

引用本文: 姜彬, 周鹏. 6G 短距离可见光通信信道估计与均衡[J]. 光通信技术, 2025, 49(1): 38–43.

6G 短距离可见光通信信道估计与均衡

姜彬, 周鹏

(江苏航运职业技术学院 智能制造与信息学院, 江苏 南通 226010)

摘要: 为了提升室内短距离可见光通信(VLC)的传输速率和通信质量, 提出了一种基于正交时频空间(OTFS)调制和残差卷积神经网络(ResCNN)的 VLC 信道估计和均衡方法。首先, 构建了 OTFS 调制下的室内 VLC 系统, 并提出了基于训练序列的时频域信道估计模型。接着, 利用 ResCNN 学习最小二乘(LS)信道估计到优化信道之间的映射关系, 以解决符号间干扰问题并提高信道估计的准确性。最后, 通过 ResCNN 对可见光信道进行估计和均衡。实验结果表明, 在信号传输距离为 1 m、传输速率为 512 Mb/s~1.5 Gb/s 时, 该方法估计的误码率均低于 3.8×10^{-3} , 有效提升了室内短距离 VLC 的传输速率和通信质量。

关键词: 可见光通信; 短距离通信; 信道估计; 信道均衡化; 深度学习

中图分类号: TN929.12; TP394.1 **文献标志码:** A **文章编号:** 1002-5561(2025)01-0038-06

DOI: 10.13921/j.cnki.issn1002-5561.2025.01.007

开放科学(资源服务)标识码(OSID):



Channel estimation and equalization of short distance visible light communication in 6G

JIANG Bin, ZHOU Peng

(Intelligent Manufacturing and Information College, Jiangsu Shipping College, Nantong Jiangsu 226010, China)

Abstract: To improve the transmission rate and communication quality of indoor visible light communication (VLC), a VLC channel estimation and equalization method based on orthogonal time-frequency space (OTFS) modulation and residual convolutional neural network (ResCNN) is proposed. First, an indoor VLC system based on OTFS modulation is constructed, and a time-frequency domain channel estimation model based on training sequences is proposed. Then, ResCNN learns the mapping relationship between the least squares (LS) channel estimation and the optimized channel to solve the inter-symbol interference problem and improve the accuracy of channel estimation. Finally, the visible light channel is estimated and equalized using ResCNN. The experimental results show that when the signal transmission distance is 1 m and the transmission rate is 512 Mb/s to 1.5 Gb/s, the bit error rate estimated by the proposed method is lower than 3.8×10^{-3} , effectively improving the transmission rate and communication quality of indoor short-distance VLC.

Key words: visible light communication, short distance communication, channel estimation, channel equalization, deep learning

0 引言

第六代(6G)移动通信技术时代将实现移动通信网络的全域覆盖^[1], 包括空中、地面和水下空间。鉴于无线射频的频谱资源有限, 可见光通信(VLC)作为一

收稿日期: 2024-08-01。

基金项目: 江苏省第五期 333 工程科研项目(BRA2018220)资助; 南通市自然科学基金项目(JCZ2023029) 资助。

作者简介: 姜彬(1980—), 男, 江苏如皋人, 硕士, 副教授, 网络管理员高级技师, 主要从事计算机网络、智能系统等方面的教学与应用研究工作, 发表论文约 20 篇, 主持完成了江苏省大学生创新训练计划项目 1 项, 省部级和市厅级科研项目各 1 项, 以及横向合作项目 1 项, 并获得了 2 项专利授权。



种与射频通信互补的无线通信技术, 有望成为 6G 系统不可或缺的一部分^[2-3]。目前, 无论是室内 VLC^[4]还是水下 VLC^[5]都已获得了广泛研究。发光二极管(LED)以其环保耐用、同时具备照明与通信双重功能的特点, 成为当前室内 VLC 中最常用的光源^[6]。但是, LED 的带宽相对较窄^[7], 因此如何提高频谱效率成为提升室内 VLC 性能的关键所在。尽管 VLC 不存在多普勒频移的问题, 但它仍面临着由不同传输路径导致的多径衰落效应挑战。当前许多 VLC 系统采用了正交频分复用(OFDM)技术来应对多径效应和符号间干扰。然而, OFDM 技术需要在每个符号之前插入循环前缀(CP), 这不仅增加了帧的长度, 还减少了每帧内可用的用户

数据量,最终导致 VLC 系统的总容量下降。

正交时频空间(OTFS)调制^[8]通过利用时间与频率的正交特性,能够增强多径传播环境下的容量与可靠性。研究表明,OTFS 调制在相同频谱效率下的接收灵敏度优于 OFDM 调制^[9],并且 OTFS 调制无需在每个符号前添加 CP,可以有效提升室内 VLC 的频谱效率和传输速度^[10-11]。然而,当 CP 数量不足时,OTFS 调制在处理可见光多径传播时会出现严重的符号间干扰,进而显著影响 VLC 的通信质量^[12-13]。

近年来,研究者们提出了 2 种不同的 OTFS 信道估计算法:一种是基于变换域基函数的方法^[14-16],另一种则是基于机器学习的方法^[17]。这 2 种方法在提升 OTFS 信道估计的精度和降低计算复杂度方面均取得了显著进展。然而,它们通常需要在 OTFS 系统中引入额外的导频信号,这不仅要求设计专门的帧结构,还可能对室内 VLC 系统的数据传输速率造成负面影响。

针对上述问题,本文提出一种基于 OTFS 调制与残差卷积神经网络(ResCNN)的可见光信道估计与均衡方法,旨在提高室内短距离 VLC 的传输速率和通信质量。

1 基于 OTFS 调制的室内 VLC 原理与信道模型

基于 OTFS 调制的室内 VLC 原理框图如图 1 所示。输入的比特流数据首先经过 OTFS 调制,生成相应的时域信号。随后,任意波形发生器将此数字时域信号转化为模拟信号。接下来,可变增益放大器对模拟信号的幅度进行调节,以适应 LED 驱动电路的要求。“T”型偏置器(Bias-T)则用于调节 LED 的偏置电压,确保 LED 能够在最佳状态下工作,从而将电信号高效地转换为可见光信号。经过室内自由空间的传输后,可见光信号被接收端的透镜汇聚到光电探测器(PD)上,PD 将接收到的光信号转换回电信号。最后,示波器将这一电信号数字化,数字信号再经过 OTFS 解调器处理,恢复成原始的比特流数据。

1.1 OTFS 调制

在 OTFS 调制过程中,首先将输入的比特信息通过正交幅度调制(QAM)映射后投影到延迟-多普勒(DD)域。接着,利用逆辛有限傅里叶变换(ISFFT)将 DD 域信号转换到时频域。为了满足 VLC 系统的需求,保证发送信号为实数,采用厄米特对称处理对 DD 域矩阵的每一列进行处理。然后,通过 $S \times K$ 点(S 为 DD 域子载波数, K 为符号数)的海森堡变换将时频域(TF)信号转换为时域信号。最后,将并行的时域信号转换成




图 1 基于 OTFS 调制的室内 VLC 原理框图

串行信号序列,并在信号序列的开头添加训练序列,以辅助接收端的同步与信道估计过程。

1.2 OTFS 解调

在 OTFS 解调过程中,首先使用 $S \times K$ 点的魏格纳变换将接收到的时间域信号转换到时频域。随后,将接收到的训练序列送入信道估计模块以完成信道估计。假设估计的信道为 H ,对接收的时频域信号矩阵 Y 进行均衡处理,此过程可表示为

$$Y' = YH^{-1} \quad (1)$$

其中, Y 为接收的时频域信号矩阵, Y' 为均衡处理后的时频域信号矩阵。

接下来,采用辛有限傅里叶变换(SFFT)将信号从时频域转换到 DD 域,SFFT 的数学式为

$$Y^{DD} = \sqrt{\frac{S-1}{2K}} \sum_{s=0}^{\frac{S}{2}-2} \sum_{k=0}^{K-1} Y' e^{j2\pi\left(\frac{sf}{S-1} - \frac{kq}{K}\right)} \quad (2)$$

其中, Y^{DD} 为 DD 域的符号矩阵, k 为时延轴上点的索引, f 与 q 为信号在 TF 域的索引。 s 为多普勒频移, $s \in \{0, 1, \dots, S-1\}$ 。

然后,QAM 解调器将信号从 DD 域转换成并行比特,此过程可表示为

$$B = Q^{-1}(Y^{DD}) \quad (3)$$

其中, $Q^{-1}(\cdot)$ 表示 QAM 解调器。

最后,通过计算输出比特流的误比特率来评估整个通信系统的性能表现。

2 最小二乘(LS)+ResCNN 信道估计与均衡

2.1 信道估计原理

卷积神经网络(CNN)因其强大的局部感知能力、权值共享特性和平移不变性,成为提取空间特征的有效工具。随着网络层数的增加,CNN 能够捕捉到更为

姜彬, 周鹏: 6G 短距离可见光通信信道估计与均衡

复杂的特征,但同时也面临着梯度消失和梯度爆炸等挑战。为了解决这些问题,ResCNN 引入了残差机制,有效改善了深度网络训练的稳定性。为了在特征提取能力和计算效率之间找到一个良好的平衡点,ResCNN 通常设计为 13 层,其中计算复杂度较高的部分集中在 4 层卷积层上。ResCNN 结构如图 2 所示,ResCNN 通过卷积层学习信道的特征表示,并利用 skip 连接将梯度流与卷积层输出直接相加,从而有效避免了梯度消失和梯度爆炸现象。




图 2 ResCNN 结构图

在图像处理领域,ResCNN 已被成功应用于图像降噪任务,通过学习噪声图像与干净图像间的映射关系,实现了高效的降噪处理。借鉴这一思路,本文提出了一种基于 ResCNN 的方法,用于改进信道估计的准确性。具体而言,本文将 LS 估计得到的信道视为“噪声信道”,并利用 ResCNN 学习从这个“噪声信道”到理想信道(正定信道)的映射关系,以此提高信道均衡的效果。尽管 LS 估计方法简单且计算成本较低,但由于没有考虑噪声的影响,其估计结果往往不够精确。因此,本文采用 LS 估计的信道作为 ResCNN 的输入,让网络学习如何从 LS 估计的信道响应映射到更准确的信道响应。在具体的实现过程中,首先将 LS 估计得到的时频域信道分解为频域矩阵与时域矩阵。接着,这些矩阵被输入到 ResCNN 的卷积层中进行特征提取。假设第一个卷积层的输入为 I_1 ,输出为 O_1 ,且使用 3×3 的

二维卷积核。卷积层的数学模型可表示为

$$O_1 = \text{Conv}(I_1, w_1) + b_1 \quad (4)$$

其中, b_1 与 w_1 分别表示第一个卷积层卷积核的偏置与权重, $\text{Conv}(\cdot)$ 表示二维卷积运算。

为了加速训练过程并提高网络的泛化能力,本文采用了批量归一化技术,并使用 ReLU 激活函数来增强网络对复杂非线性特征的学习能力。ReLU 函数定义为

$$\text{ReLU}(z) = \max(0, z) \quad (5)$$

其中, z 为激活函数的输入变量。

此外,为了防止过拟合,本文在网络中加入了 Dropout 层,设置 Dropout 率为 0.2。最后,通过一个回归层输出 ResCNN 对信道的预测结果。

2.2 信道估计与均衡流程

2.2.1 离线阶段

离线阶段包括数据收集和 ResCNN 训练 2 个部分。训练序列的数据处理流程如图 3 所示。




图 3 训练序列的数据处理流程

在时频域内,本文使用 LS 估计方法来获取信道响应。对于第 n 个子训练序列 I_n ,其 LS 估计的信道响应记作 H_{LS}^n 。将 H_{LS}^n 分解为频域分量和时域分量,则 I_n 可以表示为

$$I_n = \{F_r(H_{\text{LS}}^n), T_i(H_{\text{LS}}^n)\} \quad (6)$$

其中, $F_r(\cdot)$ 和 $T_i(\cdot)$ 分别提取信道的频域分量和时域分量。

I_n 输入 ResCNN 产生的预测矩阵可表示为

$$O_n = \{F_r(H^n), T_i(H^n)\} \quad (7)$$

其中, H^n 为 ResCNN 的预测信道。

ResCNN 学习输入到输出的映射关系,可表示为

$$\{F_r(H_{ls}^n), T_r(H_{ls}^n)\} \Rightarrow \{F_r(H^n), T_r(H^n)\} \quad (8)$$

ResCNN 的训练目标是 minimized 正定信道和预测信道之间的最小均方误差(MSE)。基于 MSE 的损失函数 $l_{\text{CENet}}(w, b)$ 定义为

$$l_{\text{CENet}}(w, b) = \frac{1}{N} \sum_{n=1}^N \|H^n - \hat{H}^n\|_2^2 \quad (9)$$

其中, H^n 为对应的正定信道, w 和 b 分别为 ResCNN 的权重参数和偏置参数, N 为训练信道样本总数。

ResCNN 的训练流程如图 4 所示。图中, E 表示当前 epoch, $E_{\max}$ 表示预设的最大 epoch 轮数。训练过程中, 通过反向传播迭代地调整 ResCNN 的权重参数 w 和偏置参数 b , 以最小化损失函数。




图 4 ResCNN 的训练流程

2.2.2 在线阶段

在 ResCNN 信道估计阶段, 首先加载已训练的 ResCNN 模型, 用于对信道进行估计; 接着, 利用估计得到的信道信息对接收数据进行均衡化处理; 最后, 计算并得出接收数据的误码率。ResCNN 信道估计的在线阶段处理流程如下:

- 1) 加载离线阶段训练的 ResCNN 估计器;
- 2) 加载测试训练序列和 ResCNN 参数;
- 3) 基于测试训练序列产生 LS 估计信道;
- 4) 基于 LS 估计信道产生 ResCNN 估计信道;

- 5) 将信道频域和时域部分结合重建估计信道;
- 6) 使用重建估计信道对接收用户数据进行均衡;
- 7) 计算测试集数据传输的误码率。

3 实验与结果

3.1 实验参数

本文基于 PyTorch 1.7.0 实现了 ResCNN, 编程环境为 Python 3.6 与 Matlab 2019a。硬件配置方面, 使用的是 Intel i7-13700KF CPU, 搭配 Nvidia TITAN RTX 显卡, 后者具有 24 GB 的显存容量。实验系统的搭建遵循图 1 的设计。调制方式采用 16QAM, ISFFT 符号矩阵大小设定为 58×256 , 海森堡变换点数为 128。实验中使用的子载波数量为 58 个, 过采样因子设为 6, 数/模转换器采样率为 2.5 GSa/s, 而模/数转换器采样率为 10 GSa/s。偏置电压设置为 3.75 V, LED 的 3 dB 带宽为 83 MHz。室内自由空间传输的距离设为 0.5、1、1.5 m, 而数据传输速率设为 512 Mb/s、768 Mb/s、1 Gb/s 和 1.5 Gb/s。

对于每个子训练序列, 其长度定义为 $4 \times 58 = 232$ 个符号, 总共收集了 30 个这样的子训练序列组成总的训练集。在这些训练序列中, 90% 用于训练 ResCNN 模型, 剩下的 10% 用于验证。训练过程中采用了 Adam 优化器, 初始学习率设为 0.001, 批量大小(batch size)为 16, 整个训练过程计划进行 50 个 epochs。验证策略为每完成 5 个 epochs 后进行一次验证, 如果连续 2 次验证的损失值没有显著变化, 则提前终止训练以避免过拟合。测试阶段使用的训练序列长度同样为 232, 即相当于一个子训练序列的长度。为了生成随机比特流作为用户数据, 本文采用了 Matlab 内置的 randi() 和 dec2bin() 函数。

在进行 ResCNN 性能对比时, 本文选择了 LS 估计和符号内频域平均(ISFA)估计^[20]作为参考方法。在 ISFA 估计中, 平均化的相邻子载波数量被设定为 4 个, 即包括待估计子载波前后的各 2 个子载波。

3.2 实验结果

首先, 将发送速率固定为 512 Mb/s, 自由空间传输距离设定为 1 m, 以此测试数据误码率与峰峰值电压增益间的关系, 测试结果如图 5 所示。可以看出, 当峰峰值电压增益从 0 dB 增加至 10 dB 时, LS 估计方法的误码率始终高于 3.8×10^{-3} 的硬判决前向纠错 (HD-FEC) 阈值。相较于 LS 估计方法, ISFA 估计方法表现出更好的误码率性能, 在峰峰值电压增益为 4~6 dB 时, 其误码率能够降至 HD-FEC 阈值之下。然而, 无论

姜彬, 周鹏: 6G 短距离可见光通信信道估计与均衡




图5 峰峰值电压增益实验结果

是LS估计方法还是ISFA估计,这2种方法对信道的估计准确性都不高,未能有效对抗衰落信道的影响,从而导致较高的误码率。相比之下,在相同的峰峰值电压增益变化范围内,ResCNN估计展现出显著优于LS估计方法和ISFA估计方法的误码率性能。在整个测试范围内,ResCNN估计方法的误码率均保持在 3.8×10^{-3} 的HD-FEC阈值以下,尤其在峰峰值电压增益为5 dB时达到了最低点。ResCNN估计方法通过利用深度CNN的强大空间特征提取能力,成功学习到了从LS估计方法信道到正定信道的精确映射关系,实现了对衰落信道的有效估计与均衡,显著降低了室内VLC系统的误码率。

其次,本文测试了不同发送速率下3种估计方法的误码率性能。实验设置包括将峰峰值电压增益固定为5 dB,自由空间传输距离设定为1 m。在此设置下,分别计算了512 Mb/s、768 Mb/s、1 Gb/s和1.5 Gb/s这4种不同速率下的误码率,具体结果如图6所示。可以看出,随着传输速率的提升,3种估计方法的误码率均有不同程度的增加。这是由于随着速率的提升,信号




图6 不同速率的误码率性能

间的干扰加剧所致。然而,ISFA估计方法仅在768 Mb/s的速率下能满足HD-FEC的要求,而LS估计方法即便是在较低的传输速率下也无法达到HD-FEC的标准。相比之下,ResCNN估计方法不仅在低速传输时表现出更低的误码率,而且在传输速率不超过1 Gb/s的情况下,均可满足HD-FEC的要求。

最后,为了进一步评估传输距离对室内VLC系统性能的影响,本文在相同的峰峰值电压增益(5 dB)和发送速率(512 Mb/s)条件下,分别测量了信号在0.5、1、1.5 m自由空间传输距离下的误码率,结果如图7所示。可以看出,在3种信道估计方法中,ResCNN估计方法始终保持着最低的误码率。此外,由于发送端采用了透镜技术将可见光聚焦到直接传输路径上,接收端同样利用透镜技术将接收到的直射可见光聚焦到PD上,这使得即便是在自由空间传输距离从0.5 m增加到1.5 m的过程中,PD所检测到的光强度变化也相对较小。这表明传输距离对于误码率的影响较为有限,基于OTFS的室内VLC系统展现出了良好的传输距离适应性。




图7 不同自由空间传输距离的误码率性能

4 结束语

本文提出了利用ResCNN来进行VLC多载波信道的精确估计与均衡方法,这一方法有效地缓解了符号间干扰对VLC系统性能造成的负面影响。实验结果显示,在信号传输距离为1 m的情况下,当传输速率分别设定为512 Mb/s、768 Mb/s、1 Gb/s和1.5 Gb/s时,采用ResCNN估计方法得到的误码率均能保持在 3.8×10^{-3} 以下。本文提出的信道估计方案无需额外引入CP编码或导频信号,在离线阶段通过特定的训练序列对ResCNN模型进行训练;而在在线应用阶段,则只需少量训练序列即可高效完成信道估计任务,从而确保了

VLC 系统的整体容量不受影响。然而, 当前的方法主要适用于静态环境下的信道条件。未来的工作将重点探索如何在动态场景中实现 OTFS 调制下的室内 VLC 信道估计与均衡, 以期进一步拓展该方法的应用领域, 使其在即将到来的 6G 移动通信技术中展现出更广泛的价值。

参考文献:

- [1] 徐金雷, 赵俊涅, 卢华兵, 等. 面向 6G 的多维扩展通感一体化研究综述[J]. 电子与信息学报, 2024, 46(5): 1-12.
- [2] 孙婷, 杨康, 韩莹雪, 等. 可见光条件下的星图识别算法综述[J]. 光学技术, 2023, 49(4): 469-475.
- [3] MERDAN F A B, THIAGARAJAH S P, DAMBUL K. Non-line of sight visible light communications: a technical and application based survey[J]. Optik, 2022, 259(3): 168982-168991.
- [4] MIRAMIRKHANI F, KARBALAYGHAREH M, ZEYDAN E, et al. Enabling 5G indoor services for residential environment using VLC technology[J]. Physical Communication, 2022, 4(8): 53-61.
- [5] 朱义君, 王超, 汪涛, 等. 水下单光子 VLC 技术研究[J]. 光通信技术, 2020, 44(6): 1-5.
- [6] 黄兆标, 杨国伟, 樊冰, 等. 基于朗伯模型参数估计的 VLC 室内定位优化算法[J]. 光电子·激光, 2020, 22(6): 641-647.
- [7] 魏有财, 宋小庆, 赵梓旭, 等. 室内 VLC 白光 LED 调制带宽拓展[J]. 红外与激光工程, 2018, 47(9): 188-194.
- [8] SRIVASTAVA S, SINGH R K, JAGANNATHAM A K, et al. Bayesian learning aided sparse channel estimation for orthogonal time frequency space modulated systems[J]. IEEE Transactions on Vehicular Technology, 2021, 70(8): 8343-8348.
- [9] SHARMA A, JAIN S, MITRA R, et al. Performance analysis of OTFS over multipath channels for visible light communication[C]//2020 International Conference on Communications, Signal Processing, and Their Applications, March 16-18, 2021, Sharjah, United Arab Emirates. New York: IEEE, 2021: 1-6.
- [10] JBARI M E, MOUSSAOUI M. Efficient downlink MU-MIMO VLC systems with NOMA-OTFS modulation for indoor applications[J]. Optical Engineering, 2024, 31(2): 63-71.
- [11] MOHAMMED S K. Derivation of OTFS modulation from first principles[J]. IEEE Transactions on Vehicular Technology, 2021, 70(8): 7619-7636.
- [12] RAVITEJA P, VITERBO E, HONG Y. OTFS performance on static multipath channels[J]. IEEE Wireless Communication Letters, 2019, 8(3): 745-748.
- [13] 邢旺, 唐晓刚, 周一青, 等. 面向 OTFS 的时延-多普勒域信道估计方法综述[J]. 通信学报, 2022, 43(12): 188-201.
- [14] 张阳, 张群飞, 王樱洁, 等. 一种低复杂度正交时频空间调制水声通信方法[J]. 西北工业大学学报, 2021, 39(5): 954-961.
- [15] QU H, LIU G, ZHANG L, et al. Low-dimensional subspace estimation of continuous-doppler-spread channel in OTFS systems[J]. IEEE Transactions on Communications, 2021, 1(3): 1-1.
- [16] MATTU S R, CHOCKALINGAM A. Learning in time-frequency domain for fractional delay-doppler channel estimation in OTFS [J]. IEEE Wireless Communications Letters, 2024, 13(5): 1245-1249.
- [17] 赵如歌, 冯鹏, 罗燕, 等. 基于噪声水平估计的多孔准直 X 射线荧光 CT 去噪算法[J]. 光学学报, 2023, 43(20): 20340011-20340019.
- [18] 徐少平, 刘婷云, 罗洁, 等. 图像质量感知的混合噪声快速盲降噪算法[J]. 计算机研究与发展, 2019, 56(11): 2458-2468.
- [19] FANG X, WANG Y, ZHANG L, et al. Intra symbol frequency domain averaging channel estimation for coherent optical OFDM/OQAM system [C]//17th International Conference on Optical Communications and Networks(ICOCN2018), November 16-19, 2018, Zhuhai, China. Washington: SPIE, 2019: 83-92.