

DOI:10.16136/j.joel.2023.11.0599

基于 GAN 指纹库的卷积神经网络室内可见光信道模型

卢宇希, 张慧颖*, 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:提出一种神经网络算法实现室内可见光信道模型,解决 Lambert 模型难以计算室内可见光信道的噪声和误差问题。针对指纹库数据量大、难以采集和训练参数多导致迭代速度慢的问题,提出使用生成式对抗网络(generative adversarial network, GAN)生成仿真数据集融合原有的稀疏指纹库,生成满足训练要求数量的指纹库;使用一维的卷积神经网络(convolutional neural network, CNN)提取数据特征,降低训练参数,提高迭代速度。在室内 $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ 环境下采集稀疏指纹库,分别用反向传播神经网络(back propagation neural network, BPNN)和一维 CNN 室内可见光信道模型进行对比。仿真结果表明:使用 GAN 生成指纹库的平均绝对误差为 0.04,对数据量增广 300%;在同一指纹库下,BPNN 信道模型误差为 3.81,迭代 500 次收敛;而 CNN 信道模型误差为 0.79,迭代 100 次收敛。本文提出的 GAN 指纹库融合 CNN 的可见光信道模型具有精度高、误差小、速度快、泛化性强等优点,为室内可见光信道模型提供新的研究方案。

关键词:光通信;生成式对抗网络(GAN);可见光信道模型;稀疏指纹库;反向传播神经网络(BPNN);一维卷积神经网络(CNN)

中图分类号: TN929.12 **文献标识码:** A **文章编号:** 1005-0086(2023)11-1201-09

Convolutional neural network indoor visible light channel model based on GAN fingerprint database

LU Yuxi, ZHANG Huiying*, LIANG Yu, WANG Kai

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

Abstract: In order to solve the Lambert model is difficult to calculate the indoor visible light channel noise and error problems, a neural network algorithm is proposed to realize the indoor visible light channel model. Aiming at the problems of large amount of fingerprint database data, difficult collection and many training parameters, which lead to slow iteration speed, the generative adversarial network (GAN) is proposed to generate simulation data set and merge the original sparse fingerprint database to generate the number of fingerprint database meeting the training requirements. A one-dimensional convolutional neural network (CNN) is used to extract data features, reduce training parameters and improve iteration speed. The sparse fingerprint database is collected in the indoor environment of $5\text{ m} \times 5\text{ m} \times 3\text{ m}$, and the back propagation neural network (BPNN) and one-dimensional CNN indoor visible light channel model are respectively used for comparison. The simulation results show that the average absolute error of GAN is 0.04, and the data volume is increased by 300%. Under the same fingerprint database, the error of BPNN channel model is 3.81, and the convergence is realized after 500 iterations. However, the error of CNN channel model is 0.79, and the iteration converges are 100 times. The GAN fingerprint database merged CNN visible light channel model proposed in this paper has the advantages of high precision, small error, fast speed and strong generalization, which provides a new research scheme for indoor visible

* E-mail: yingzi1313@163.com

收稿日期: 2022-08-25 修订日期: 2022-10-15

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

light channel model.

Key words: optical communication; generative adversarial network (GAN); visible light channel model; sparse fingerprint database; back propagation neural network (BPNN); one-dimensional convolutional neural network (CNN)

0 引 言

随着通信技术的发展,通信方式逐渐由有线通信转向无线通信方向。电磁波通信已成为室外场所的主流通信方式,如 GPS、移动设备、基站等设备通信都由电磁波为媒介实现通信。但电磁波影响电子设备正常运行,且其开放性和保密性差、易受介入,且易受到建筑物遮挡,使其在如医院、军事基地、隧道、地下设施等特殊场景难以应用。为此室内通信技术提出了解决方案,如红外通信、射频通信、蓝牙通信、UWB 通信等。但红外通信功耗大,发射角度小;射频通信的方向虽然没有指向,但其通信数据量低;蓝牙通信传输速率低,不同设备协议不兼容。而室内可见光通信能够弥补上述通信的缺点,在室内利用 LED 实现通信,具有速度快、保密性好的优点。但在对室内信道进行建模仿真时,传统的 Lambert 模型只能计算出直射信号的接收光强。蒋玉想在水泥路面激光散射特性研究中提出水泥地面具有朗伯体散射特征,地面反射信号对可见光信道有影响^[1];赵太飞等^[2]在近距离 LED 光通信直视信道模型研究中提出高斯拟合函数构建的近距离 LED 直射信道模型,但其未考虑反射、噪声等干扰;张伟望等^[3]在基于朗伯型反射微结构的 LED 室内照明光源设计中提出一种基于朗伯型反射面的室内可见光信道模型,通过反射点计算接收面处的光强;YANG 等^[4]在 LED 照度分布的分析模型中提出使用高斯近似法拟合可见光信道模型,计算接收平面的光照分布;刘百芬等^[5]在基于 LED 阵列与漫反射自由曲面的均匀照明光源设计中提出一种由平面 LED 阵列与高漫反射率自由曲面构成的模型;XIA 等^[6]在近似朗伯式 LED 光学透镜结构的设计中提出了一种 LED 近似朗伯源封装模型;WU 等^[7]在 LED 照明的精确模型及其在均匀照明系统中的应用中使用曲线拟合技术降低 Lambert 模型的误差;WANTANEE 等^[8]在使用现成踏板车尾灯进行可见光通信的通道模型中提出使用现实环境采集的数据集计算实际场景的可见光通信信道;WU 等^[9]在室内无定向光无线通信的朗伯阶优化中提出朗伯阶优化算法以优化室内可见光通信的非直射(non-line-of-sight, NLOS)信道模型,但其未考虑二阶及以上反射。

本文为结合实际场景,提出一种基于生成式

对抗网络(generative adversarial networks, GAN)生成指纹库的卷积神经网络(convolutional neural network, CNN)室内可见光信道模型,该模型对实际场景采集的稀疏指纹库使用 GAN 进行数据增广,提高神经网络信道模型的预测精确度;对反向传播神经网络(back propagation neural network, BPNN)使用 CNN 进行优化,通过对指纹库数据集使用卷积、池化和矩阵线性运算、激活函数的非线性运算实现由灯源信息预测接收面光强分布,构建更符合实际场景的室内可见光信道模型,为室内可见光通信建模提供新的理论支撑。

1 室内可见光信道模型

在室内 $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ 环境下设置单个 LED,离地面 $h\text{ m}$ 的高度设置接收网格接收面,构建室内可见光信道模型。其中发射端参数包含 LED 位置信息、功率信息、发射角度和朝向角,接收面光强分布为网格矩阵数据,信道模型如图 1 所示。其中图 1(a)所示的为直射链路模型,图 1(b)所示为非直射链路的一次反射模型。通过对不同 LED 信息下的接收面光强分布进行线性叠加,得到多 LED 下的室内可见光信道模型。

传统的 Lambert 模型能够根据发射端和接收端的位置信息、灯源信息计算出接收点的光照强度,按图 1 所示建立仿真模型,直射链路的增益计算如式(1)所示^[10]:

$$H_{\text{LOS}}(0) = \begin{cases} \frac{(m+1)S}{2\pi d^2} \cos^m(\phi) \cos(\varphi) T(\varphi) g(\varphi), & 0 \leq \varphi \leq \varphi_c \\ 0, & \varphi > \varphi_c \end{cases}, \quad (1)$$

式中, m 、 d 、 S 、 ϕ 、 φ 、 T 、 g 分别为朗伯系数、发射端与接收端距离、接收端面积、发射角、入射角、滤波增益和聚光器增益。

非直射链路选择一次反射模型,其增益计算如式(2)所示^[11]:

$$H_{\text{ref}}(0) = \begin{cases} \frac{(m+1)A_s}{2\pi^2 D_1^2 D_2^2} \rho d S_{\text{wall}} \cos^m(\theta) \cos(\partial) \\ \cos(\beta) g(\varphi) T(\varphi) \cos(\varphi), & 0 \leq \varphi \leq \varphi_c \\ 0, & \varphi > \varphi_c \end{cases}, \quad (2)$$

式中, S_{wall} 、 D_1 、 D_2 、 ∂ 、 β 分别为墙面反射单位面积、发射端到墙面反射点距离、墙面反射点到 PD 接收端

距离、反射系数和反射角度。

构建室内可见光的信道模型指纹库,搭建 5 m×5 m×3 m 的实际室内场景进行指纹库采集,如图 2 所示。

在现实环境中存在多次反射和热噪声、散粒噪

声、非规则房间布局等问题^[12],导致构建的信道模型与实际场景的信道模型不同,对室内可见光信道模型指纹库使用神经网络^[13]训练后实现接收面光强分布的计算,从而实现基于神经网络的室内可见光信道模型。




图 1 室内可见光信道模型:(a) 直射链路模型;(b) 非直射链路模型

Fig. 1 Indoor visible light channel model:(a) LOS channel model; (b) NLOS channel model




图 2 指纹库采集环境

Fig. 2 Fingerprint database acquisition environment

2 稀疏指纹库与 GAN 数据增广

由于接收面矩阵的参数较大,为适应较大场景需求和提高神经网络精确度,在实际室内环境下采集稀疏指纹库数据集^[14],其包含灯源位置、功率、角度信息和其对应接收面光强矩阵信息,采集指纹库的流程如表 1 所示。

采集到 1 000 组灯源信息和对应光强矩阵的稀疏指纹库,该指纹库数据如表 2 所示。*Light_info_[i]*和 *Power_matrix_[i]* 分别表示第 *i* 组灯源信息和第 *i* 组灯源信息对应的接收面光强矩阵。

其中 *LED_info_[i]* 为 1 行 *r* 列矩阵(本文取 *r*=12),包含灯源位置、功率等信息,*Power_matrix_[i]* 为接收面使用网格法采集的 *m* 行 *n* 列矩阵数据(本文

表 1 GAN 稀疏指纹库采集流程

Tab. 1 Algorithm process of GAN sparse fingerprint database

Steps	Process
Step1	Set the LED at (0.5 m,0.5 m,3 m) with the orientation set to 0° and the power set to 5 W. Record the power distribution matrix of the receiving surface.
Step2	Reduce the power value by 0.5 W. Record the power distribution matrix of the receiving surface.
Step3	Repeat Step2 until LED power changes to 0 W.
Step4	Repeat Step1 through Step3,change the LED position until lamp source position (5 m,5 m,3 m) is reached. The power tensor of the receiving surface is obtained.

表 2 LED 信息-光强分布的稀疏指纹库

Tab. 2 Sparse fingerprint database of LED information-power distribution

LED ID	LED information	Power matrix
1	<i>Light_info₁</i>	<i>Power_matrix₁</i>
2	<i>Light_info₂</i>	<i>Power_matrix₂</i>
...	...	...
1 000	<i>Light_info_{1 000}</i>	<i>Power_matrix_{1 000}</i>

取 $m=n=11$),该数据为 $m\times n+r$ 维随机变量,设其服从 P_g 分布,通过捕获该分布从而实现数据预测。对表1中的指纹库使用GAN进行数据增强^[15],扩充指纹库数据集。构建如图3所示的GAN模型。其中指纹库采集的数据作为图中的LED information-power matrix real sample,在Latent space构建服从正态分布的噪声时间序列 $p_z(z)$,通过Generator network构建的神经网络,可学习参数 θ_g 实现分布 $G(z, \theta_g)$ 的映射接近 P_g 分布,从而生成新指纹库样

本。为验证 G_g 和 P_g 的差异性,使用训练后的Discriminator network验证输入样本的真伪二分类器,用可学习参数 θ_d 来学习样本真伪的 $D[G(z, \theta_g), \theta_d]$ 分布,实现判断输入进Discriminator network的样本来是否为真实数据。经过训练的GAN能够优化参数 θ_g 和 θ_d 使 $[1-D(G(z, \theta_g), \theta_d)]$ 值最小,使 $\log\{D[G(z, \theta_g), \theta_d]\} + \log\{1-D[G(z, \theta_g), \theta_d]\}$ 值最大。经过训练达到纳什平衡的GAN能够捕捉真实样本数据的分布,并生成服从该分布的数据。




图3 GAN 指纹库扩增模型

Fig. 3 GAN fingerprint database augmentation model

其中 Generator network 为一个生成网络,能够通过迭代训练提取 Real sample 数据的概率分布,经过训练后将输入随机的正态分布信号,经过网络生成同概率分布的新指纹库数据样本;Discriminator network 为对抗网络,该网络实现数据辨别,其通过

辨别来自真实样本和生成样本时的误差损失进行迭代,更新生成网络的权重,从而实现 Generator network 的训练。GAN 算法如表3所示,该算法能够在训练后生成被 Discriminator network 网络识别为真实灯源信息仿真指纹库数据,用该网络进行最终

表3 GAN 算法流程

Tab. 3 Algorithm process of GAN

Steps	Process
Step1	Sample noise as the Generator network inputs. The noise obeys normal distribution.
Step2	The Generator network outputs is fake LED information and power matrix, it's computed by hidden neuron 'Weights' and 'Bias', activation function 'ReLU', 'Tanh'.
Step3	Mix the real sample and fake sample as the Discriminator network inputs, set a 'truth matrix' with all elements are 1, set a 'false matrix' with all elements are 0.
Step4	Compute the binary cross entropy of Discriminator network outputs and truth matrix, use Adam algorithm update the neuron 'Weights' and 'Bias'.
Step5	Repeat Step1 to Step4 until the program loss function is below the threshold.
Step6	Generator network generates the simulation fingerprint database by random noise.

的指纹库扩增。

3 BPNN 和 CNN 的室内可见光信道模型

通过训练神经网络,可以拟合由输入数据到输出数据的映射关系。将扩增后的指纹库作为神经网络的训练数据,搭建如图4所示的BPNN^[16,17]信道

模型,实现给定灯源布局获取接收面的光强分布。

该神经网络的隐藏层中由多个线性层和激活函数层构成,其中激活函数能为线性层提供非线性的参量,使该网络由输入的灯源位置、光强信息非线性回归接受面的光强分布。其中第 $i+1$ 层 $layer^{(i+1)}$ 线性层和激活函数层的计算如式(3)和式(4)所示:

$$layer^{(i+1)} = w^{(i)} layer^{(i)} + b^{(i)}, \quad (3)$$

$$layer^{(i+1)} = \tanh(layer^{(i)}) =$$




图 4 BP 神经网络信道模型

Fig. 4 BP neural network channel model

$$\frac{e^{layer^{(i)}} - e^{-layer^{(i)}}}{e^{layer^{(i)}} + e^{-layer^{(i)}}}, \quad (4)$$

式中, i 取值范围为 $[0, p-1]$ 。

神经网络经过迭代后,不断更新式(3)中的权重矩阵 w 和偏置矩阵 b ,使网络的误差随着迭代降低,第 i 层 w 矩阵和 b 矩阵的计算如式(5)和式(6)所示:

$$w^{(i)} = w^{(i)} - \mu \frac{\partial Loss(t)}{\partial w^{(i)}} = w^{(i)} - \frac{\mu}{M} \sum_{i=1}^M \frac{\partial Loss function}{\partial w^{(i)}}, \quad (5)$$

$$b^{(i)} = b^{(i)} - \mu \frac{\partial Loss(t)}{\partial b^{(i)}} = b^{(i)} - \frac{\mu}{M} \sum_{i=1}^M \frac{\partial Loss function}{\partial b^{(i)}}, \quad (6)$$

式中, μ 为学习率, M 为权重总数量。

但 BPNN 的线性层包含大量矩阵运算,其中巨大参数量使该网络收敛慢、需求指纹库大、预测精度低。为此提出使用 CNN^[18,19] 网络对 BPNN 进行改进,在 BPNN 中添加一维 valid 卷积的操作,能够提取网络中的特征,实现更高精度的光强分布预测。

由于接收面的光强分布为连续信号,对该网络层输出进行最大池化^[20]运算,使参数量降低的同时不损失非线性回归的精度。CNN 的室内可见光信道模型如图 5 所示。一维卷积的公式如式(7)所示:

$$Convolution = \sum_{p=1}^{n-c} w_p v_p, \quad (7)$$

式中, p 为卷积核滑动次数, n 为输入张量维度, c 为卷积核大小, w_p 和 v_p 分别为输入张量卷积计算部分和卷积核。




图 5 CNN 神经网络信道模型

Fig. 5 CNN neural network channel model

4 仿真分析

4.1 GAN 指纹库增广模型

本文用于生成灯源布局和光照分布指纹库数据的 GAN 实验硬件环境为: NVIDIA RTX3090 GPU, GPU 内存 48 G; 软件及环境: python3.8, Pycharm, Jupyter notebook, CUDA 11.1, Pytorch1.91, matplotlib, numpy。操作系统: Ubuntu 18.04.3 TLS。GAN 所用神经网络层、激活函数(Activation)、归一

化(Norm)等超参数如表 4 所示。

将采集的稀疏指纹库作为 GAN 的 Real Sample, 设置长度为 100 的初始隐空间, 噪声服从高斯分布。分别为 Generator network 和 Discriminator network 搭建神经网络, 其中 Generator 实现仿真数据生成, 而 Discriminator 实现真伪判别; Generator 网络的迭代曲线如图 6 所示, Discriminator 网络的迭代曲线如图 7 所示, 真值迭代曲线如图 8 所示。

由图 6—图 8 可知, 经过训练 300 次后,

表 4 GAN 超参数设置

Tab. 4 GAN hyperparameter setting

Generator network hyperparameter			Discriminator network hyperparameter		
Layer	Activation/Norm	Output size	Layer	Activation/Norm	Output size
Linear1	LeakyReLU	128	Linear1	LeakyReLU	512
Linear2	LeakyReLU+BN	256	Linear2	LeakyReLU	256
Linear3	LeakyReLU+BN	512	Linear3	LeakyReLU	128
Linear4	LeakyReLU+BN	1 024	Linear4	LeakyReLU	32
Linear5	None	133	Linear5	None	1




图 6 Discriminator 迭代曲线

Fig. 6 Discriminator iteration curve




图 8 真值迭代曲线

Fig. 8 Real iteration curve




图 7 Generator 迭代曲线

Fig. 7 Generator iteration curve

Generator 网络和 Discriminator 网络的平均绝对误差(mean absolute error, MAE)损失值分别达到 0.04 和 0.025 并收敛, 真值损失为对抗网络判断输入 Real sample 的损失, 与 Discriminator 的损失共同作为优化项更新 Generator 的权重。即经过 Discriminator 网络的对抗后, Generator 网络能生成符合实际场景的指纹库数据集。设置 LED 个数为 4 个, 使用 GAN 生成指纹库数据结果可视化: 迭代 150 次和迭代 300 次后的 GAN 生成随机指纹库模型。由生成指纹库中的灯源布局信息, 在实际实验环境中采集接收面光强矩阵如图 9(a) 所示; GAN 迭代 150 次和迭代 300 次生成的光强分布如图 9(b) 和 9(c)

所示。

由图 9 可知在 GAN 迭代过程中,Generator 网络不断学习稀疏指纹库中的概率分布,在迭代至 150 次时 MAE 达到 0.24,呈现出实际分布的趋势,但此时误差仍然较高;当迭代至 300 次时二者分布趋势

近乎相同,此时的光照分布和生成分布的 MAE 降低至 0.04,证明 GAN 经过 300 次迭代后能够生成的仿真指纹库数据集符合神经网络的训练要求,且结合图 7 可知该神经网络已达到临界拟合,使用该 GAN 模型对稀疏指纹库进行数据增广。




图 9 GAN 迭代生成指纹库数据:(a) 真实分布;(b) 150 次迭代分布;(c) 300 次迭代分布

Fig. 9 GAN iteration generation fingerprint database data:(a) True distribution;
(b) 150 iteration distribution;(c) 300 iteration distribution

4.2 BP 和 CNN 的室内可见光信道模型

将 GAN 增广后的指纹库中的灯源信息及对应的接收面光照分布作为信道模型的训练数据,分别使用 BPNN 和 CNN 网络进行训练,其中 BPNN 的超参数和 CNN 网络的超参数如表 5 和表 6 所示。

表 5 BP 神经网络超参数设置

Tab. 5 BP Neural Network hyperparameter setting

Layer	Activation/Norm	Output shape
Linear1	Tanh	48
Linear2	Tanh+BN	256
Linear3	Tanh+BN	512
Linear4	None	121

表 6 CNN 超参数设置

Tab. 6 CNN hyperparameter setting

Layer	Activation/Norm	Output shape
Linear1	Tanh+BN	512
Linear2	ReLU+BN	1 024
Conv1d_1	ReLU+BN	256×3
Maxpooling	None	128×3
Conv1d_2	ReLU+BN	64×5
Flatten	None	320
Linear3	None	121

分别使用表 5 和表 6 中的超参数训练 BPNN 室内可见光信道模型和 CNN 室内可见光信道模型,经过 1000 次迭代的 BPNN 和 CNN 室内可见光信道模型误差损失迭代曲线如图 10 所示。




图 10 室内可见光信道模型损失迭代曲线

Fig. 10 Loss iteration curve of indoor visible light channel model

由图 10 可知:使用 BPNN 迭代 500 次后达到拟合,其 MAE 值为 3.81,而使用 CNN 迭代 100 次即达到收敛,且 MAE 值为 0.79。相较于 BPNN 的信道模型,使用 CNN 构建的信道模型在迭代次数上减少 400 次,信道模型的 MAE 降低 78.6%,说明使用 CNN 构建的室内可见光信道模型更符合实际应用。

对 BPNN 和 CNN 构建的信道模型分别可视化,指定光源信息下,BPNN 的信道模型和 CNN 信道模型预测的接收面光照分布如图 11 所示。

图 11(a)为随机指定光源信息下采集的实际接收面光照分布,图 11(b)和图 11(c)分别为 BPNN 信道模型和 CNN 信道模型预测的接收面光照分布。由图 11 可知,使用 BPNN 预测的分布(图 11(b))与实际分布(图 11(a))误差较大,其 MAE 误差达到 3.81,该模型预测出的峰值达 450 lx,而实际峰值为 400 lx,在光源处预测分布的趋势较为准确,但在边

缘处预测误差较大,边缘峰值为 250 lx,而实际边缘峰值为 300 lx,且预测曲线趋势不同;而使用 CNN 预测的分布(图 11(c))与实际分布(图 11(a))误差较小,其 MAE 误差仅为 0.79,其预测的峰值结果与实际分布中峰值结果相同,在边缘处预测的结果和趋势也更为接近,仅在墙角处误差较明显,误差值为 30 lx。由此可以说明,使用 CNN 信道模型相较于 BPNN 信道模型预测的接收面光照分布更接近实际环境,基于 CNN 的室内可见光信道模型更符合实际场景的应用。




图 11 指定光源信息下 BP 模型和 CNN 模型光照分布:

(a) 真实分布; (b) BP 神经网络信道模型分布; (c) CNN 信道模型分布

Fig. 11 Illumination distribution of BP model and CNN model under specified light source information:

(a) True distribution; (b) BP neural network channel model distribution; (c) CNN channel model distribution

5 结 论

为解决传统 Lambert 模型构建的室内可见光信道模型难以计算实际场景中的多次反射、噪声干扰和误差等问题,本文使用 GAN 生成稀疏指纹库结合 CNN 构建室内可见光信道模型。为解决神经网络训练精度低、指纹库数据量不足的问题,使用 GAN 训练稀疏指纹库,使用 GAN 中的 Generator 生成新的、MAE 低于 0.04 的指纹库数据。为解决传统的 BPNN 信道模型训练过程慢、损失值收敛较高、精度低的问题,使用 CNN 网络为其添加卷积和池化运算,提高其收敛速度,MAE 值为 0.79,相较 BPNN 的信道模型误差降低 78.6%。因此,本文提出的室内可见光信道模型能获取更符合实际场景下的接收面光强分布,为室内可见光通信下的信道模型提供新的理论模型支撑。

参考文献:

[1] JIANG Y X, LI Z H. Research on laser scattering charac-

teristics of cement road surface[J]. Laser Technology, 2021, 45(3): 344-349.

蒋玉想,李振华. 水泥路面激光散射特性研究[J]. 激光技术, 2021, 45(3): 344-349.

[2] ZHAO T F, MA Z, LI X S, et al. Research on line-of-sight channel model of short-range LED optical communication [J]. Acta Photonica Sinica, 2020, 49(1): 0106001.

赵太飞,马壮,李星善,等. 近距离 LED 光通信直视信道模型研究[J]. 光子学报, 2020, 49(1): 0106001.

[3] ZHANG W W, HAN Y J, LUO Y, et al. LED illumination design based on Lambertian reflection of micro-structure [J]. Semiconductor Optoelectronics, 2018, 39(1): 118-123.

张伟望,韩彦军,罗毅,等. 基于朗伯型反射微结构的 LED 室内照明光源设计[J]. 半导体光电, 2018, 39(1): 118-123.

[4] YANG H, BERGMANS J W M, SCHENK T C W, et al. An analytical model for the illuminance distribution of a power led[J]. Optics Express, 2008, 16(26): 21641-21646.

[5] LIU B F, JIN X L, ZHU Z M. Uniform illumination design based on LED array and diffuse reflection freeform sur-

- face[J]. *Journal of Applied Optics*, 2014, 35(4): 598-602.
- 刘百芬,金小龙,祝振敏. 基于LED阵列与漫反射自由曲面的均匀照明光源设计[J]. *应用光学*, 2014, 35(4): 598-602.
- [6] XIA X L, YU B H, MAI Z Q. Design on approximate Lambertian LED opto lens configuration [J]. *Electro-Optic Technology Application*, 2010, 25(1): 22-25+37.
- 夏勋力,余彬海,麦镇强. 近朗伯光型LED透镜的光学设计[J]. *光电技术应用*, 2010, 25(1): 22-25+37.
- [7] WU F, HUANG Q. A precise model of LED lighting and its application in uniform illumination system[J]. *Optoelectronics Letters*, 2011, 7(5): 334-336.
- [8] VIRIYASITAVAT W, YU S H, TSAI H M. Short paper: Channel model for visible light communications using off-the-shelf scooter taillight[C]//2013 IEEE Vehicular Networking Conference, December 16-18, 2013, Boston, MA, USA. New York: IEEE, 2013: 170-173.
- [9] WU D, GHASSEMLOOY Z, MINH H L, et al. Optimisation of Lambertian order for indoor non-directed optical wireless communication[C]//2012 1st IEEE International Conference on Communications in China Workshops (IC-CC). IEEE, August 15-17, 2012, Beijing, China. New York: IEEE, 2012: 43-48.
- [10] 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.
- 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.
- [11] WU M L, MA F K, LIU W K. Noise suppression method in medium and long distance outdoor visible light communication[J]. *Laser & Optoelectronics Progress*, 2020, 57(13): 130601.
- 武梦龙,马富康,刘文楷. 中远距离室外可见光通信中噪声抑制方法[J]. *激光与光电子学进展*, 2020, 57(13): 130601.
- [12] HANG S, ZHANG J, MENG F Y, et al. Low light communication in darkroom based on single photon detection[J]. *Journal of Information Engineering University*, 2017, 18(6): 679-682.
- 韩松,张剑,孟凡玉,等. 基于单光子检测的暗室弱光通信[J]. *信息工程大学学报*, 2017, 18(6): 679-682.
- [13] HU J Y. Research on indoor lighting source layout based on neural network[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2019: 29-43.
- 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: 29-43.
- [14] LI X C, WANG H. Fingerprint location using sparse fingerprint acquisition and improved WKNN [J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2019, 31(4): 451-459.
- 李新春,王欢. 基于稀疏指纹采集和改进WKNN的定位算法[J]. *重庆邮电大学学报(自然科学版)*, 2019, 31(4): 451-459.
- [15] WANG K, GOU C, DUAN Y, et al. Generative adversarial networks: introduction and outlook [J]. *Journal of Automatica Sinica*, 2017, 4(4): 588-598.
- [16] HAO X D, SUN L, CHI J L, et al. Off-design performance of 9F gas turbine based on gPROMs and BP neural network model [J]. *Journal of Thermal Science*, 2022, 31(1): 261-272.
- [17] XIAO M H, ZHANG W, WEN K, et al. Fault diagnosis based on BP neural network optimized by beetle algorithm [J]. *Chinese Journal of Mechanical Engineering*, 2021, 34(6): 270-279.
- [18] ZHANG Y Q, XIAO D Q, LIU Y F, et al. An algorithm for automatic identification of multiple developmental stages of rice spikes based on improved Faster R-CNN [J]. *The Crop Journal*, 2022, 10(5): 1323-1333.
- [19] Li Y, HAO Z B, LEI H. Survey of convolutional neural network [J]. *Journal of Computer Applications*, 2016, 36(9): 2508-2515.
- [20] ZUBAIR S, FEI Y, WANG W. Dictionary learning based sparse coefficients for audio classification with max and average pooling [J]. *Digital Signal Processing*, 2013, 23(3): 960-970.

作者简介:

张慧颖 (1982—),女,博士,副教授,主要研究方向为光通信技术及应用、可见光通信、检测技术等。