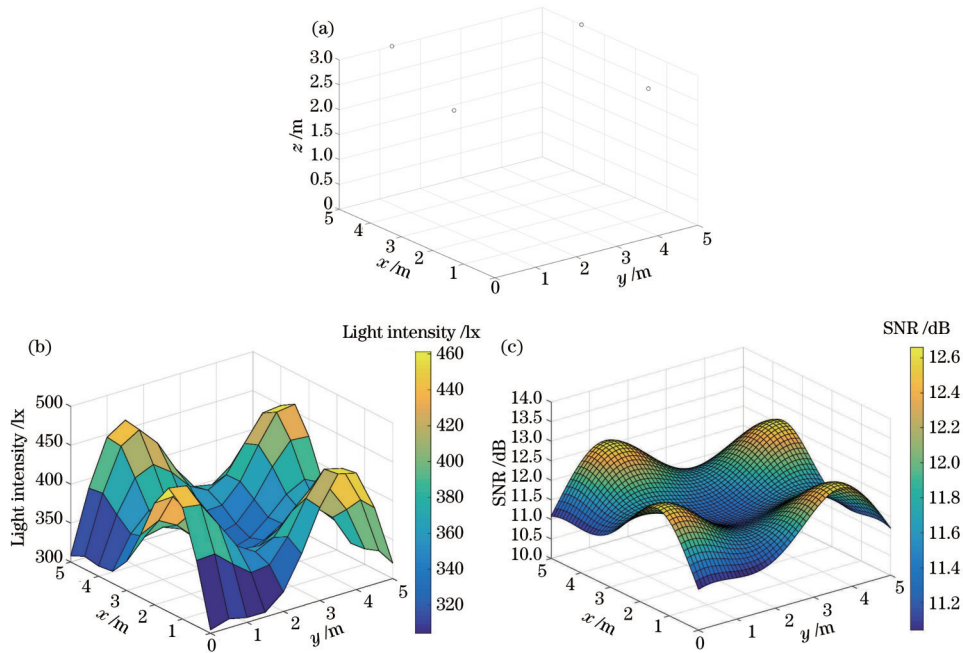


图 19 蒙特卡罗参数下的 4-LED 最优布局。(a) 4-LED 最优位置;(b) 4-LED 光照分布;(c) 4-LED 信噪比分布

Fig. 19 Optimal layouts of 4-LED under Monte Carlo parameters. (a) 4-LED optimal location; (b) intensity distribution of 4-LED; (c) SNR of 4-LED

由图 19 和图 20 可看出:4-LED 布局的光强分布范围为 340~440 lx,光强波峰与波谷的差值为 100 lx,相较基于方差参数的波峰波谷差值降低 20 lx,光强平坦度更高;4-LED 布局的信噪比范围为 10.2~11.4 dB,信噪比最大值和最小值的差值为 1.2 dB,方差为 0.149,相较基于方差参数的信噪比方差降低 0.082,接收面信噪比波动更小,在位置 $(x, y) = (3, 5)$ 处信噪比约为 10.4 dB,相较于优化前提高 1 dB,通信性能得到改善。12-LED 布局的光强分布范围为 980~1120 lx,光强波峰与波谷的差值为 140 lx,相较基于方差参数的波峰波谷差值降低 560 lx,光强平坦度更高;

12-LED 布局的信噪比范围为 12.5~14.5 dB,信噪比的最大值和最小值的差值为 2.0 dB,方差为 0.169,相较基于方差参数的信噪比方差降低 3.561,在位置 $(x, y) = (0, 0)$ 处信噪比约为 13.0 dB,相较于优化前提高 3.0 dB,通信性能得到明显改善,接收面全局信噪比分布更平均。蒙特卡罗方法解决以方差为核心的平坦度参数的局部最优问题,符合实际应用。由仿真分析可得出结论:相较于以方差为核心的平坦度参数,蒙特卡罗方法作为平坦度参数可避免 Mot-PSO-K-Means++ 算法出现投机最优解的情况,可实现最优灯源布局方案的建立。

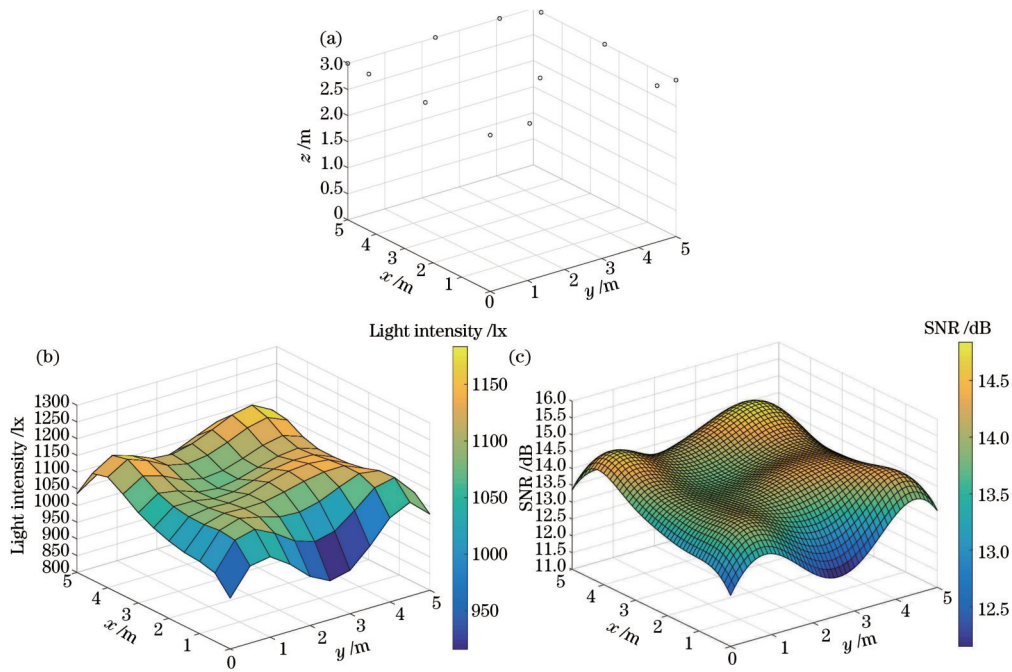


图 20 蒙特卡罗参数下 12-LED 最优布局。(a) 12-LED 最优位置;(b) 12-LED 光照分布;(c) 12-LED 信噪比分布;

Fig. 20 Optimal layouts of 12-LED under Monte Carlo parameters. (a) 12-LED optimal location; (b) intensity distribution of 12-LED; (c) SNR of 12-LED

6 结 论

本文提出 Mot-PSO-K-Means++ 算法用于寻找 PFCNN 平坦度预测模型下的室内可见光源布局方案。提出 PFCNN 模型用于光强分布平坦度参数预测;采用 Mot-PSO-K-Means++ 算法解决 PSO 局部收敛和迭代速度慢等问题,建立 PFCNN 模型下最优光源布局;提出蒙特卡罗方法用于衡量平坦度,相较于传统基于方差的平坦度参数预测方法,所提方法可应用于光源数量较多、接收平面更大的室内空间。本文方法解决了传统 Lambert 模型中难以考虑的非直射信道、环境中噪声和干扰、障碍物遮挡、室内边界和不规则房间布局等问题,可获取更符合实际室内空间场景、光强分布更均匀的最优光源布局方案。通过仿真可知:本文构建的 PFCNN 信道模型相比于全连接神经网络信道模型,预测精度提升 84.69%,符合实际室内场景应用。建立的 4-LED 最优布局方案的光强范围为 340~440 lx,波峰波谷差值由 120 lx 降低至 100 lx,平坦度参数值由 84.8% 提高至 92.0%,建立的 12-LED 最优布局方案的光强范围为 340~440 lx,波峰波谷差值由 120 lx 降低至 100 lx,平坦度参数值由 84.8% 提高至 92.0%,两种光源布局下信噪比均得到明显改善。因此,所提出的室内可见光信道模型通用性较强且 PFCNN 平坦度预测模型具有较高精确度,适用于任意光源数量和任意给定室内空间大小的环境,在该模型下提出的光源布局方案更适合实际室内场景,接收面接收信号强度更均匀,为 VLP 光源布局深入研究提供理论支撑。

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] 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.
- [3] 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.
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.
- [4] 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.
- [5] 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.
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.
- [6] 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.
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.
- [7] 杨智群, 梁继然, 毛陆虹. 蚁群算法优化室内可见光通信功率均匀性的研究[J]. 激光与光电子学进展, 2019, 56(22): 220601.
Yang Z Q, Liang J R, Mao L H. Power uniformity optimization in indoor visible light communication based on ant colony algorithm[J]. Laser & Optoelectronics Progress, 2019, 56(22): 220601.
- [8] 王加安, 车英, 吕超, 等. 基于能量最优的室内可见光通信 LED 布局[J]. 光学学报, 2017, 37(8): 0806003.
Wang J A, Che Y, Lü C, et al. LED layout for indoor visible light communication based on energy optimization [J]. Acta Optica Sinica, 2017, 37(8): 0806003.
- [9] 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: 29-44.
Hu J Y. Research on indoor lighting source layout based on neural network[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019: 29-44.
- [10] 翟长鑫, 郑茹, 刘畅, 等. 室内可见光通信系统光源优化设计[J]. 光通信技术, 2019, 43(8): 11-15.
Zhai C X, Zheng R, Liu C, et al. Optimum design of light source for indoor visible communication system[J]. Optical Communication Technology, 2019, 43(8): 11-15.
- [11] 韩雨, 岳殿武. 基于鲸鱼优化算法的室内可见光通信 LED 布局[J]. 光电子技术, 2020, 40(3): 201-208.
Han Y, Yue D W. Lighting layout for indoor visible light communication based on whale optimization algorithm[J]. Optoelectronic Technology, 2020, 40(3): 201-208.
- [12] Wang J A, Xu A C, Ju J T, et al. Optimization lighting layout of indoor visible light communication system based on improved artificial fish swarm algorithm[J]. Journal of Optics, 2020, 22(3): 035701.
- [13] Zhai C X, Liu H, Wen Y Y, et al. Multipopulation genetic algorithm-optimized LED layout in a visible light communication system[J]. Optical Engineering, 2020, 59: 066103.
- [14] Zhang X L, Duan J Y, Fu Y G, et al. Theoretical accuracy analysis of indoor visible light communication positioning system based on received signal strength indicator[J]. Journal of Lightwave Technology, 2014, 32(21): 4180-4186.
- [15] Ding J P, Huang Z T, Ji Y F. Evolutionary algorithm based power coverage optimization for visible light communications[J]. IEEE Communications Letters, 2012, 16(4): 439-441.
- [16] Liu H L, Wang X, Chen Y, et al. Optimization lighting layout based on gene density improved genetic algorithm for indoor visible light communications[J]. Optics Communications, 2017, 390: 76-81.
- [17] 丁举鹏, 易芝玲, 王劲涛, 等. 可见光定位系统中发光二极管的空间波束效应分析[J]. 光学学报, 2021, 41(5): 0523001.
Ding J P, Yi Z L, Wang J T, et al. Analysis of light-emitting diodes spatial beam effect in visible light positioning system[J]. Acta Optica Sinica, 2021, 41(5): 0523001.
- [18] Sadeghi B H M. A BP-neural network predictor model for plastic injection molding process[J]. Journal of Materials Processing Technology, 2000, 103(3): 411-416.
- [19] Albawi S, Mohammed T A, Al-Zawi S. Understanding of a convolutional neural network[C]//2017 International Conference on Engineering and Technology (ICET), August 21-23, 2017, Antalya, Turkey. New York: IEEE Press, 2017: 17615756.
- [20] Hastings W K. Monte Carlo sampling methods using Markov chains and their applications[J]. Biometrika, 1970, 57(1): 97-109.
- [21] Nebro A J, Durillo J J, Garcia-Nieto J, et al. SMPSO: a new PSO-based metaheuristic for multi-objective optimization[C]//2009 IEEE Symposium on Computational Intelligence in Multi-Criteria Decision-Making, March 30-April 2, 2009, Nashville, TN, USA. New York: IEEE Press, 2009: 66-73.