

基于神经网络的紫外光散射湍流信道估计方法

赵太飞^{1,2*}, 吕鑫喆¹, 孙玉歆¹, 张爽¹¹西安理工大学自动化与信息工程学院, 陕西 西安 710048;²陕西省智能协同网络军民共建重点实验室, 陕西 西安 710000

摘要 由于紫外光在传输过程中受到散射效应和大气湍流的影响,非直视无线紫外光通信中存在严重的码间串扰和传输衰减问题。提出一种基于深度学习的无线紫外光散射信道估计方法。在深度学习模型训练阶段,利用差分进化算法优化深度神经网络(DNN),根据网络最优的输出结果准确估计出信道特性,进而在接收端对传输衰减进行补偿。仿真结果表明:与最小二乘估计相比,所提方法的均方误差提升了 1 个数量级,在误码率性能方面提升了 2 个数量级;与最小均方误差估计相比,所提方法的均方误差提升了 38%,在误码率性能方面提升了 78%。此外,在 DNN 训练过程中引入差分进化算法,可以提高网络的学习收敛速度和全局优化能力。最后改变信道模型的湍流强度,验证了所提方法在不同湍流环境下的稳定性。

关键词 光通信; 无线紫外光通信; 单次散射; 大气湍流; 深度学习; 信道估计

中图分类号 TN929.12

文献标志码 A

doi: 10.3788/AOS202141.2406001

Neural-Network-Based Estimation Method for Ultraviolet Scattering Channel Under Turbulence

Zhao Taifei^{1,2*}, Lü Xinzhe¹, Sun Yuxin¹, Zhang Shuang¹¹Faculty of Automation and Information Engineering, Xi'an University of Technology, Xi'an, Shaanxi 710048, China;²Shaanxi Civil-Military Integration Key Laboratory of Intelligence Collaborative Networks, Xi'an, Shaanxi 710000, China

Abstract Atmospheric scattering and turbulence during the transmission of ultraviolet beams can cause severe intersymbol interference and transmission attenuation in a nonline-of-sight wireless ultraviolet optical communication system. To prevent these problems, a wireless ultraviolet scattering channel estimation method based on deep learning is proposed. In the training stage of deep learning model, the deep neural network (DNN) is optimized using differential evolution algorithm to accurately estimate the channel characteristics based on the optimal network output. Then, channel attenuation is compensated at the receiver. Simulation results show that compared with least-squares estimation, the mean-square error of the proposed method is increased by one order of magnitude, and the bit error rate is increased by two orders of magnitude. Compared with minimum mean-square error estimation, the mean-square error of the proposed method is increased by 38%, and the bit error rate is increased by 78%. In addition, differential evolution algorithm during DNN training accelerates learning convergence and promotes global optimization. Furthermore, the proposed method maintains stability in different environments with varying turbulence intensities in the channel model.

Key words optical communications; wireless ultraviolet optical communication; single scattering; atmospheric turbulence; deep learning; channel estimation

OCIS codes 060.4510; 060.2605; 290.1310; 010.1330

收稿日期: 2021-05-28; **修回日期:** 2021-06-23; **录用日期:** 2021-06-28

基金项目: 国家自然科学基金(61971345)、陕西省重点研发计划一般项目(2021GY-044)、陕西省教育厅科研计划(17-JF024)、西安市碑林区科技计划(GX1921)、榆林市科技计划(2019-145)

通信作者: *zhaotaifei@163.com

1 引言

无线紫外光散射通信是一种基于大气粒子散射的无线通信技术^[1]。由于具有较强的散射特性,无线紫外光可以应用于非直视(NLOS)等特殊的应用场景^[2]。紫外光束在大气中传输时会受到大气散射和湍流效应的影响,导致发生折射率起伏和脉冲展宽现象,严重时会导致码元之间产生码间串扰,直接影响光传播特性和通信性能。

在散射信道方面,关于利用蒙特卡罗方法对紫外光单次散射^[3-4]和多次散射^[5-7]的研究已有不少,通过对紫外光散射信道进行建模,研究非直视散射信道的脉冲响应、路径损耗及信道带宽等信道特性。在大气湍流环境下,紫外光传输信号会受到湍流等因素的影响,在整个通信系统中造成较大的传输衰减和误码率^[8],给后续的信号检测带来一定的困难。现有的研究大多利用对数正态分布^[9]和 Gamma-Gamma 分布^[10]来分析大气湍流信道模型和光传输特性,随着通信距离的增加,湍流引发的传输衰减已经不容忽视。如何消除散射和湍流效应给紫外光通信系统带来的影响,也是目前的研究热点。

针对湍流下散射信道造成通信系统性能下降的问题,信道估计是一种有效的解决方案。常用的信道估计方法有最小二乘(LS)估计^[11]、最小均方误差(MMSE)估计^[12]和贝叶斯(Bayesian)估计^[13]等。针对自由空间光通信中的信道估计问题,文献[14-16]利用非线性相关滤波技术和信道估计方法分析了自由空间光通信系统的误码率和信道容量等性能参数,进而估计出信道特性和湍流衰减的情况。对于无线紫外光散射通信的信道估计也有不少研究,Gong 等^[17]利用线性时不变的泊松信道模型对非直视无线紫外光散射通信进行建模,提出了基于最小二乘相关准则的信道估计方案。为了解决紫外光散射通信中的码间串扰问题,文献[18-19]研究了信道特性和通信信号的联合估计方法,在贝叶斯估计原理的基础上改进估计算法,可以有效地检测通信信号,实现可靠的信息传输。但是对于紫外光隐秘通信这种特殊的通信场景来说,传统算法的适用性并不强,导致信道估计系统性能下降,而且传统算法大多是非线性信道估计算法,计算复杂度很高。针对这两方面的问题,将深度学习技术引入到紫外光通信的信道估计中是一个新的思路,数据迭代训练可以使学习到的网络模型无限逼近真实的信道模

型^[20-22],而且深度学习类信道估计算法可以搭载到 GPU 上,使得运算效率得到大大的提升。

深度学习技术是提高信道估计准确性的重要手段之一,Hu 等^[23]提出一种基于生成对抗网络(GAN)的信道估计增强算法,可以在不增加实际训练序列开销的情况下提高信道估计的精度。陈小威等^[24]利用人工神经网络模型估算近地面光学湍流强度,通过优化多层感知器结构训练出气象参数和湍流强度的映射关系,提高系统的估算精度及泛化能力。文献[25]将神经网络应用于大气湍流环境中的光束传播性能分析,提出一种基于卷积神经网络的湍流相位信息提取方法,该方法具有较好的特征提取效果及训练效率。深度神经网络(DNN)在无线光通信信号处理方面也有一定的研究成果^[26-27],通常将通信系统的信号处理过程视为一个“黑盒”,学习输入与输出的非线性映射关系,相比传统的方法,DNN 具有较为简单的计算复杂度。

综上所述,神经网络在无线通信系统的信道估计应用方面已经取得了一定的成果。神经网络可以学习到隐藏在大量数据中难以发现的规律,从而降低无线通信系统算法的复杂度并提高系统性能。本文提出一种基于深度学习的无线紫外光散射信道估计方法,设计深度神经网络结构和差分进化算法来训练网络模型。通过训练好的 DNN 模型输出信道脉冲系数与接收信号的最优映射关系,所提方法准确提取出大气湍流下无线紫外光散射信道的统计特性,为通信系统中后续的信号检测和信道编码提供依据。

2 湍流下的非直视无线紫外光单次散射信道模型

无线紫外光非直视通信主要以单次散射为主,在远距离通信的情况下,大气湍流对光传输特性的影响不可忽视^[28]。提出一种考虑了大气湍流效应的紫外光单次散射信道模型,引入了折射率结构常数,信道模型如图 1 所示。图 1 中 T_X 为发射端; R_X 为接收端; d 为收发端之间的通信距离; β_T 和 β_R 分别为发射端和接收端的仰角; θ_T 为光束发散角; θ_R 为接收视场角; φ_T 和 φ_R 为偏轴角,主要研究共面情况下的单次散射,即取 $\varphi_T = \varphi_R = 0^\circ$; V 为公共散射体; d_1 和 d_2 分别为发射端和接收端到 V 的距离; θ_s 为散射角。信道几何结构参数和大气湍流环境参数共同决定了信道特性。




图 1 无线紫外光非直视单次散射信道模型

Fig. 1 Wireless ultraviolet NLOS single scattering channel model

2.1 单次散射路径损耗

通信系统收发两端之间的非直视链路可以看作是 d_1 和 d_2 两条直视链路之和。设发射端的传输功率为 P_t , 单位立体角的功率为 P_t/Ω_t , 由于散射过程中存在路径损耗和信号衰减, 故 P_t 经过 d_1 传输后衰减为 $P_t e^{-k_e d_1}/\Omega_t d_1^2$, 再经公共散射体 V 散射后为 $(P_t e^{-k_e d_1}/\Omega_t d_1^2) \cdot (k_s P_s V/4\pi)$, 之后还会受到大气衰减 $e^{-k_e d_2}$ 和空间链路损耗 $(\lambda/4\pi d_2)^2$ 的影响, 且检测器的接收增益为 $4\pi A_r/\lambda^2$ 。综上所述, 紫外光非直视单次散射通信链路接收光功率^[29]为

$$P_{r,NLOS} = \left(\frac{P_t}{\Omega_t}\right) \left(\frac{e^{-k_e d_1}}{d_1^2}\right) \cdot \left(\frac{k_s P_s V}{4\pi}\right) \left(\frac{\lambda}{4\pi d_2}\right)^2 \left(\frac{4\pi A_r}{\lambda^2}\right) \exp(-k_e d_2), \quad (1)$$

式中: Ω_t 为发射端光束立体角, 且 $\Omega_t = 2\pi(1 - \cos \frac{\theta_T}{2})$; $d_1 = \frac{d \sin \theta_R}{\sin \theta_s}$, $d_2 = \frac{d \sin \theta_T}{\sin \theta_s}$, $\theta_s = \theta_T + \theta_R$, $V \approx d_2 \cdot \theta_R \cdot d^2$ 。代入各参数, (1) 式可化简为

$$P_{r,NLOS} = \frac{P_t A_r k_s P(\mu) \theta_R \theta_T^2 \sin(\beta_T + \beta_R)}{32\pi^3 d \sin \beta_T \left(1 - \cos \frac{\theta_T}{2}\right)} \cdot \exp\left[-\frac{k_e d (\sin \beta_T + \sin \beta_R)}{\sin(\beta_T + \beta_R)}\right], \quad (2)$$

式中: k_s 和 k_e 分别为信道散射系数和信道衰减系数; $P(\mu)$ 为散射相函数, 其中 $\mu = \cos \theta_s$; A_r 为接收孔径面积。则路径损耗为

$$L = \frac{P_t}{P_r} = \frac{32\pi^3 d \sin \beta_T (1 - \cos \frac{\theta_T}{2})}{A_r k_s P(\mu) \theta_R \theta_T^2 \sin(\beta_T + \beta_R)} \cdot \exp\left[\frac{k_e d (\sin \beta_T + \sin \beta_R)}{\sin(\beta_T + \beta_R)}\right]. \quad (3)$$

2.2 大气湍流的光束衰减

紫外光信号经过信道传输之后发生的光功率衰减不仅由散射和吸收作用引起, 还与大气湍流造成的闪烁衰减(SA)有关。对于平面波情况下的直视链路来说, 通过 Rytov 理论, 可以近似得到湍流导致的 SA^[30]为

$$\alpha = 2 \cdot \sqrt{23.17 \cdot C_n^2 \cdot (2\pi/\lambda)^{7/6} \cdot d^{11/6}}, \quad (4)$$

式中: C_n^2 为折射率结构常数, 用来度量大气湍流强度; λ 为光波长。与研究单次散射类似, 这里同样将非直视链路分为两条直视链路, 分别为从 T_x 到 V 和从 V 到 R_x 。因此, 由(4)式可得两条直视链路的衰减分别为

$$\alpha_1 = 2 \cdot \sqrt{23.17 \cdot C_n^2 \cdot (2\pi/\lambda)^{7/6} \cdot d_1^{11/6}}, \quad (5)$$

$$\alpha_2 = 2 \cdot \sqrt{23.17 \cdot C_n^2 \cdot (2\pi/\lambda)^{7/6} \cdot d_2^{11/6}}. \quad (6)$$

则整条非直视通信链路上的 SA 为

$$\alpha_{\text{turb}} = \alpha_1 + \alpha_2 = 2 \cdot (\sqrt{23.17 \cdot C_n^2 \cdot (2\pi/\lambda)^{7/6} \cdot d_1^{11/6}} + \sqrt{23.17 \cdot C_n^2 \cdot (2\pi/\lambda)^{7/6} \cdot d_2^{11/6}}). \quad (7)$$

在弱湍流的情况下, 假设发射端 T_x 发射平面波, 光束发散角比较小, 使公共散射体 V 中湍流导致的 SA 保持恒定。使用对数正态(LN)分布模型来描述紫外光的信号强度分布, 为了方便计算, 对传输信号光强进行归一化处理, 概率密度函数^[31]为

$$f_i(I/\langle I \rangle) = \frac{1}{\sqrt{2\pi\sigma_I^2} \langle I \rangle} \cdot \exp\left\{-\left[\ln\left(\frac{I}{\langle I \rangle}\right) + \sigma_I^2/2\right]^2 / 2\sigma_I^2\right\}, \quad (8)$$

式中: I 为光强起伏; $\langle I \rangle$ 为光强起伏平均值; $I/\langle I \rangle$ 为归一化的光强起伏; σ_I^2 为传输光信号的对数光强起伏方差。

$$\sigma_I^2 = \exp(4\sigma_X^2) - 1, \quad (9)$$

式中: σ_X^2 为光波正态分布对数振幅变量 X 的方差。

$$\sigma_X^2 = 0.56(2\pi/\lambda)^{7/6} \int_0^d C_n^2(h) (d-h)^{5/6} dh. \quad (10)$$

随着紫外光子经单次散射到达接收端 R_x , 其接收到的光信号强度的条件概率密度函数为

$$f_r(I_r | I) = \frac{1}{\sqrt{2\pi} I_r \sigma_r} \cdot \exp\left\{-\left[\ln\left(\frac{I_r}{E(I_r | I)}\right) + \frac{1}{2}\sigma_r^2\right]^2 / 2\sigma_r^2\right\}, \quad (11)$$

式中: 固定的非直视信道几何模型 $E(I_r | I) = I \cdot A_r e^{-k_e d_2}/d_2^2$; σ_r^2 为接收光信号的对数光强起伏方

差,同样可用(9)式表示。根据以上推导,可以获得接收光信号强度的边缘密度函数分布:

$$f_r(I_r) = \int f_r(I_r | I) f_t(I) dI. \quad (12)$$

3 基于深度神经网络的信道估计方案

将深度学习技术应用于无线紫外光通信的信号处理过程,针对湍流环境下的非直视紫外光单次散射信道,利用神经网络强大的自主学习能力进行信道估计,准确估计出信道响应系数,进而恢复出

原始信号。基于深度神经网络的信道估计方案如图 2 所示,主要分为离线训练过程和在线估计部分。训练阶段中,首先对接收到的传输信息帧和信道模型进行特征提取,获得适合深度神经网络的低维特征参数,然后将此参数转换为矩阵形式输入到神经网络,通过不断地训练输出接收信号和信道响应系数的映射关系;在线估计部分,利用训练好的神经网络估计出最优的信道响应系数,在接收端准确恢复出发射信号,信道估计的准确度将直接影响整个系统的通信性能。

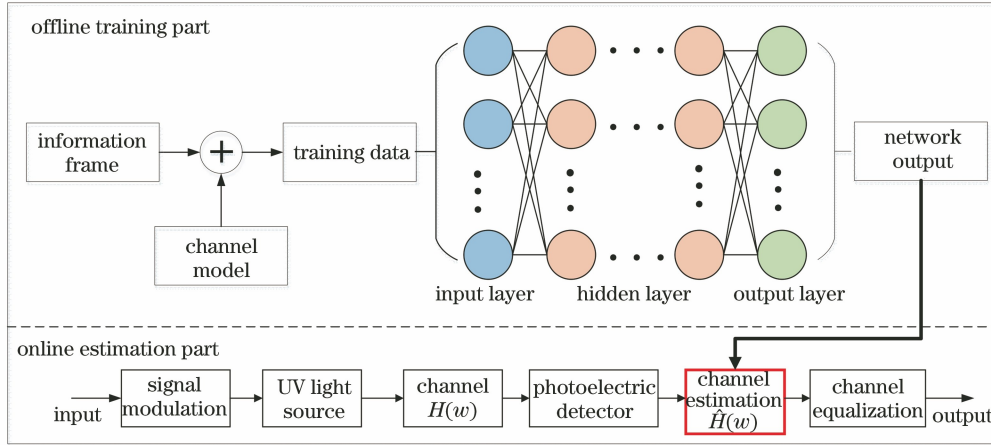


图 2 基于深度神经网络的无线紫外光信道估计方案

Fig. 2 Wireless ultraviolet channel estimation scheme based on deep neural network

3.1 深度神经网络模型

所使用的深度神经网络是深度学习中常用的网络模型,通过多个隐含层来捕获大量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输入与输出的最佳映射关系。图 3 为单个神经元的基本结构。

对于输入数据 $\mathbf{x}^{(l)} = (x_1, x_2, \dots, x_n)$ 来说,神

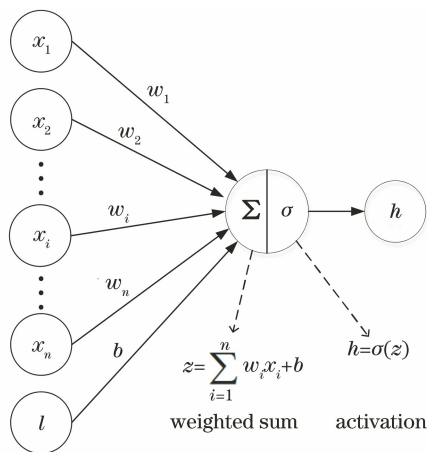


图 3 单个神经元的基本结构

Fig. 3 Basic structure of a single neuron

经元的输出为

$$h_{w,b}(\mathbf{x}^{(l)}) = \sigma(\mathbf{W}^T \mathbf{x}^{(l)}) = \sigma\left(\sum_{i=1}^n w_i x_i^{(l)} + b\right), \quad (13)$$

式中: \mathbf{W} 为隐含层之间以及输出层对应的权值系数; b 为偏置系数; σ 为激活函数,这里选择 Sigmoid 函数。

$$\sigma(x) = \frac{1}{1 + e^{-x}}. \quad (14)$$

本方案构建深度神经网络实现信道估计,使用的深度学习方法类属于一种回归预测问题,因此选择均方误差(MSE)函数作为损失函数,定义为

$$L_{\text{loss}}(\mathbf{W}, b, \mathbf{x}, \mathbf{y}) = \frac{1}{2} \|\mathbf{h}^L - \mathbf{y}\|_2^2, \quad (15)$$

式中: \mathbf{h}^L 为网络实际输出; \mathbf{y} 为目标输出; $\|\cdot\|_2$ 为二范数操作。

为了防止 DNN 训练过程中出现过拟合问题,使用 Dropout 方法进行正则化。在每次训练时,采用 Dropout 随机地激活一部分隐含层的神经元,使其他神经元处于未激活的状态,然后只对激活的神经元权重和偏置进行更新,即假设每个神经元以概

率 P 被激活,此神经元的输出值需要乘以 $1/P$ 来保证输入到下一层神经元的信号强度基本稳定。此概率的设置不宜过小,否则会造成欠拟合现象,本方案取 $P=0.6$ 。

3.2 差分进化算法优化深度神经网络

多层 DNN 的计算复杂度较高且易陷入局部最优,为了解决这个问题,本方案 DNN 训练过程中采用差分进化(DE)算法进行优化,使算法具有更大的搜索空间,进而提高系统的收敛速度并达到全局最优^[32]。DE 算法的目标是进化规模为 N_P 且由 D 维参量组成的种群,该 D 维参量称为个体,表示为 $\mathbf{X}_{i,G} = \{x_{i,G}^1, \dots, x_{i,G}^D\}, i=1, \dots, N_P, G$ 表示当前进化的代数,对种群中的所有个体进行变异、交叉和选择操作,寻找种群中的最优个体,具体操作如下。

1) 变异操作:在种群中任意选择两个个体作差,利用缩放后的差分向量与另一随机个体产生一个新的个体,变异方式为

$$\mathbf{V}_{i,G} = \mathbf{X}_{r_1,G} + F \cdot (\mathbf{X}_{r_2,G} - \mathbf{X}_{r_3,G}), \quad (16)$$

式中: r_1, r_2, r_3 是 $[1, N_P]$ 范围内的互斥整数,且与 i 不同; F 为缩放因子。

2) 交叉操作:为了增加种群的多样性,对原始个体 $\mathbf{X}_{i,G}$ 和变异个体 $\mathbf{V}_{i,G}$ 进行重组,产生新的个体,生成实验个体 $\mathbf{U}_{i,G+1} = \{u_{i,G+1}^1, \dots, u_{i,G+1}^D\}$ 。交叉操作作为

$$\mathbf{U}_{i,G+1} = \begin{cases} \mathbf{V}_{i,G}^j, & [\text{rand}(j) \leq C_R] \text{ or } [j = n(j)] \\ \mathbf{X}_{i,G}^j, & [\text{rand}(j) > C_R] \text{ and } [j \neq n(j)] \end{cases}, \quad (17)$$

式中: $\text{rand}(j)$ 是在 $[0, 1]$ 上服从均匀分布的随机数; C_R 为交叉因子,用来控制交叉比例,且 $C_R \in [0, 1]$; $n(j)$ 是 $[0, D]$ 上的随机整数。

3) 选择操作:采用贪婪的搜索策略选择进入下一代的个体,适应度值越大越优先,选择操作作为

$$\mathbf{X}_{i,G+1} = \begin{cases} \mathbf{X}_{i,G}, & \text{fitness}(\mathbf{U}_{i,G}) \leq \text{fitness}(\mathbf{X}_{i,G}) \\ \mathbf{U}_{i,G}, & \text{fitness}(\mathbf{U}_{i,G}) > \text{fitness}(\mathbf{X}_{i,G}) \end{cases}, \quad (18)$$

式中: $\text{fitness}(\cdot)$ 函数为求向量的适应度值。

针对深度神经网络的连接权值和偏置建立参数种群,通过 DE 算法来实现 DNN 训练时的参数更新,经过不断地迭代训练,形成一个新的学习模型(DE-DNN),此模型的训练流程如图 4 所示,具体步骤如下。

1) 初始化参数设置。DNN 的初始化包括网络层数、每层神经元个数、激活函数、最大迭代次数和

训练阈值。DE 算法的初始化包括种群规模 N_P 、向量维数 D 、缩放因子 F 及交叉因子 C_R 。

2) 初始化设置 DNN 开始训练时的连接权重和偏置。

3) 初始化参数种群中个体的适应度值。本方案采用参数种群训练过程中产生的均方误差的平均值作为适应度值。

4) 根据(16)~(18)式对参数种群个体进行 DE 算法中的变异、交叉和选择操作。

5) 计算新生个体的适应度值,保留最优个体。

6) 判断是否到达终止条件,如果满足,进行步骤 7); 否则返回步骤 4) 继续进行 DE 操作。

7) 结合参数种群的最优个体,通过判断 DNN 学习误差进行参数更新,完成 DNN 训练过程。

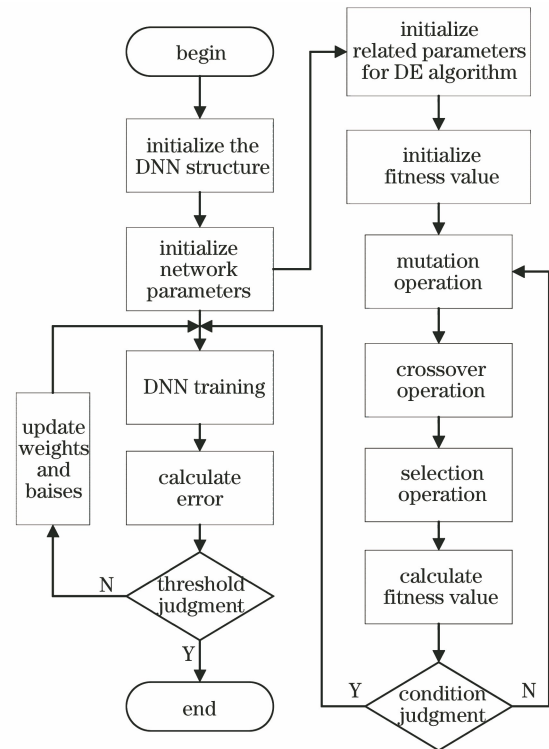


图 4 DE-DNN 训练过程流程

Fig. 4 Training phase flow chart of DE-DNN

4 分析与讨论

针对大气湍流环境中的紫外光单次散射信道场景,首先对所使用的湍流信道模型进行数值模拟,分析其非直视链路上的传输损耗和光强分布特性。然后在此信道环境中利用所提基于深度学习的信道估计方法进行仿真分析,分析其可行性及有效性。

4.1 非直视紫外光单次散射湍流信道模型分析

所采用的非直视紫外光通信系统的基本参数如

表 1 所示,通过改变几何角度、通信距离和湍流强度等参数来分析信道传输衰减及光信号强度分布的变化特性。

表 1 无线紫外光 NLOS 通信系统参数
Table 1 Parameters of wireless NLOS UV communication system

Parameter	Value
Wavelength λ /nm	254
Scattering coefficient k_s /km ⁻¹	0.74
Extinction coefficient k_e /km ⁻¹	0.49
Area of receiving aperture A_r /cm ²	1.77
Pulse power emitted P_t /mW	50
Communication rate /(Mbit · s ⁻¹)	1
Beam divergence angle θ_T / (°)	15
Receiving field of view θ_R / (°)	30

图 5 展示了不同通信距离、收发仰角及湍流强度下接收光信号强度的概率密度函数(PDF)分布。

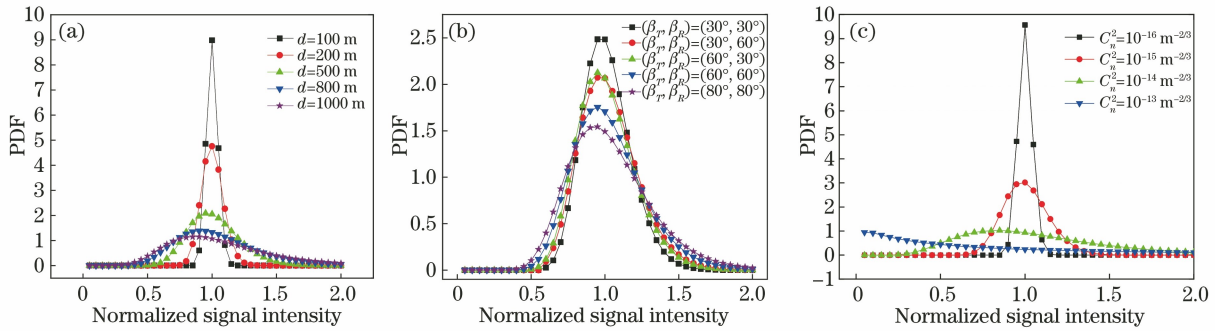


图 5 不同参数下的接收光信号强度概率密度分布曲线。(a)通信距离;(b)收发仰角;(c)湍流强度

Fig. 5 PDF curves of received optical signal intensity under different parameters. (a) Communication distance; (b) elevation angle of transceiver; (c) turbulence intensity

传输衰减作为紫外光信道的重要特性,可以为后续深度学习模型提供关键的预测依据和学习特征。综合考虑散射效应引起的路径损耗和湍流效应引起的光束闪烁衰减,通过改变信道几何形状来分析系统总的传输衰减。图 6 展示了信道非直视链路

图 5(a)中设置收发仰角均为 60° 且湍流强度 $C_n^2 = 10^{-16} \text{ m}^{-2/3}$,可以看出,随着通信距离 d 的增加,接收光信号强度的概率密度函数方差逐渐增大,信号能量衰减也随之增加。图 5(b)中固定通信距离和湍流强度,分别设为 $d = 200 \text{ m}$ 和 $C_n^2 = 10^{-16} \text{ m}^{-2/3}$,改变发射仰角 β_T 和接收仰角 β_R ,可知,随着收发仰角的增大,接收光信号强度的概率密度函数方差逐渐增大,同样引起了能量衰减的增加。图 5(c)中固定通信距离和收发仰角,分别设为 $d = 200 \text{ m}$ 和 $\beta_T = \beta_R = 60^\circ$,在不同的湍流强度下观察信号强度分布,可知,在较弱的湍流的环境下,接收光信号强度的概率密度函数方差和能量衰减都很小,随着 C_n^2 的增大,接收光信号强度的概率密度函数方差逐渐增大,当达到强湍流程度时,能量衰减非常大,几乎无法进行通信。

的传输衰减随收发仰角变化的三维曲线。这里固定通信距离和湍流强度,分别设置为 $d = 200 \text{ m}$ 和 $C_n^2 = 10^{-15} \text{ m}^{-2/3}$,由图 6 可知,随着收发仰角的增加,系统中发生的传输衰减也随之增大,且发射端仰角 β_T 对衰减的影响更大。




图 6 收发端仰角变化对系统传输衰减的影响

Fig. 6 Influence of elevation angle on transmission attenuation

图 7 中固定了收发端的几何结构,取收发仰角 $\beta_T = \beta_R = 30^\circ$ 。分析不同湍流强度下传输衰减随通信距离的变化情况。由图 7 可知:传输衰减总体上与通信距离呈正相关;当通信距离小于 100 m 时,大气湍流对传输衰减的影响较弱;当通信距离大于 100 m 时,随着湍流强度的不断增加,传输衰减逐渐增大,进而对紫外光通信系统性能造成不可忽视的影响。

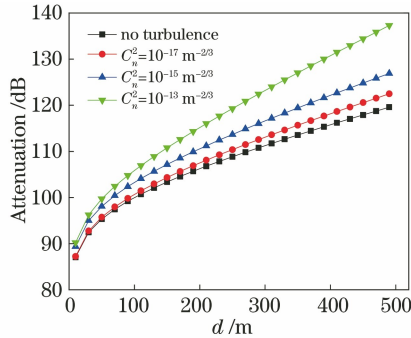


图 7 不同湍流强度下传输衰减随通信距离的变化曲线
Fig. 7 Variation curves of transmission attenuation with communication distance under different turbulence intensities

4.2 基于神经网络的信道估计方法仿真分析

对提出的 DNN 模型进行调参优化,分析差分优化算法应用在 DNN 模型上的收敛速度和全局最优性。此外,对比不同信道估计方案的性能,通过均方误差和误码率两方面说明所提方案的优越性。DNN 模型训练时的超参数预设值如表 2 所示。

表 2 DNN 训练阶段超参数预设值
Table 2 Hyperparameter preset values in DNN training phase

Parameter	Value
Learning-rate	0.001
Dropout	0.6
Maximum number of epochs	60
Data size	3000
Dataset split (train : test)	7:3
Number of hidden layers	3
Number of neurons per hidden layer	5

首先分析不同 DNN 结构下的算法性能,如图 8 所示,从隐含层层数(L)和神经元个数(n)两个角度出发,仿真出算法的均方误差性能。由图 8(a)可知:整体上随着迭代次数的增加,信道估计的均方误差先减小,然后趋于平缓;然而,随着隐含层层数的增加,均方误差先减小后增大,即估计性能先变好后变差,当 $L=5$ 时均方误差曲线最低,则取最优的估计性能。

考虑到网络模型训练算法的计算复杂度问题,这里设每层隐含层的神经元个数相同,并设为 n 。由图 8(b)可知:随着迭代次数的增加,均方误差整体上先减小然后趋于平缓;然而,随着 n 的增加,均方误差逐渐减小,即估计性能越来越好;需要注意的是,当 n 取 10,15,20 时,均方误差性能曲线几乎重合,估计性能近似相等。所以综合考虑估计性能和 DNN 的训练复杂程度,这里选取 $n=10$ 。

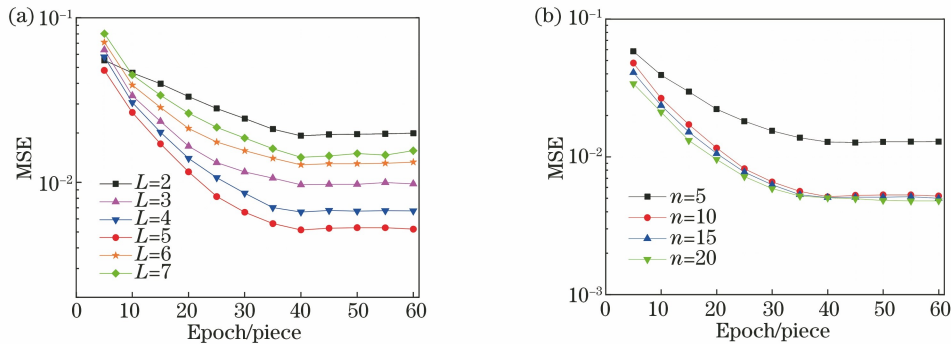


图 8 不同 DNN 模型结构下的均方误差曲线。(a)隐含层层数;(b)每层隐含层的神经元个数
Fig. 8 MSE curves under different DNN model structures. (a) Number of hidden layers;
(b) Number of neurons per hidden layer

为了分析差分进化算法对算法收敛速度和全局最优性的影响,对本方案所提的 DE-DNN 模型与使用反向传播算法优化的传统 DNN 模型进行对比,结果如图 9 所示。通过两组不同的 DNN 结构进行训练,可以明显看出,在相同条件下 DE-DNN 的收敛速度要快于 DNN,而且 DE-DNN 在整个训练过

程中具有更好的均方误差性能。

通过上述对于 DNN 模型的调参过程,取 $L=5$ 和 $n=10$ 。接下来对 DE-DNN 方案与其他信道估计方案进行对比,分析 DE-DNN 的估计性能。首先计算出不同算法估计出的信道响应系数,通过与真实值进行对比,可以直观地看出不同算法的信道估




图 9 两种优化算法下的收敛速度对比

Fig. 9 Comparison of the convergence speed of two optimization algorithms

计结果与真实值的差距,结果如图 10 所示。由图可知,DE-DNN 算法的估计结果要优于 LS 和 MMSE,而且相比 LS 提高不少,更加接近真实值。

以 MSE 和误码率(BER)为衡量标准,对不同方案下的信道估计性能进行对比分析,如图 11 所示。由图 11(a)可知:均方误差整体上随着信噪比(SNR)的增加逐渐减小,即估计性能越来越好;相比于LS估计,所提方案的均方误差性能显著

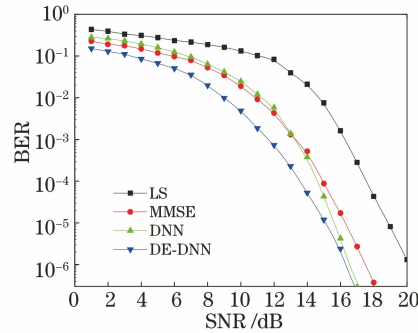



图 11 不同算法的信道估计性能对比曲线。(a)均方误差;(b)误码率

Fig. 11 Comparison curves of channel estimation performance of different algorithms. (a) MSE; (b) BER

最后为了验证所提方案在不同信道环境下的适用性,通过改变紫外光信道模型所处的湍流强度来分析 DE-DNN 的误码率性能,分别选择弱、中、强及无湍流 4 种情况,如图 12 所示。由图 12 可知:当信道处于中、弱及无湍流情况时,所提方案获得的误码率曲线几乎重合,即具有相似的估计性能;但是当处于强湍流时产生了较高的误码率,信道估计水平下降,将在下一步工作中重点优化此问题。因此,在未达到强湍流的条件下,所提方案对紫外光信道估计具有一定的稳定性。

5 结 论

基于湍流下的非直视紫外光单次散射信道模

提高。在 DNN 训练过程的反向传播中使用经典梯度下降法进行优化的 DNN 方案只能逼近 MMSE 的估计性能,而所提使用差分进化算法优化的 DE-DNN 模型可以获得比 MMSE 更好的均方误差性能。由图 11(b)可知,4 种方案下的误码率性能水平随着信噪比的增加逐渐减小,相比其他三种信道估计方案,DE-DNN 具有更好的误码率性能。

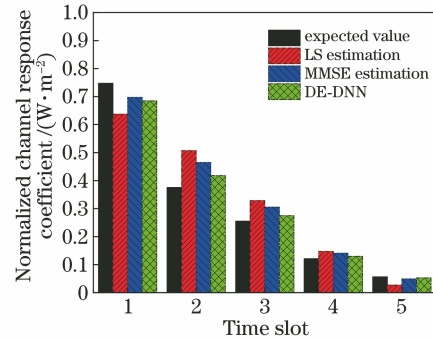


图 10 不同算法的信道响应系数估计结果

Fig. 10 Channel response coefficient estimation results of different algorithms

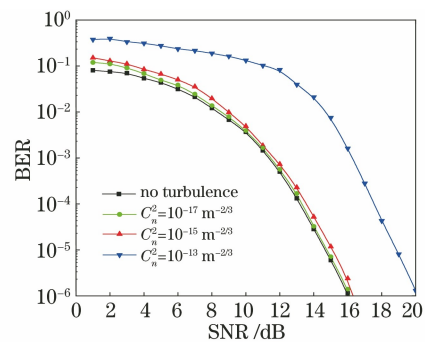


图 12 湍流强度对 DE-DNN 估计性能的影响

Fig. 12 Influence of turbulence intensity on the estimation performance of DE-DNN

型,利用深度神经网络实现了信号处理过程中的信道估计,通过差分进化算法的全局寻优能力准确快

速地估计出信道响应系数,可用于紫外光通信系统中后续的信号检测和信道均衡。仿真结果表明,所提方案的估计性能相较于传统的 LS 与 MMSE 估计方法有了明显的提升,适用于无线紫外光通信的信号处理过程,对提高紫外光通信系统性能具有重要的意义。经过差分进化算法优化的 DNN 模型具有更高的收敛速度和全局优化能力,在不同强度的湍流环境中可以稳定实现信道估计。未来的研究将考虑深度学习应用于紫外光多发多收(MIMO)情况下信道估计的可能性。

参 考 文 献

- [1] Xiao H F, Zuo Y, Wu J, et al. Non-line-of-sight ultraviolet single-scatter propagation model [J]. *Optics Express*, 2011, 19(18): 17864-17875.
- [2] Zhao T F, Zhang A L, Jin D, et al. Research on the inter-link interference model in wireless ultraviolet non-line-of-sight communication [J]. *Acta Optica Sinica*, 2013, 33(7): 0706023.
赵太飞, 张爱利, 金丹, 等. 无线紫外光非视距通信中链路间干扰模型研究 [J]. *光学学报*, 2013, 33(7): 0706023.
- [3] Song P, Liu C, Zhu L, et al. Analysis of single-scatter path loss in wireless ultraviolet communication in mobile scene [J]. *Acta Optica Sinica*, 2020, 40(4): 0406001.
宋鹏, 刘春, 朱磊, 等. 移动场景下无线紫外光通信单次散射路径损耗分析 [J]. *光学学报*, 2020, 40(4): 0406001.
- [4] Cao T, Song J, Pan C Y. Simplified closed-form single-scatter path loss model of non-line-of-sight ultraviolet communications in noncoplanar geometry [J]. *IEEE Journal of Quantum Electronics*, 2021, 57(2): 1-9.
- [5] Lin Y, Xu Z Y, Wang J Y, et al. Optimization of link analysis for non-line-of-sight atmospheric scattering communication in fog weather [J]. *Infrared and Laser Engineering*, 2015, 44(2): 705-710.
林勇, 徐智勇, 汪井源, 等. 雾环境下非视距散射光通信最佳链路分析 [J]. *红外与激光工程*, 2015, 44(2): 705-710.
- [6] Yuan R Z, Ma J S, Su P, et al. Monte-Carlo integration models for multiple scattering based optical wireless communication [J]. *IEEE Transactions on Communications*, 2020, 68(1): 334-348.
- [7] Zhao T F, Leng Y X, Yang L Y, et al. Characteristics of ultraviolet light scattering by soot cluster particles [J]. *Laser & Optoelectronics Progress*, 2019, 56(5): 050103.
赵太飞, 冷昱欣, 杨黎洋, 等. 紫外光在烟尘团簇粒子中的散射特性 [J]. *激光与光电子学进展*, 2019, 56(5): 050103.
- [8] Zuo Y, Wu J, Xiao H F, et al. Non-line-of-sight ultraviolet communication performance in atmospheric turbulence [J]. *China Communications*, 2013, 10(11): 52-57.
- [9] Shan T, Ma J S, Wu T F, et al. Single scattering turbulence model based on the division of effective scattering volume for ultraviolet communication [J]. *Chinese Optics Letters*, 2020, 18(12): 120602.
- [10] Sun J, Huang P M, Yao Z S. Diversity reception technology in coherent optical communication over gamma-gamma atmospheric turbulence channel [J]. *Acta Optica Sinica*, 2018, 38(7): 0706002.
孙晶, 黄普明, 幺周石. Gamma-Gamma 大气湍流下相干光通信分集接收技术研究 [J]. *光学学报*, 2018, 38(7): 0706002.
- [11] Chen Y N, Qi X M. An improved least squares channel estimation algorithm with low SNR [J]. *Journal of Huangshan University*, 2018, 20(5): 46-49.
陈远宁, 齐祥明. 低信噪比下一种改进的最小二乘信道估计算法 [J]. *黄山学院学报*, 2018, 20(5): 46-49.
- [12] Fang J, Li X J, Li H B, et al. Low-rank covariance-assisted downlink training and channel estimation for FDD massive MIMO systems [J]. *IEEE Transactions on Wireless Communications*, 2017, 16(3): 1935-1947.
- [13] Salari S, Chan F. Joint CFO and channel estimation in OFDM systems using sparse Bayesian learning [J]. *IEEE Communications Letters*, 2020, 25(1): 166-170.
- [14] Chen D, Hui J X. Parameter estimation of Gamma-Gamma fading channel in free space optical communication [J]. *Optics Communications*, 2021, 488: 126830.
- [15] Cao M H, Hu Q, Wang H Q, et al. Atmospheric optical communications channel estimation employing superimposed training sequence under sand-dust weather conditions [J]. *Infrared and Laser Engineering*, 2019, 48(S2): 115-122.
曹明华, 胡秋, 王惠琴, 等. 沙尘气象条件下基于隐训练序列的大气光通信信道估计 [J]. *红外与激光工程*, 2019, 48(S2): 115-122.
- [16] Wu Y, Mei H P, Wei H L. Performance analysis of free-space optical communication system under joint channel conditions [J]. *Laser & Optoelectronics Progress*, 2020, 57(5): 050101.

- 吴琰, 梅海平, 魏合理. 联合信道条件下自由空间光通信系统性能分析[J]. 激光与光电子学进展, 2020, 57(5): 050101.
- [17] Gong C, Xu Z Y. Channel estimation and signal detection for optical wireless scattering communication with inter-symbol interference [J]. IEEE Transactions on Wireless Communications, 2015, 14(10): 5326-5337.
- [18] Zhao T F, Liu L F, Liu L, et al. Differential evolution particle filtering channel estimation for non-line-of-sight wireless ultraviolet communication [J]. Optics Communications, 2019, 451: 80-85.
- [19] Wei Z K, Hu W X, Han D H, et al. Simultaneous channel estimation and signal detection in wireless ultraviolet communications combating inter-symbol-interference[J]. Optics Express, 2018, 26(3): 3260-3270.
- [20] Liao Y, Hua Y X, Yao H M, et al. Channel estimation method based on deep learning in high-speed mobile environments [J]. Acta Electronica Sinica, 2019, 47(8): 1701-1707.
廖勇, 花远肖, 姚海梅, 等. 高速移动环境下基于深度学习的信道估计方法 [J]. 电子学报, 2019, 47(8): 1701-1707.
- [21] Soltani M, Pourahmadi V, Mirzaei A, et al. Deep learning-based channel estimation [J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [22] Yang Y W, Gao F F, Ma X L, et al. Deep learning-based channel estimation for doubly selective fading channels[J]. IEEE Access, 2019, 7: 36579-36589.
- [23] Hu T Y, Huang Y, Zhu Q M, et al. Channel estimation enhancement with generative adversarial networks [J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 145-156.
- [24] Chen X W, Zhu W Y, Qian X M, et al. Estimation of surface layer optical turbulence using artificial neural network [J]. Acta Optica Sinica, 2020, 40(24): 2401002.
- 陈小威, 朱文越, 钱仙妹, 等. 基于人工神经网络的近地面光学湍流估算[J]. 光学学报, 2020, 40(24): 2401002.
- [25] Xu Q W, Wang P P, Zeng Z J, et al. Extracting atmospheric turbulence phase using deep convolutional neural network [J]. Acta Physica Sinica, 2020, 69(1): 014209.
徐启伟, 王佩佩, 曾镇佳, 等. 基于深度卷积神经网络的大气湍流相位提取 [J]. 物理学报, 2020, 69(1): 014209.
- [26] Sun H R, Chen X Y, Shi Q J, et al. Learning to optimize: training deep neural networks for interference management[J]. IEEE Transactions on Signal Processing, 2018, 66(20): 5438-5453.
- [27] Balevi E, Doshi A, Andrews J G. Massive MIMO channel estimation with an untrained deep neural network [J]. IEEE Transactions on Wireless Communications, 2020, 19(3): 2079-2090.
- [28] Wang P, Xu Z Y. Characteristics of ultraviolet scattering and turbulent channels[J]. Optics Letters, 2013, 38(15): 2773-2775.
- [29] Xu Z Y, Ding H P, Sadler B M, et al. Analytical performance study of solar blind non-line-of-sight ultraviolet short-range communication links [J]. Optics Letters, 2008, 33(16): 1860-1862.
- [30] Xiao H F, Zuo Y, Wu J, et al. Non-line-of-sight ultraviolet single-scatter propagation model in random turbulent medium [J]. Optics Letters, 2013, 38(17): 3366-3369.
- [31] Ding H P, Chen G, Majumdar A K, et al. Turbulence modeling for non-line-of-sight ultraviolet scattering channels[J]. Proceedings of SPIE, 2011, 8038: 80380J.
- [32] Gao S C, Yu Y, Wang Y R, et al. Chaotic local search-based differential evolution algorithms for optimization [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(6): 3954-3967.