

## 基于神经网络的可见光通信系统信道估计方法

陈勇<sup>1\*</sup>, 吴志倩<sup>1</sup>, 刘焕淋<sup>2</sup>, 胡陈毅<sup>1</sup>, 吴金兰<sup>1</sup>, 王创世<sup>1</sup><sup>1</sup>重庆邮电大学工业物联网与网络化控制教育部重点实验室, 重庆 400065;<sup>2</sup>重庆邮电大学通信与信息工程学院, 重庆 400065

**摘要** 针对现有的非对称限幅光正交频分复用(ACO-OFDM)可见光通信(VLC)系统中信道估计方法存在导频数量过大、精度低、估计效率不高的问题,提出一种基于深度神经网络(DNN)的VLC信道估计方法。利用梯度集中化(GC)方法进行模型优化,并采用端到端的方式跟踪信道信息并恢复失真信号。仿真结果表明:所提方法的误码率(BER)和均方误差(MSE)性能均优于传统方法;在使用较少的导频和省略循环前缀(CP)进行信道估计时,所提方法具有更强的鲁棒性。此外,在DNN训练过程中引入GC方法,可以加快网络的收敛速度,提高其优化能力。

**关键词** 光通信; 非对称限幅光正交频分复用; 信道估计; 深度神经网络

**中图分类号** TN929.1      **文献标志码** A

**DOI:** 10.3788/AOS221812

## 1 引言

为了适应可见光通信(VLC)系统采用的正交频分复用(OFDM)正实数约束条件,引入一种高效的非对称限幅光 OFDM(ACO-OFDM)调制方式来保证 VLC 系统的高速率和高频谱效率<sup>[1-4]</sup>。但是信号在传输过程中会受到 VLC 信道的多径干扰,出现信号失真,从而导致接收端无法正常恢复发射端信号,降低系统的通信质量。VLC 系统接收端通过获取信道状态信息(CSI)来实现发射端信息恢复,因此,如何精确反馈高维 CSI 是设计 ACO-OFDM 系统必须解决的问题之一<sup>[5]</sup>。

基于导频辅助(PA)的信道估计方法主要有最小二乘(LS)法、最小均方误差(MMSE)法<sup>[6-7]</sup>和压缩感知(CS)法<sup>[8-9]</sup>。LS 方法将 VLC 信道视为理想信道进行处理,忽略了信道中存在的噪声,导致估计精度不高;MMSE 方法估计的精度随着导频数量和复杂度的增加而提高;CS 方法利用信道稀疏性进行信道估计,但实际应用中稀疏度难以直接获得。利用上述方法在信噪比(SNR)的基础上设计自适应信道估计方法,虽然估计精度得到了提升,但估计效率低<sup>[10]</sup>;Miao 等<sup>[11]</sup>针对 VLC 系统中存在的严重非线性和多径效应,提出一种贝叶斯学习(BL)和卡尔曼滤波(KF)相结合的信道估计方法,相比于传统方法,该方法的估计精度得到提升,但复杂度更高。

深度学习(DL)为准确反馈 CSI 提供了新的解决方案。目前,对深度学习与无线通信的融合仍处于探索阶段<sup>[12]</sup>。将具有记忆功能的卷积神经网络(CNN)<sup>[13]</sup>、双分支多层感知器(MLP)<sup>[14]</sup>、去噪卷积神经网络(FFDNet)<sup>[15]</sup>和长短期记忆网络(LSTM)<sup>[16]</sup>等神经网络模型应用于 VLC 系统中,以抑制系统的非线性效应。针对室内 VLC 直流偏置光 OFDM(DCO-OFDM)系统,Cao 等<sup>[17]</sup>研究了导频辅助逐层计算(PA-RC)频域均衡算法的信号恢复情况,在假设没有性能损失的情况下,RC 通过只训练部分神经网络的连接权值进行神经网络训练,在 RC 特征中加入导频信号,提高了传统 LS 的信道估计精度;Salama 等<sup>[18]</sup>针对 DCO-OFDM 系统在不同的正交振幅调制(QAM)下的信道估计,提出一种基于神经网络和卡尔曼滤波算法的信道估计方法,旨在解决室内 VLC 系统信道估计方面存在的问题;Costa 等<sup>[19]</sup>针对多径单输入单输出 VLC 信道,研究了基于深度学习的 OFDM 均衡问题,将卷积神经网络体系结构直接应用于 OFDM 映射符号均衡,无需进行信道估计,其估计性能优于传统 LS 方法的估计性能,但估计精度仍有待提高;Mei 等<sup>[20-23]</sup>采用深度学习方法获得信道矩阵的相关性,实现信道估计,进而降低信道估计方法的复杂度,提高估计精度,并提升估计效率。目前,基于 ACO-OFDM 的 VLC 系统的信道估计研究鲜有报道。

针对现有信道估计方法存在的问题,本文提出—

收稿日期: 2022-10-12; 修回日期: 2022-11-14; 录用日期: 2022-11-22; 网络首发日期: 2023-01-04

基金项目: 国家自然科学基金(51977021)、重庆市自然科学基金(cstc2020jcyj-msxmX0682)、重庆市研究生科研创新项目(CYS22483)

通信作者: \*chenyong@cqupt.edu.cn

种基于深度神经网络(DNN)的ACO-OFDM VLC系统信道估计方法。首先设计了基于DNN的信道估计模型,然后利用梯度集中化(GC)方法对模型进行优化,最后采用端到端的方式隐式估计信道信息,直接恢复发射端信号。

## 2 ACO-OFDM VLC 系统模型

基于ACO-OFDM的VLC系统由发射端[发光二极管(LED)]、接收端[光电二极管(PD)]和信道组成。在发射端,输入的串行数据流被划分为并行的低数据流并随之映射为QAM星座;利用厄米特对称对

OFDM信号进行处理,经过快速傅里叶逆变换(IFFT)的信号为实数双极性信号;该OFDM信号经过循环前缀(CP)得以消除符号间干扰(ISI)和载波间干扰(ICI);通过剪切负值信号得到非负的传输信号,经光电转换后由光信道传输。接收端的操作为发射端的反向操作:首先对接收信号进行串并转换;然后去除CP,将并行信号反馈给快速傅里叶变换(FFT)模块来产生相应的频域信号,进而解调恢复发送信号。ACO-OFDM VLC系统结构如图1所示,其中S/P表示串/并转换,P/S表示并/串转换,D/A表示数/模转换,A/D表示模/数转换。

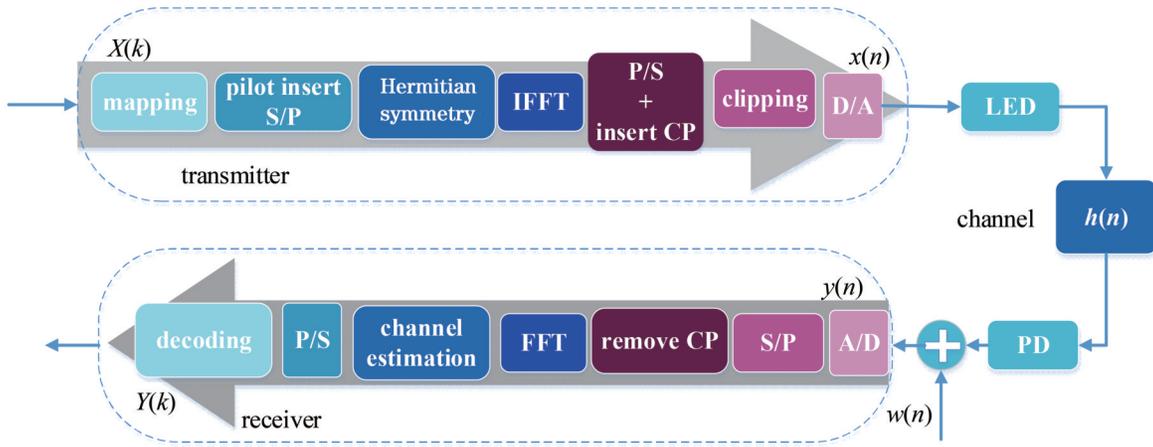


图1 ACO-OFDM VLC系统结构图

Fig. 1 Structure diagram of ACO-OFDM VLC system

在发射端,ACO-OFDM系统经星座映射后的数据符号需要具有符合光学OFDM系统要求的厄米特对称性,以保证传输的OFDM信号为正实数信号。IFFT的输入矢量为

$$\mathbf{X} = [0, X_1, 0, X_3, \dots, X_{N-1}] = [0, X_1, 0, X_3, \dots, X_{N/2-1}, 0, X_{N/2-1}^*, 0, \dots, X_1^*]. \quad (1)$$

经过IFFT后,时域ACO-OFDM信号表示为

$$x(n) = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} X(k) \exp\left(\frac{j2\pi nk}{N}\right), n = 1, 2, \dots, N, \quad (2)$$

式中; $j$ 为虚数单位; $x(n)$ 为传输信号; $X(k)$ 表示频域下的传输信号; $N$ 为子载波数; $k$ 表示第 $k$ 个子载波。

经过串并转换并加入CP后,对 $x(n)$ 进行非对称裁剪,得到单极性正实数信号:

$$x^c(n) = \begin{cases} x(n), & x(n) \geq 0 \\ 0, & x(n) < 0 \end{cases} \quad (3)$$

需要特别说明的是,本文只对视距链路进行分析。因此,LED到PD之间的信道增益<sup>[24]</sup>为

$$h = \begin{cases} \frac{(m+1)A}{2\pi d^2} \cos^m \phi \cdot T_s(\varphi) \cdot g(\varphi) \cdot \cos \varphi, & 0 \leq \varphi \leq \varphi_{\text{FOV}} \\ 0, & \varphi > \varphi_{\text{FOV}} \end{cases}, \quad (4)$$

式中: $\phi$ 为发射角; $\varphi$ 为入射角; $\varphi_{\text{FOV}}$ 为PD的视场角; $d$ 表示两者之间的距离; $A$ 为PD接收面积; $m$ 为朗伯辐射阶数; $T_s(\varphi)$ 和 $g(\varphi)$ 分别表示光滤波器增益和光集中器增益。

发送信号在自由空间光信道上传输,接收端的PD将光强度转换为电信号,从而产生基带信号 $y(n)$ ,记为

$$y(n) = x(n) \otimes h(n) + w(n), \quad (5)$$

式中: $\otimes$ 表示卷积; $w(n)$ 为加性高斯白噪声。

相应的频域信号为

$$Y(k) = X(k)H(k) + W(k), \quad (6)$$

式中: $W(k)$ 为频域中的噪声分量; $H(k)$ 为信道的频域响应分量。

ACO-OFDM信号在传输过程中会受到多径效应

的影响,导致接收端不能准确恢复发射端信号。若要提高 ACO-OFDM VLC 系统的通信质量,需要设计合适的信道估计方法来恢复发射端信号。对此,基于 ACO-OFDM VLC 系统利用 DNN 进行信道估计。

### 3 基于 DNN 的信道估计设计

图 2 所示为基于 DNN 的 ACO-OFDM 信道估计方案,该方案分为离线训练和在线部署两个阶段。在离线训练阶段,首先生成一个伪随机二进制序列作为传输信号,并对信号进行 QAM 调制,与插入的导频序

列一起形成 OFDM 帧。对信道进行模拟仿真,得到信道响应后,发射端发射的 OFDM 帧通过模拟的信道模型到达接收端,接收端收到的信号为失真的 OFDM 帧。采集原始的传输信号和失真的接收信号作为数据集,数据样本由不同的信息序列生成,具有一定统计特性。将 ACO-OFDM 调制和信道视为黑盒,再利用 DNN 模型进行训练。在在线部署阶段,将训练好的 DNN 模型在 ACO-OFDM 中进行在线部署,在不需明确估计信道响应的前提下,可直接恢复传输数据。

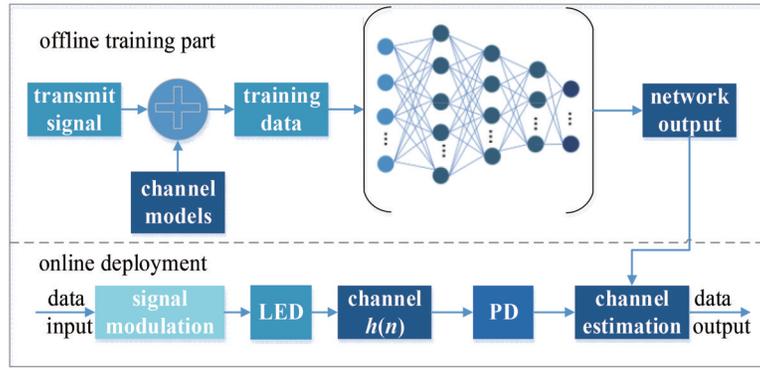


图 2 基于 DNN 的 ACO-OFDM 信道估计方案

Fig. 2 Channel estimation scheme of ACO-OFDM based on DNN

#### 3.1 DNN 模型

基于 DNN 的 ACO-OFDM 信道估计系统可通过多个隐藏层来获取训练数据中隐藏的结构特性,自适应地调整网络模型来获取模型输入与输出之间的最佳映射关系。包含多个隐藏层的 DNN 结构如图 3 所示。

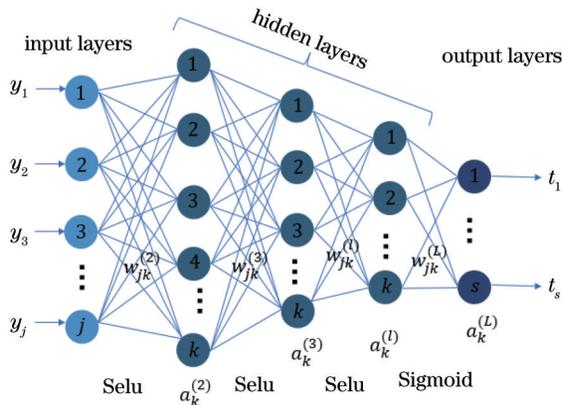


图 3 DNN 整体结构

Fig. 3 Overall structure of DNN

DNN 模型由输入层、隐藏层和输出层组成。用  $w_{jk}^{(l)}$  和  $b^{(l)}$  分别表示 DNN 模型中第  $l$  层的权重系数和偏置系数。在离线训练阶段,发射端信号经过信道送达接收端,提取接收端信号作为网络的输入。对于输入数据  $y^{(l)} = (y_1, y_2, \dots, y_j)$ ,神经元的输出为

$$a_k^{(l)} = \sigma \left( \sum_{j=1}^i w_{jk}^{(l)} y_j^{(l)} + b^{(l)} \right), \quad (7)$$

式中:  $\sigma(\cdot)$  表示激活函数。因此,通过前向传播得到网络输出,其输出可用矩阵形式表示为

$$a^{(L)} = \sigma(o^{(L)}) = \sigma(w^{(L)} a^{(L-1)} + b^{(L)}), \quad (8)$$

式中:  $a, o, w, b$  分别为矩阵形式的网络输出激活值、DNN 模型某一层的输出、权重和偏置;  $L$  为 DNN 模型的总层数。

通过在隐藏层和输出层引入激活函数,网络可以表征更多非线性函数。隐藏层和输出层分别使用 Selu 和 Sigmoid 作为激活函数, Selu 函数在全连接层网络中可以有效解决梯度消失的问题,其函数定义为

$$\sigma_{\text{Selu}}(v) = \lambda \begin{cases} v, & \text{if } v > 0 \\ \alpha e^v - \alpha, & \text{if } v \leq 0 \end{cases}, \quad (9)$$

$$\sigma_{\text{Sigmoid}}(v) = \frac{1}{1 + e^{-v}}, \quad (10)$$

式中:  $v$  为激活函数中的自变量;为了使函数的输出保持在一定的方差范围内,将激活函数 Selu 的比例因子  $\lambda$  设置为 1.6733,比例因子  $\alpha$  设置为 1.0507<sup>[25]</sup>。

训练 DNN 模型由前向传播和反向传播两个部分组成。前向传播算法通过每一层的  $w$  和  $b$  从输入层开始计算。在输入层输入矩阵  $y$  和初始化的  $w, b$ , 并逐层向后计算,直到得到输出层的输出为止;反向传播算法的思想是通过计算损失函数对各层权重和偏置的偏导数,进一步得到网络的具体参数。

ACO-OFDM 信道估计系统的 DNN 模型选择 MSE 作为损失函数, 定义为

$$\begin{aligned} \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t}) &= \frac{1}{2} \|\mathbf{a}^{(L)} - \mathbf{t}\|_2^2 = \\ &= \frac{1}{2} \|\sigma(\mathbf{w}^{(L)} \mathbf{a}^{(L-1)} + \mathbf{b}^{(L)}) - \mathbf{t}\|_2^2, \end{aligned} \quad (11)$$

式中:  $\mathbf{a}^{(L)}$  和  $\mathbf{t}$  分别表示网络的实际输出和目标输出;

$\|\cdot\|_2$  为  $L_2$  范数。

使用链式法则对每一层的权重和偏置求偏导数, 依据损失函数和式(8)计算梯度, 目的是使网络输出和目标输出之间的损失最小化(目标输出为 ACO-OFDM 原始发送信号), 保证网络输出与目标输出之间差异最小。输出层权重和偏置的偏导数计算公式为

$$\begin{cases} \frac{\partial \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t})}{\partial \mathbf{w}^{(L)}} = \frac{\partial \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t})}{\partial \mathbf{o}^{(L)}} \frac{\partial \mathbf{o}^{(L)}}{\partial \mathbf{w}^{(L)}} = (\mathbf{a}^{(L)} - \mathbf{t})(\mathbf{a}^{(L-1)})^T \odot \sigma'(\mathbf{o}^{(L)}) \\ \frac{\partial \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t})}{\partial \mathbf{b}^{(L)}} = \frac{\partial \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t})}{\partial \mathbf{o}^{(L)}} \frac{\partial \mathbf{o}^{(L)}}{\partial \mathbf{b}^{(L)}} = (\mathbf{a}^{(L)} - \mathbf{t}) \odot \sigma'(\mathbf{o}^{(L)}) \end{cases}, \quad (12)$$

式中:  $\odot$  表示 Hadamard 积;  $\sigma'(\cdot)$  为对网络输出求偏导数;  $T$  为矩阵的转置。在求输出层的  $\mathbf{w}$  和  $\mathbf{b}$  时, 将两者的公共部分定义为

$$\boldsymbol{\tau}^{(L)} = \frac{\partial \mathfrak{J}(\mathbf{w}, \mathbf{b}, \mathbf{a}, \mathbf{t})}{\partial \mathbf{o}^{(L)}} = (\mathbf{a}^{(L)} - \mathbf{t}) \odot \sigma'(\mathbf{o}^{(L)}). \quad (13)$$

计算出输出层权重和偏置的梯度, 利用数学归纳法将第  $l$  层的  $\boldsymbol{\tau}^{(l)}$  计算出来, 即

$$\boldsymbol{\tau}^{(l)} = \boldsymbol{\tau}^{(l+1)} \frac{\partial \mathbf{o}^{(l+1)}}{\partial \mathbf{o}^{(l)}} = (\mathbf{w}^{(l+1)})^T \boldsymbol{\tau}^{(l+1)} \odot \sigma'(\mathbf{o}^{(l)}), \quad (14)$$

更新后第  $l$  层的权重矩阵和偏置矩阵为

$$\begin{cases} \mathbf{w}^{(l)*} = \mathbf{w}^{(l)} - \eta \boldsymbol{\tau}^{(l)} (\mathbf{a}^{(l-1)})^T \\ \mathbf{b}^{(l)*} = \mathbf{b}^{(l)} - \eta \boldsymbol{\tau}^{(l)} \end{cases}, \quad (15)$$

式中:  $\mathbf{w}^{(l)*}$ 、 $\mathbf{b}^{(l)*}$  分别表示下一次迭代对应的权重和偏置的更新结果;  $\eta$  表示 0~1 的学习率。

由于 DNN 可以从复杂的数据结构和内部关系

中自动提取数据特征, 在离线训练阶段, 提取接收端信号作为网络的输入, 将发射端原始信号作为网络的目标输出, 通过训练模型, 使得网络输出和目标输出之间的损失最小化。为了提高 DNN 模型的信道估计精度、加快模型的收敛速度, 对 DNN 模型进行优化。

### 3.2 利用 GC 方法优化 DNN

为了加速 DNN 的训练过程、确保模型能够对测试数据作出准确预测、使训练过程更有效和稳定, 利用 GC 方法对 DNN 模型进行优化。将 GC 嵌入到 DNN 模型优化器 RMSprop 中进行处理<sup>[26]</sup>。通过作用于权重向量的梯度来约束损失函数, 使模型更稳定、有效。如图 4 所示, 与经典的梯度下降算法不同, GC 方法对梯度向量进行零均值化, 其中  $\mathbf{W} \in \mathbf{R}^{M \times N}$  表示网络的权重矩阵,  $\mathfrak{J}$  为目标函数,  $\nabla_{\mathbf{w}} \mathfrak{J}$  为  $\mathfrak{J}$  的梯度权重矩阵,  $\Psi_{GC}(\nabla_{\mathbf{w}} \mathfrak{J})$  为集中式梯度。

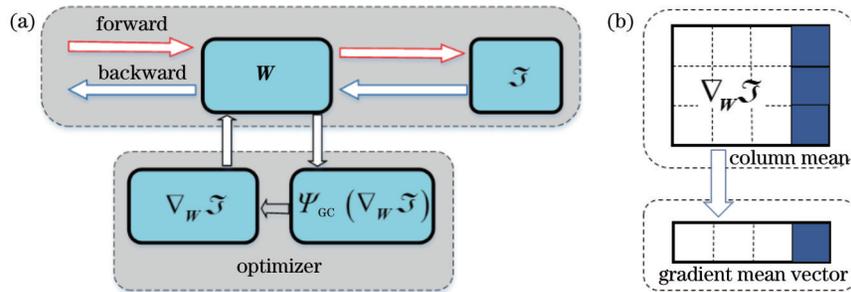


图 4 GC 优化过程示意图。(a) GC 优化示意图; (b) GC 方法产生效果的可视化

Fig. 4 Schematic of GC optimization process. (a) Schematic of GC optimization; (b) visualization of the effect of GC method

DNN 模型通过反向传播得到权重梯度, 对于权重矩阵的第  $l$  列的权重向量  $\mathbf{w}_l$ , 其梯度为  $\nabla_{\mathbf{w}_l} \mathfrak{J}$  ( $l = 1, 2, \dots, N$ ), 表示梯度矩阵的第  $l$  列向量。用  $\Psi_{GC}$  表示 GC 的优化过程, 可得到

$$\Psi_{GC}(\nabla_{\mathbf{w}} \mathfrak{J}) = \nabla_{\mathbf{w}} \mathfrak{J} - \beta \nabla_{\mathbf{w}} \mathfrak{J}, \quad (16)$$

式中:  $\beta \nabla_{\mathbf{w}} \mathfrak{J} = \frac{1}{M} \sum_{j=1}^M \nabla_{\mathbf{w}_{j,l}} \mathfrak{J}$ ,  $\beta$  为  $M$  维矩阵的平均值,  $M$  为权重矩阵的维数。对于梯度矩阵  $\nabla_{\mathbf{w}} \mathfrak{J}$ , 先求出列

向量中每个元素的平均值, 再从权重矩阵的列向量中去除平均值。对权重矩阵的每个列向量进行相同的操作, 从而实现梯度矩阵集中化。将  $\beta \nabla_{\mathbf{w}} \mathfrak{J}$  代入式(16) 并合并之后, 提出一个因子  $P$ , 最终得到

$$\begin{cases} \Psi_{GC}(\nabla_{\mathbf{w}} \mathfrak{J}) = P \nabla_{\mathbf{w}} \mathfrak{J} \\ P = I - \mathbf{e} \mathbf{e}^T \end{cases}, \quad (17)$$

式中:  $I \in \mathbf{R}^{M \times M}$  为单位矩阵;  $\mathbf{e} = \frac{1}{\sqrt{M}}$  表示  $M$  维单位

向量。

图 5 所示为 GC-RMSprop 的优化过程。通过 GC 实现 DNN 训练参数更新,并将 GC 嵌入 DNN 优化器 RMSprop 中,以进一步提高模型的有效性。在获得集中式梯度  $\Psi_{GC}(\nabla_w \mathcal{J})$  后,直接更新权重矩阵。其中优

化算法中的  $\rho$  表示衰减速率值; $\epsilon$  是防止分母为 0 引入的变量; $m$  表示权重梯度的平方值,初始化时将其设置为 0; $g$  和  $\hat{g}$  分别为权重的梯度值和经过 GC 处理后的权重梯度值。

Algorithm GC-RMSprop optimization algorithm	
<b>Input:</b>	Weight vector $w^0$ , learning rate $\eta$ , fraction of gradient decay $\rho$ , computability guard $\epsilon$ , $m^0$
<b>Training step:</b>	
1.	<b>for</b> $t=1, \dots, T$ <b>do</b>
2.	$g^t = \nabla_w \mathcal{J}$
3.	$\hat{g}^t = \Psi_{GC}(g^t)$
4.	$m^t = \rho m^{t-1} + (1-\rho) \hat{g}_t \odot \hat{g}_t$
5.	$\hat{m}^t = m^t / (1-\rho^t)$
6.	$w^{t+1} = w^t - \eta \frac{1}{\sqrt{\hat{m}^t + \epsilon}}$
7.	<b>end for</b>

图 5 GC-RMSprop 的优化过程

Fig. 5 Optimization process of GC-RMSprop

## 4 仿真与分析

为了验证所提 GC-DNN 方法在 ACO-OFDM VLC 系统中信道估计的有效性,设计了以下相关实验,并以误码率(BER)和 MSE 作为评价指标(值越小,系统性能均越好),对比方法选用 LS 和 MMSE 方法。房间尺寸设置为  $5\text{ m} \times 5\text{ m} \times 3\text{ m}$ ,通过信道向信号中加入加性高斯白噪声(AWGN);发射机采用 LED,分布在天花板顶部;接收机采用光电二极管,接收机平面距离地面 1 m;选用单输入单输出模型。LOS Lambertian 通信模型的相关参数设置如表 1 所示。在 OFDM 系统中,CP 的长度为 16;调制方式采用 4-QAM,该调制方式将传输数据分布在星座图上;系统子载波数为 64。信道估计需要插入导频序列,本次仿真采用梳状导频在 OFDM 符号的子载波上周期性放置导频序列,并按照特定的频率间隔发送导频。采用端到端的方式进行信道估计,在接收端采集经过 FFT 之后的频域接收信号作为数据集,接收信号为复数形式的信号。此外,将数据集随机分成 80% 和 20% 两个部分,其中 80% 作为训练集,20% 作为测试集。由于 DNN 的输入只允许实数信号,但经过 FFT 后的接收信号为复数形式,因此分别提取频域接收信号的实部与虚部,并将其结合作为网络输入层的输入数据。将 DNN 网络设计为 5 层,每一层对应的神经元个数分别为 256、512、256、128、64<sup>[27]</sup>。输入层和输出层的神经元数量分别为两者输入数据的长度。利用一个独立训练的单一模型对输出层的传输数据按照 16 位进行

分组和预测,然后将其连接起来组成最后的输出结果。GC-DNN 模型训练时的参数设置如表 2 所示。

表 1 LOS Lambertian 通信模型的参数设置

Table 1 Parameter setting of LOS Lambertian communication model

Parameter	Value
Refractive index	1.5
Viewing angle / (°)	70
Half power angle / (°)	60
Photoelectric conversion efficiency	0.51
Receiving area / cm <sup>2</sup>	1
Single LED emission power / W	0.05

表 2 GC-DNN 训练阶段参数设置

Table 2 Parameter setting of GC-DNN training phase

Parameter	Value
Learning rate $\eta$	0.001
Fraction of gradient decay $\rho$	0.9
Computability guard $\epsilon$	$10^{-7}$
Maximum number of epochs	500

### 4.1 GC-DNN 模型性能分析

为了分析引入 GC 优化算法对网络训练的收敛速度和优化性能的影响,将 GC-DNN 模型与利用经典梯度下降算法进行优化的 DNN 模型进行对比,建立了两种模型下的迭代次数与 MSE 之间的关系,结果如图 6 所示。在相同条件下引入 DNN 模型,经典 DNN 模型

大约在 95 个 epoch 时趋于收敛, 而引入 GC 的 DNN 模型大约在 80 个 epoch 接近收敛, 并且具有更小的 MSE, 表明引入 GC 后 DNN 模型的收敛速度更快, MSE 性能更好。

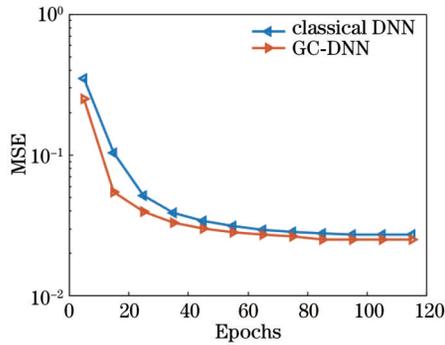


图 6 不同 DNN 模型随迭代次数变化的 MSE

Fig. 6 MSE of different DNN models varying with the iterations

为了进一步说明 GC-DNN 性能的优越性, 将 GC-DNN 模型与经典 DNN 模型完成一个 OFDM 符号向前传递所消耗的时间进行对比<sup>[28]</sup>, 经典 DNN 模型所消耗的时间为  $1.5 \times 10^{-6}$  s, 而 GC-DNN 消耗的时间为  $1.4 \times 10^{-6}$  s, 比经典 DNN 模型消耗的时间更短。由于 GC-DNN 能够约束损失函数并具有较好的抗扰动力, 能加速和平滑训练过程, 使网络训练更稳定、高效,

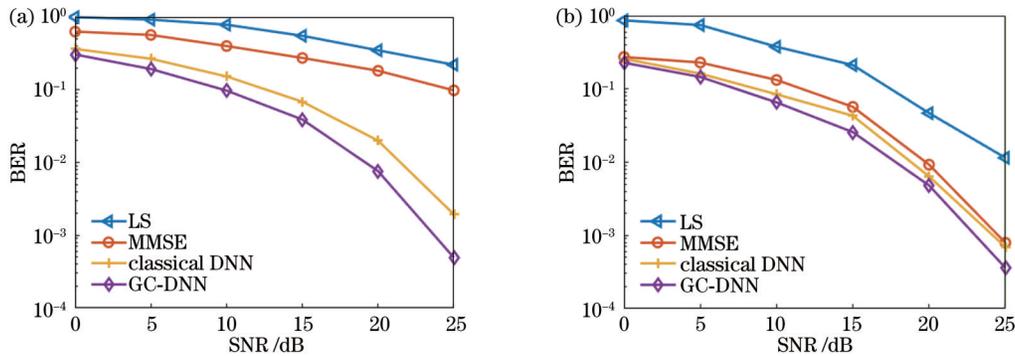


图 7 不同方法在 8 和 64 导频下的 BER。(a) 8 导频; (b) 64 导频

Fig. 7 BER of different methods at 8 and 64 pilots. (a) 8 pilots; (b) 64 pilots

图 8 所示为上述 4 种方法在不同导频数量下的 MSE 性能, 可以看到: MSE 随着 SNR 的增加逐渐减小; LS 方法 MSE 性能最差, 而所提方法 (GC-DNN) 具有更好的 MSE 性能。在 8 导频下, LS 和 MMSE 方法 MSE 曲线达到饱和, 而 DNN 方法的估计精度并不受导频数量的影响, 即使在较少的导频数量下也具有较好的 MSE 性能, 因此可以用更少的导频数量进行信道估计, 从而获得更好的频谱利用率。此外, 引入 GC 可使 DNN 网络的训练更快、更高效, 相比于经典 DNN 方法具有更优的 MSE 性能。在 64 导频下, 当 BER 为  $10^{-1}$  时, GC-DNN 方法的 SNR 增益比 LS 方法高 8 dB 左右, 比 MMSE 方法高 2 dB

因此与经典 DNN 模型相比, GC-DNN 模型的耗时更短。

#### 4.2 导频数量分析

基于导频辅助的信道估计方法以牺牲频谱资源为代价。图 7 所示为不同方法在不同导频数量下的 BER 性能。可以看到, BER 整体上随着 SNR 的增大逐渐减小。由图 7 可知: 所提方法 (GC-DNN) 的 BER 性能最好, LS 方法的性能最差, 这是因为 LS 方法没有利用信道的先验统计信息进行估计, 导致估计精度不高; 由于假设信道的二阶统计信息是已知并用于信道估计, MMSE 方法的 BER 性能优于 LS 方法; 经典 DNN 方法的 BER 性能优越, 是因为信道的 CSI 分布不均匀, 经典 DNN 模型可以根据生成的训练数据来学习信道的特性。为了提高频谱利用率, 将导频数量设置为 8, 从图 7(a) 可以看到, 传统方法的 BER 性能明显降低, 这是因为 LS 和 MMSE 方法 BER 性能的提升依赖导频数量的增加, 而 DNN 方法不受导频数量的影响, 其 BER 性能优于传统方法; 由图 7(b) 可知, 将导频数量设为 64, 当 BER 为  $10^{-1}$  时, GC-DNN 方法的 SNR 增益相比于 LS 和 MMSE 方法分别提升了 10.0 dB 和 4.2 dB。与经典 DNN 模型相比, GC-DNN 由于引入了 GC, 在相同条件下具有更好的 BER 性能。可见, GC-DNN 使用较少的导频数量也能获得较好的估计性能, 可以降低导频的频谱占用率。

左右。

#### 4.3 鲁棒性分析

为了进一步研究导频数量对 GC-DNN 信道估计 BER 和 MSE 性能的影响, 对 GC-DNN 方法分别插入 8、16、32、64 个导频进行信道估计时的 BER 和 MSE 性能进行比较, 结果如图 9 所示。由图 9 可知, 随着 SNR 增大, BER 和 MSE 逐渐降低, 并且所提方法在不同导频数量下的 BER 和 MSE 性能相差不大。基于 DNN 的方法的 BER 和 MSE 均随着 SNR 的增加而降低, 这表明所提方法对于信道估计的导频数量具有鲁棒性, 相较于传统方法, 其使用较少的导频就能达到较好的估计效果。

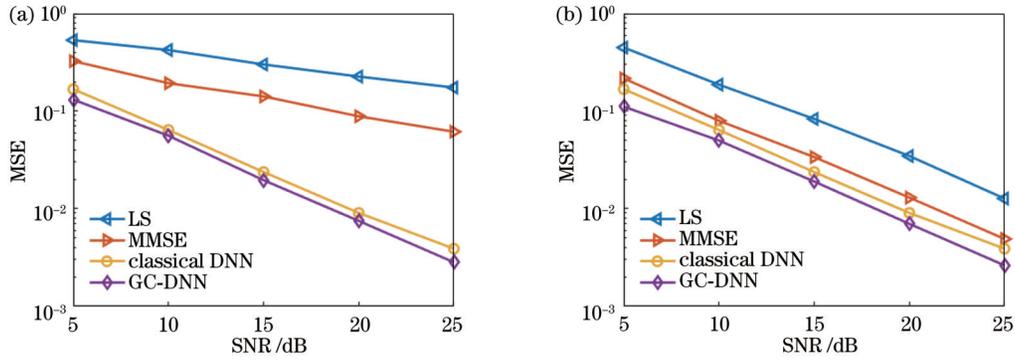


图 8 不同方法在 8 和 64 导频下的 MSE。(a) 8 导频;(b) 64 导频  
Fig. 8 MSE of different methods at 8 and 64 pilots. (a) 8 pilots; (b) 64 pilots

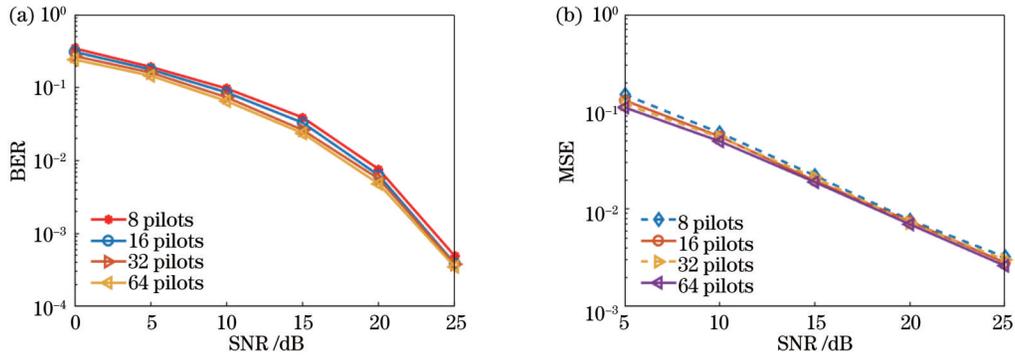


图 9 GC-DNN 方法在不同导频数量下的 BER 和 MSE 性能。(a) BER;(b) MSE  
Fig. 9 BER and MSE performance of GC-DNN method under different number of pilots. (a) BER; (b) MSE

#### 4.4 CP 分析

CP 对于 OFDM 系统十分重要,可以消除由系统带来的 ISI 和 ICI,但是在系统中加入 CP 会降低数据的传输速率和发射功率。对此设计实验来评估有/无 CP 情况下不同方法的 BER 曲线,结果如图 10 所示。考虑到 LS 和 MMSE 等传统方法的估计性能受到导频数量的影响较大,而 DNN 方法受导频数量的影响较小,所以选取导频数量为 64,这是因为在 64 导频下传统方法的估计性能较好。

当去除 CP 后,由于系统受到 ISI 和 ICI 的影响,LS 和 MMSE 方法的信道估计 BER 性能明显降低。当 SNR 增加时,LS 和 MMSE 方法的 BER 曲线逐渐趋于饱和,不能有效进行信道估计;即使去除 CP,DNN 方法依然表现出较好的估计性能。由于 DNN 模型通过多个隐藏层来获取训练数据中隐藏的结构特性,隐式地从先前的估计信道中学习时变信道的时变相关性,然后将它们与当前获取的数据合并,以进一步提高信道估计的准确性。在有/无 CP 下,GC-DNN 方法均表现出最好的 BER 性能,其中在去除 CP 后,当 BER 为 0.266 时,GC-DNN 方法的 SNR 增益高于 LS 方法 19.1 dB 左右,高于 MMSE 方法大约 11.9 dB。这说明 GC-DNN 方法有较强的鲁棒性,去除 CP 不会对信道估计准确性造成很大的影响,进而降低 ISI 和 ICI 对

VLC 系统 CP 的依赖,提高系统效率。

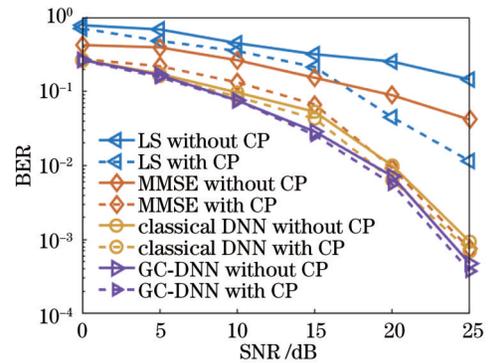


图 10 不同方法在有/无 CP 情况下的 BER  
Fig. 10 BER of different methods with or without CP

## 5 结 论

针对传统方法的信道估计存在精度低、效率不高等问题,提出一种基于 DNN 的信道估计方法,并建立基于 GC-RMSprop 优化算法的 DNN 模型对系统进行信道估计。仿真结果表明:所提方法的 BER 和 MSE 性能相比于 LS 和 MMSE 等传统方法有明显提升,适用于 VLC 系统的信道估计,对提升 VLC 系统性能具有重要意义;在使用较少导频以及去除 CP 后,所提方

法仍然能正常工作,表明所提方法具有更高的频谱利用率和较强的鲁棒性;相较于利用经典梯度下降算法优化的 DNN 模型,经 GC 优化的 DNN 模型具有较快的收敛速度和更好的 MSE 性能。综上,所提方法为 VLC 系统实现高频谱利用率、强可靠性提供一种有效的信道估计参考方案。

## 参 考 文 献

- [1] Khan L U. Visible light communication: applications, architecture, standardization and research challenges[J]. *Digital Communications and Networks*, 2017, 3(2): 78-88.
- [2] 贾科军, 郝莉, 余彩虹. 室内可见光通信多径信道建模及 MIMO-ACO-OFDM 系统性能分析[J]. *光学学报*, 2016, 36(7): 0706005.  
Jia K J, Hao L, Yu C H. Modeling of multipath channel and performance analysis of MIMO-ACO-OFDM system for indoor visible light communications[J]. *Acta Optica Sinica*, 2016, 36(7): 0706005.
- [3] 张健, 王辉. 一种改进的可见光通信系统 SNR 均匀性优化方法[J]. *重庆邮电大学学报(自然科学版)*, 2015, 27(1): 78-82.  
Zhang J, Wang H. An improved SNR uniformity optimization scheme for VLC system[J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2015, 27(1): 78-82.
- [4] 贾科军, 魏少博, 蒯莹, 等. 可见光通信预编码光正交频分复用系统的研究[J]. *光学学报*, 2021, 41(17): 1706004.  
Jia K J, Wei S B, Lin Y, et al. Research on precoding optical orthogonal frequency division multiplexing system in visible light communication[J]. *Acta Optica Sinica*, 2021, 41(17): 1706004.
- [5] Vappangi S, Vakamulla V M. Channel estimation in ACO-OFDM employing different transforms for VLC[J]. *AEU-International Journal of Electronics and Communications*, 2018, 84: 111-122.
- [6] Zhang C, Du H Q, Wu Z J. Sparsity-based channel estimation in visible light communication[C]//2018 IEEE/CIC International Conference on Communications in China (ICCC), August 16-18, 2018, Beijing, China. New York: IEEE Press, 2018: 126-130.
- [7] Lu C Y, Wu S, Jiang C X, et al. Weak harmonic signal detection method in chaotic interference based on extended Kalman filter[J]. *Digital Communications and Networks*, 2019, 5(1): 51-55.
- [8] Manur V B, Ali L. Compressed sensing channel estimation for STBC-SM based hybrid MIMO-OFDM system for visible light communication[J]. *International Journal of Communication Systems*, 2020, 33(11): e4403.
- [9] Mu Z, Liu Y Y, Wang Y, et al. Anonymous crowdsourcing-based WLAN indoor localization[J]. *Digital Communications and Networks*, 2019, 5(4): 226-236.
- [10] 陈勇, 尹辉, 刘焕淋. MIMO-OFDM 可见光通信系统的自适应信道估计[J]. *中国激光*, 2016, 43(9): 0906003.  
Chen Y, Yin H, Liu H L. Adaptive channel estimation for MIMO-OFDM visible light communication system[J]. *Chinese Journal of Lasers*, 2016, 43(9): 0906003.
- [11] Miao P, Chen G J, Wang X B, et al. Adaptive nonlinear equalization combining sparse Bayesian learning and Kalman filtering for visible light communications[J]. *Journal of Lightwave Technology*, 2020, 38(24): 6732-6745.
- [12] Jiao J Y, Sun X H, Fang L, et al. An overview of wireless communication technology using deep learning[J]. *China Communications*, 2021, 18(12): 1-36.
- [13] Gao Y L, Wu Z Y, Wang J. Convolution neural network-based time-domain equalizer for DFT-Spread OFDM VLC system[J]. *Optics Communications*, 2019, 435: 35-40.
- [14] Zhao Y H, Zou P, Yu W X, et al. Two tributaries heterogeneous neural network based channel emulator for underwater visible light communication systems[J]. *Optics Express*, 2019, 27(16): 22532-22541.
- [15] Gao Z P, Wang Y H, Liu X D, et al. FFDNet-based channel estimation for massive MIMO visible light communication systems[J]. *IEEE Wireless Communications Letters*, 2020, 9(3): 340-343.
- [16] Lu X Y, Lu C, Yu W X, et al. Memory-controlled deep LSTM neural network post-equalizer used in high-speed PAM VLC system[J]. *Optics Express*, 2019, 27(5): 7822-7833.
- [17] Cao B Y, Yuan K C, Li H, et al. The performance improvement of VLC-OFDM system based on reservoir computing[J]. *Photonics*, 2022, 9(3): 185.
- [18] Salama W M, Aly M H, Amer E S. Enhanced deep learning based channel estimation for indoor VLC systems[J]. *Optical and Quantum Electronics*, 2022, 54(9): 535.
- [19] Costa W S, Samatelo J L A, Rocha H R O, et al. CNN direct equalization in OFDM-VLC systems: evaluations in a numerical model based on experimental characterizations[J]. *Photonic Network Communications*, 2022: 1-11.
- [20] Mei K, Liu J, Zhang X Y, et al. A low complexity learning-based channel estimation for OFDM systems with online training [J]. *IEEE Transactions on Communications*, 2021, 69(10): 6722-6733.
- [21] Sun Y, Shen H, Du Z G, et al. ICINet: ICI-aware neural network based channel estimation for rapidly time-varying OFDM systems[J]. *IEEE Communications Letters*, 2021, 25(9): 2973-2977.
- [22] Mashhadi M B, Gündüz D. Pruning the pilots: deep learning-based pilot design and channel estimation for MIMO-OFDM systems[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(10): 6315-6328.
- [23] 石佳, 黄爱萍, 陶林伟. 深度学习辅助水下光通信信道估计和信号检测[J]. *中国激光*, 2022, 49(17): 1706004.  
Shi J, Huang A P, Tao L W. Deep learning aided channel estimation and signal detection for underwater optical communication[J]. *Chinese Journal of Lasers*, 2022, 49(17): 1706004.
- [24] 王铠尧, 洪智勇, 曾志强. 可见光通信系统的符号定时偏移估计方法[J]. *光学学报*, 2022, 42(7): 0706007.  
Wang K Y, Hong Z Y, Zeng Z Q. Symbol timing offset estimation method for visible light communication systems[J]. *Acta Optica Sinica*, 2022, 42(7): 0706007.
- [25] Klambauer G, Unterthiner T, Mayr A, et al. Self-normalizing neural networks[C]//NIPS'17: Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, CA, USA. New York: ACM Press, 2017: 972-981.
- [26] Yong H W, Huang J Q, Hua X S, et al. Gradient centralization: a new optimization technique for deep neural networks[M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12346: 635-652.
- [27] Ye H, Li G Y, Juang B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. *IEEE Wireless Communications Letters*, 2018, 7(1): 114-117.
- [28] Gao X X, Jin S, Wen C K, et al. ComNet: combination of deep learning and expert knowledge in OFDM receivers[J]. *IEEE Communications Letters*, 2018, 22(12): 2627-2630.

# Neural-Network-Based Channel Estimation Method for Visible Light Communication Systems

Chen Yong<sup>1\*</sup>, Wu Zhiqian<sup>1</sup>, Liu Huanlin<sup>2</sup>, Hu Chenyi<sup>1</sup>, Wu Jinlan<sup>1</sup>, Wang Chuangshi<sup>1</sup>

<sup>1</sup>Key Laboratory of Industrial Internet of Things & Network Control, Ministry of Education, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

<sup>2</sup>School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

## Abstract

**Objective** It has been widely noticed that visible light communication (VLC) has the advantages of anti-electromagnetic interference, abundant spectrum resources, and low cost. This paper introduces an efficient asymmetrically clipped optical orthogonal frequency division multiplexing (ACO-OFDM) modulation method to accommodate visible light communication systems using orthogonal frequency division multiplexing (OFDM) with positive real number constraints. However, the signal is easily distorted by multi-path interference of the channel during transmission, which results in poor communication quality of the VLC system. The VLC system mainly recovers the signal by obtaining the channel state information, and how to provide accurate feedback on the high-dimensional state information is particularly important to improve the communication quality of the VLC system. The commonly employed channel estimation method is based on the guide frequency assisted method. Among the existing methods, least squares (LS) method treats the channel as an ideal one and ignores its noise for channel estimation. Despite low complexity, the estimation accuracy is not high. Minimum mean square error (MMSE) is utilized for channel estimation due to the assumption that the second-order statistical information of the channel is known and adopted for channel estimation, but the estimation accuracy increases with the complexity. Deep learning provides a new solution for accurate feedback of channel state information, but few deep learning methods for channel estimation in ACO-OFDM systems have been reported. To improve the problems of low estimation accuracy and efficiency, and a large number of leads in channel estimation of ACO-OFDM systems, this paper proposes a deep neural network channel estimation method to improve the communication quality of the system.

**Methods** A deep neural network (DNN)-based channel estimation method is proposed for the channel estimation of the ACO-OFDM visible light communication system. Within this scheme, an end-to-end approach is applied to implicitly estimate channel state information and directly recover distorted signals. The DNN network is divided into an offline training phase and an online implementation phase. In the offline training phase, the fast Fourier-transformed received signal at the receiver is leveraged as the input of the DNN network, and the original transmitter signal is the ideal output of the network. The mean square error (MSE) is adopted as the loss function of the network to minimize the MSE between the network output and the ideal output. The well-trained DNN model is then implemented in the ACO-OFDM system for online deployment. In addition, with an aim to accelerate the DNN network training and ensure that the model can make accurate predictions on the test data, the DNN network is optimized through gradient centralization (GC), which is embedded in the optimizer for processing and acts on the gradient of the weight vector to constrain the loss function. The estimation accuracy of the DNN-based ACO-OFDM channel estimation method is further improved to enhance the communication performance of the system.

**Results and Discussions** The effectiveness of the proposed method is verified by the relationship between the performance indexes of bit error rate (BER) and MSE and signal noise ratio (SNR). The conventional methods of least squares (LS) and MMSE are selected as the comparison algorithms. The parameters of the system are set as shown in Tables 1 and 2. The convergence speed and MSE of the DNN network after the introduction of the gradient concentration (GC) method are better than those of the DNN network using the classical gradient descent method (Fig. 5). When channel estimation is performed at 8 pilots and 64 pilots, the method in this paper shows the best BER performance compared with other methods. At 8 pilots, the LS and MMSE methods are no longer effective for channel estimation. At 64 pilots and BER of  $10^{-1}$ , the proposed method improves the SNR gain by 10 dB and 4.2 dB compared to LS and MMSE (Fig. 6). The proposed method also exhibits the best MSE performance at different pilots, which indicates that the proposed method is robust to the pilots and can obtain better estimation performance at fewer pilots, thus improving the spectrum utilization (Fig. 7). The robustness of the pilots is analyzed, and the BER and MSE performances of the proposed method are not affected by the pilots (Fig. 8). Cyclic prefix (CP) is important for OFDM systems, but the CP inclusion in the system reduces the data transmission rate and wastes time and efforts. The BER performance of the

proposed method is not affected when analyzing with/without CP, but the conventional method can no longer work properly without CP. The proposed method improves the SNR gain by 19.1 dB and 11.9 dB at a BER of 0.266 compared to the LS and MMSE methods respectively (Fig. 9). This shows that the proposed method does not significantly affect the channel estimation by removing CP and reduces the dependence of inter-symbol interference and inter-carrier interference on CP. The gradient centralization optimized DNN method outperforms the DNN method with the classical gradient descent method in terms of BER and MSE performances.

**Conclusions** To address the problems of low accuracy and inefficient channel estimation facing traditional methods, this paper proposes a DNN-based channel estimation method. The simulation results show that the BER and MSE performances of this method are significantly improved compared with the traditional methods of LS and MMSE. The method is applicable to the channel estimation of the visible light communication system and is important to improve the performance of the visible light communication system. Additionally, it still works well under less guide frequency and removing. The proposed method has better spectral utilization and stronger robustness than the DNN model optimized by the classical gradient descent algorithm, and the DNN model optimized by gradient centralization has higher convergence speed and better MSE performance than the DNN model optimized by the classical gradient descent algorithm. In summary, the proposed method provides an effective channel estimation reference scheme for visual light communication systems to achieve high spectrum utilization and reliability.

**Key words** optical communications; asymmetrically clipped optical orthogonal frequency division multiplexing; channel estimation; deep neural network