

引用本文: 邱涵, 张峰, 赵黎. 基于 NOMA-VLC 系统的 GWO-DNN 信道估计方法[J]. 光通信技术, 2024, 48(2): 62-67.

基于 NOMA-VLC 系统的 GWO-DNN 信道估计方法

邱涵, 张峰*, 赵黎

(西安工业大学 电子信息工程学院, 西安 710021)

摘要: 为了解决室内非正交多址(NOMA)可见光通信(VLC)信道估计方法的可靠性和用户公平性低问题,提出了一种在 NOMA-VLC 系统中使用灰狼优化(GWO)算法对深度神经网络(DNN)进行信号补偿和恢复的方法,即 GWO-DNN 信道估计方法。该方法引入非线性收敛因子和二维混沌映射,有效提升了系统可靠性和多用户传输公平性。实验结果表明:在误码率(BER)为 10^{-4} 时,所提方法比最小均方误差(MMSE)方法最高可获得 4.3 dB 的信噪比(SNR)增益,两用户的 SNR 差异由 3.2 dB 降到 0.9 dB;在不同阶次的正交幅度调制下,所提方法的性能均优于 MMSE 方法,且调制阶次越高性能改善越明显。

关键词: 可见光通信;非正交多址接入;神经网络;灰狼算法;信道估计

中图分类号: TN929.1 文献标志码: A 文章编号: 1002-5561(2024)02-0062-06

DOI: 10.13921/j.cnki.issn1002-5561.2024.02.011

开放科学(资源服务)标识码(OSID):



GWO-DNN channel estimation method based on NOMA-VLC system

QIU Han, ZHANG Feng*, ZHAO Li

(Academy of Electronic and Information Engineering, Xi'an Technology University, Xi'an 710021, China)

Abstract: In order to solve the problems of low reliability and user fairness in indoor non-orthogonal multiple access(NOMA) visible light communication(VLC) channel estimation methods, a method of using the Gray Wolf optimizer(GWO) algorithm to compensate and restore signals in deep neural network(DNN) in NOMA-VLC systems, that is GWO-DNN channel estimation method. This method introduces nonlinear convergence factors and two-dimensional chaotic mapping, effectively improving system reliability and multi-user transmission fairness. Experimental results show that, at a bit error rate(BER) of 10^{-4} , the proposed method can achieve a maximum signal-to-noise ratio(SNR) gain of 4.3 dB compared to the minimum mean square error(MMSE) method, and the SNR difference between the two users is reduced from 3.2 dB to 0.9 dB. Under different orders of quadrature amplitude modulation, the performance of the proposed method is better than the MMSE method, and the higher the modulation order, the more significant the performance improvement.

Key words: visible light communication, non orthogonal multiple access, neural network, Grey Wolf algorithm, channel estimation

0 引言

非正交多址(NOMA)利用功率域复用,能够根据

收稿日期: 2023-10-16。

基金项目: 国家自然科学基金项目(12004292)资助;陕西省科技厅一般项目-工业领域项目(2022GY-072)资助;西安市科技计划项目(2020KJRC0040)资助。

作者简介: 邱涵(1998—),女,新疆维吾尔自治区昌吉自治州人,硕士研究生,主要研究方向为可见光通信技术及其应用、神经网络、模式识别与智能系统。曾荣获相关领域省级竞赛二等奖 1 项、省级竞赛三等奖 1 项、社会奖学金 2 次、校级学业一等和三等奖学金各 1 次。



*通信作者: 张峰(1979—),男,硕士,教授,主要从事现代通信技术、可见光通信、智能信息处理与控制等方面的研究工作。

用户的信道增益同时传递多用户信息,从而改变了功率域中单一用户独占资源的传统策略^[1]。在可见光通信(VLC)中引入 NOMA 技术,实现多用户场景下可见光组网通信,这是无线通信领域由电磁走向光介质的一个切入点。然而, NOMA-VLC 系统面临着一些挑战,其中多径效应会导致信号失真与衰减,同时多用户信号在时域上的叠加容易引发用户间的相互干扰。为了提高系统通信性能并保证通信可靠性,需要一种更高性能的信道估计方法。传统的信道估计方法,如压缩感知和参数估计,都需要进行高维矩阵分解和迭代计算以获取精确的信道响应。然而,这种方法在性能和计算复杂度之间很难取得平衡。而神经网络通过大量

邱涵,张峰,赵黎:基于 NOMA-VLC 系统的 GWO-DNN 信道估计方法

其中, H 为信道增益, Z 为信道干扰。

由于 NOMA 系统实现了功率域的复用通信,不同用户间的信号会产生相互干扰,导致通信可靠性下降。同时,不同用户的信道条件具有显著差异,这会造成不同用户间性能的差异,进而降低用户间的公平性。为了解决这些问题,实际应用中常引入 Turbo 编码技术来降低信道对通信的影响,提高系统性能。然而,在进行 Turbo 编码与 OFDM 中的厄米特对称操作时,数据量会大幅增多,这可能导致系统的有效性降低。因此,本文提出利用神经网络进行自适应学习,结合 GWO 算法以实现信道准确估计^[7]。

2 基于 GWO-DNN 的信道估计方法

2.1 GWO 算法

在 GWO 算法中,每个灰狼代表一组参数,整个灰狼种群则代表一个解空间。灰狼的位置对应于参数的取值,其适应度则反映了这些参数取值的性能优劣^[8]。在每次迭代过程中,算法会根据灰狼的适应度和整个种群的信息来更新其位置和速度,从而寻找更优的参数组合。灰狼群被分为 4 个等级:最优解 α 、次优解 β 、第三优解 δ 、候选解 ω 。整个优化过程在 α 、 β 、 δ 的引导下进行, ω 跟随它们进行优化迭代。当这 3 个层级趋于稳定时,算法会选取 α 的位置作为猎物位置,即所求的最优参数^[9]。设置可行域中的适应度函数 F 为

$$F = \alpha \gamma_R(D) + \beta \frac{|C-B|}{|C|} \quad (3)$$

其中, $\gamma_R(D)$ 是部分特征集 B 的分类质量, C 为全部特征集, $\alpha \in [0, 1]$, $\beta = 1 - \alpha$ ^[10]。

为了均衡 GWO 算法的局部和全局搜索能力,本文在运用该算法时采用了二维混沌映射来初始化种群,并用非线性收敛因子替换了原有的线性收敛因子。二维混沌映射为

$$\begin{cases} x_{n+1} = ay_n^2 + bx_n + c \\ y_{n+1} = x_n \end{cases} \quad (4)$$

其中, n 为当前迭代步骤,当 $n=0$ 时, $x_1=0.15$; a 、 b 、 c 为控制参数, $a=-4$, $b=0$, $c=0.5$ 。

2.2 优化 DNN

DNN 模型为

$$y = \sum_{j=1}^u w_{i,j} x_j + \theta_i \quad (5)$$

其中, y_i 为输出层第 i 个神经元的输出, x_j 为输入层第 j 个神经网络的输入信号(接收导频信号), $w_{i,j}$ 为输入层

第 j 个神经元到隐藏层第 i 个神经元的权值, θ_i 为隐藏层第 i 个神经元的阈值, u 为输出层神经元的个数。

本文使用 GWO 算法优化 DNN, 建立 GWO-DNN 的算法结构。算法将每个灰狼(网络中 $w_{i,j}$ 和 θ_i) 表示为一组参数, 整个种群表示所有可能的参数组合。每个灰狼的适应度用训练集上的损失函数值来衡量, 通过迭代更新每个灰狼的参数, 从而找到最小化损失函数的最优参数组合。具体算法步骤如下:

- 1) 确定 DNN 的架构, 并初始化其网络参数。
- 2) 定义目标函数为 DNN 的训练误差, 其中神经网络的 $w_{i,j}$ 和 θ_i 为自变量。
- 3) 初始化灰狼群体: 使用二维混沌映射生成随机序列, 将每个灰狼的参数向量初始化为神经网络的参数。
- 4) 计算每个灰狼的适应度: 将每个灰狼的参数向量代入目标函数, 计算出适应度的最优解(α 狼的位置 X_α)、次优解(β 狼的位置 X_β)以及第三优解(δ 狼的位置 X_δ)。在确定了这些最优解之后, 将根据一定的规则更新剩余狼的位置信息, 这些规则包括使用非线性收敛因子 u 来调整更新过程。同时, 还需要根据适应度值和其它相关因素来更新参数 B 、 C 和 α 的值。其中, $\alpha = 2 - 2(2^{\frac{t}{t_{\max}}} - 1)$, $t_{\max}$ 为最大迭代次数, t 为当前迭代次数。
- 5) 更新灰狼群体: 根据更新后的位置, 重新计算每个灰狼的适应度, 并更新最优解。
- 6) 检查算法的终止条件: 如果达到最大迭代次数, 则算法结束; 否则, 返回步骤 5) 继续更新灰狼种群。
- 7) 使用反向传播算法更新 DNN 参数: 使用当前最优解的参数向量更新 DNN 的 $w_{i,j}$ 和 θ_i , 并重新训练神经网络。
- 8) 返回步骤 4) 并重复执行, 直到满足训练误差要求或达到最大迭代次数。

2.3 GWO-DNN 信道估计方法训练

本文提出了一种基于导频的信道估计方法。该方法通过利用已知的导频位置信息, 预测未来某时刻导频位置的信道状态信息, 并以此为依据, 替代实际的信道状态, 从而获取有价值的信道信息。该方法的主要优势在于其自适应估计信道响应的能力, 即无需先验知识也能进行准确估计。

为了区分相关量, 下标 p 代表导频, 下标 z 代表数据。若 X_p 为发送端导频数据频域信号, Y_p 为接收端收到的导频频域信号, 则导频处信道响应为

$$H_p = \frac{Y_p}{X_p} \quad (6)$$

将 H_p 输入到基于 GWO-DNN 的信道估计模型中, 得到一个 OFDM 符号内除导频位置外其余有用数据处的信道响应 $\hat{H}_z$, 进而恢复出发送信号。数据位置处信道响应真实值 H_z 为

$$H_z = \frac{Y_z}{X} \quad (7)$$

其中, Y_z 为接收端收到的数据信号。

GWO-DNN 的输入层负责接收导频位置的信道响应数据, 这些数据经过最小二乘法 (LS) 算法处理后, 分离出其实部和虚部作为输入。而输出层则输出一个 OFDM 符号中除了导频位置之外的有效数据点的信道响应实部和虚部。在处理每个样本时, 本文将导频位置的信道响应实部和虚部组合成一个列向量, 作为网络的输入; 相应地, 有效数据点信道响应的真实值的实部和虚部也被组合成一个列向量, 作为网络的标签值。本文使用均方误差 (MSE) 函数衡量信道响应估计值 $\hat{H}_w$ 与信道响应真实值 H_w 之间的误差为

$$L(\theta) = \frac{1}{N} \sum_{n=1}^N |H_z - \hat{H}_z|^2 \quad (8)$$

其中, N 为系统采用的子载波个数, 则输入数据可表示为

$$X_{in} = [X^R, X^I] \quad (9)$$

其中, X^R 和 X^I 分别表示接收端复数信息的实部和虚部。

基于 NOMA-VLC 系统的 GWO-DNN 信道估计分为离线训练和在线估计 2 个阶段, 如图 2 所示。

离线训练阶段: 首先, 从实际环境中采集先验数据, 提取导频, 并使用 LS 算法计算导频处的信道响应




图 2 基于 NOMA-VLC 系统的

GWO-DNN 信道估计离线训练和在线估计示意图

H_{p0} 。随后, 将这些数据作为输入, 信道响应真实值 H_w 作为标签, 用于训练 GWO-DNN 模型, 使其能够准确地预测或估计信道响应。最后, 当模型训练达到预设的准确度时, 保存模型和相关参数, 以便后续使用。


在线估计阶段: 按照图 1 所示, 完成 NOMA-VLC 系统的可见光发送和接收功能, 利用之前训练好的 GWO-DNN 模型进行实时的信道响应估计或预测。

3 实验与分析


3.1 实验平台及参数设置

本文搭建了一个室内可见光通信实验平台, 如图 3 所示。该平台采用 2 个用户系统、4QAM, 包括 1 个发射端和 2 个接收端 (模拟 2 个用户)。

信号处理过程如下: 2 个用户信号在电脑端分别进行 Turbo 编码和 4QAM, 随后通过 NOMA 编码形成叠加编码。在叠加信号中插入导频后, 进行 OFDM 调制, 并加入直流偏置, 确保 LED 照明的同时能够传输数据。处理完的数据传入发送端, 经数据处理 (包括数模转换、信号放大、Bias-T 直流偏置) 后, 最终由 LED 发送。在接收端, 2 个装有聚光镜的光电探测器 (PD) 模



(a) 示意图



(b) 实物图

图 3 2 个用户室内 VLC 实验平台

邱涵,张峰,赵黎:基于 NOMA-VLC 系统的 GWO-DNN 信道估计方法

拟 2 个用户接收信号。信号经过数据处理器处理后传入电脑端。在电脑端,数据经过 GWO-DNN 信道估计、OFDM 解调、连续干扰消除(SIC)、QAM 解调、Turbo 译码,还原出原始的 2 个用户信号。

实验共使用 100 kB 的训练数据,模拟并记录了 2 个用户的接收端随机摆放 100 组坐标位置。每组位置坐标代表一个信道环境,从而构成了训练数据集 H_p 。实验中,同步头采用 Zadoff-Chu 序列,导频长度为 16,损失函数为 MSE,评估标准为误码率(BER),优化器为 Adam。神经网络训练达到拟合阈值标准需要 3.8 h,但拟合后只需保存网络并上传至通信系统,后续使用时无需再训练。

NOMA-VLC 系统、GWO-DNN 的参数配置分别如表 1、表 2 所示。

3.2 实验结果分析

3.2.1 几种信道估计方法性能对比

本文采用几种信道估计方法优化 NOMA-VLC 系统性能,对比情况如图 4 所示。图中以各信道估计方法的缩写代替各方法。可以看出,随着 SNR 增大,DNN、GWO-DNN、最小均方误差(MMSE)方法均能显著降低 BER;当用户的 BER 达到 10^{-4} 时,GWO-DNN 方法相较于 MMSE 方法在 SNR 上低了 2.5 dB;当采用 LS 算法和无信道估计时,系统的 BER 较高,并且随着 SNR 的增大,BER 的下降趋势不明显。

3.2.2 GWO 算法优化能力

为了验证 GWO 算法的优化能力,本文对比了 DNN 添加 GWO 算法前后拟合速度和 2 个用户的 BER 性能,结果如图 5 所示。

由图 5(a)可知,添加 GWO 算法后,DNN 的拟合速度显著提升,相较于未使用 GWO 算法的情况,迭代次数减少了约 300 次。从图 5(b)可以看出,引入 GWO 算法后的曲线更为平滑,特别在 BER 为 10^{-4} 时,2 个

表 1 NOMA-VLC 系统的参数配置

NOMA-VLC 参数	值
子载波数	64
CP 长度	16
调制方式	4QAM
信道类型	瑞利信道
导频插入方式	块状导频
子载波带宽/Hz	1
LED 调制带宽/MHz	10
射频载波频率/MHz	3.75
LED 额定功率/W	3

表 2 GWO-DNN 的参数配置

神经网络参数	值
输入层维度	(64, 2)
学习率	0.01
隐藏层节点个数	128, 64, 64
输出层激活函数	Sigmoid
隐藏层激活函数	Relu
灰狼种群数量/个	50
GWO 最大迭代次数/次	500

用户场景下的 GWO-DNN 信道估计方法相较于仅使用 DNN 的方法,SNR 增益达到了 3.8 dB,同时 2 个用户之间的 SNR 差异减少了 0.4 dB。图 5 表明,GWO 算法在优化 DNN 参数时,能够有效减少训练误差,提高模型的泛化能力,从而优化神经网络性能,加快训练速度,并提升精度,确保 2 个用户在使用时的公平性。

3.2.3 不同调制阶次对系统性能的影响

在 2 个用户场景下,不同调制阶次(16、32、64)对系统性能的影响如图 6 所示。可以看出,3 种调制阶次下,系统经过 2 种信道估计方法处理时均可以达到基本通信要求,其中 GWO-DNN 方法 BER 性能与 2 个用户间公平性均优于 MMSE 方法,2 种方法在 BER 为






图 4 几种信道估计方法性能对比



(a) 迭代次数对比



(b) 2 个用户 BER 性能对比

图 5 DNN 与 GWO-DNN 性能对比




图 6 不同调制阶次对系统性能的影响

10^{-4} 时具体性能对比如表 3 所示。此外,本文还进行了无信道估计的性能实验,以探究这 3 种调制阶次下的系统表现。实验结果显示,当系统无信道估计时,BER 均大于 10^{-4} 。

表 3 不同调制阶次时的用户性能差异对比(单位: dB)

调制阶次	信道估计方法	2 个用户性能对比		
		用户 1 的 SNR	用户 2 的 SNR	用户 SNR 差异
16	MMSE	27.0	29.7	2.7
	GWO-DNN	24.1	25.4	1.3
32	MMSE	32.9	35.5	2.6
	GWO-DNN	30.8	31.7	0.9
64	MMSE	35.9	39.1	3.2
	GWO-DNN	34.3	35.2	0.9

由表 3 可以看出,在 BER 为 10^{-4} 时,不同调制阶次下采用 GWO-DNN 方法的 2 个用户 SNR 性能差异均优于 MMSE 方法;采用同阶次 MMSE 方法的 2 个用户 SNR 差异在 3 dB 左右,而采用同阶次 GWO-DNN 方法的 2 个用户差异在 0.9 dB 左右;采用同阶次、不同信道估计法的相同用户间 SNR 差异在 3 dB 左右。

4 结束语

本文提出了一种在 NOMA-VLC 系统中使用 GWO 算法对 DNN 进行信号补偿和恢复的方法。通过引入非线性收敛因子和二维混沌映射,有效提升了系统可靠性和多用户传输公平性。GWO-DNN 信道估计方法可最小化训练误差并提高模型的泛化能力,使得拟合速度更快,迭代次数减少了约 300 次;当 BER 为 10^{-4} 时,采用 GWO-DNN 方法比 MMSE 方法获得了大于 1.6 dB 的 SNR 增益。由于 GWO-DNN 信道估计方法具备学习和分析 VLC 信道特性的能力,因此,它在提升 NOMA-VLC 系统性能方面展现出广泛的应用前景。

参考文献:

- [1] 迟楠, 贾俊连. 面向 6 G 的可见光通信 [J]. 中兴通讯技术, 2020, 26(2): 11-19.
- [2] JIN Y, ZHANG J, JIN S, et al. Channel estimation for cell free mm Wave massive MIMO through deep learning[J]. IEEE Transactions on Vehicular Technology, 2019, 68(10): 10325-10329.
- [3] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [4] HUANG H, YANG J, HUANG H, et al. Deep learning for superresolution channel estimation and DOA estimation based massive MIMO system [J]. IEEE Transactions on Vehicular Technology, 2018, 67(9): 8549-8560.
- [5] 张峰, 梁渊博, 赵黎, 等. 基于非正交多址的室内可见光通信系统性能优化方法[J]. 红外与激光工程, 2021, 50(11): 311-317.
- [6] 许俊翔, 林邦姜, 汤璇, 等. 一种基于 LSTM 的 OFDM-VLC 后失真补偿方法[J]. 光通信技术, 2020, 44(1): 54-57.
- [7] 王海峰, 李萍, 王博, 等. 灰狼算法优化 BP 神经网络的图像去模糊复原[J]. 液晶与显示, 2019, 34(10): 992-999.
- [8] HE H, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems [J]. IEEE Wireless Communications Letters, 2018, 7(5): 852-855.
- [9] CHIN, JIA J, HU F, et al. Challenges and prospects of machine learning in visible light communication[J]. Journal of Communications and Information Networks, 2020, 5(3): 302-309.
- [10] 丁瑞敏, 田军委, 刘雪松, 等. 轻量化卷积神经网络目标检测算法研究[J]. 西安工业大学学报, 2022, 42(2): 188-194.