

文章编号: 2095-4980(2025)04-0410-06

一种基于改进 ANN 的光纤通信网络链路均衡方法

宇文骊敏

(国网冀北廊坊供电公司, 河北 廊坊 065000)

摘 要: 针对目前强度调制和直接检测(IMDD)短距离光纤通信系统补偿非线性失真时存在较高的实现复杂度的问题, 提出一种基于自适应人工神经网络(ANN)均衡器。结合光通信网络特点, 确定 ANN 中输入层、隐藏层节点和训练样本的数量; 考虑到光纤系统的噪声以及由于色散引起的失真, 对训练样本进行扩展, 从而提高 ANN 均衡器泛化能力; 自适应调整 ANN 均衡器权重, 并利用权重值的小变化跟踪信道波动, 缓解光纤通道的参数因环境条件的变化发生波动导致权重偏移的问题。试验结果表明, 与 ANN 相比, 所提自适应 ANN 的综合增益、计算复杂性和内存需求具备优势。该模型对噪声环境的光纤通信具备较强的鲁棒性, 具有一定实用价值。

关键词: 光纤通信; 非线性失真; 人工神经网络; 训练样本; 自适应

中图分类号: TP393

文献标志码: A

DOI: 10.11805/TKYDA2023271

A link equalization method for fiber optic communication networks based on improved ANN

YUWEN Limin

(State Grid Jibei Langfang Electric Power Supply Co., Ltd., Langfang Hebei 065000, China)

Abstract: To address the issue of high implementation complexity in compensating for nonlinear distortion in short-range optical fiber communication systems using Intensity Modulation and Direct Detection(IMDD), a method based on an Adaptive Artificial Neural Network(ANN) equalizer is proposed. By considering the characteristics of optical communication networks, the number of nodes in the input layer and hidden layer of the ANN, as well as the number of training samples, are determined. Taking into account the noise in the optical fiber system and the distortion caused by dispersion, the training samples are expanded to enhance the generalization capability of the ANN equalizer. The weights of the ANN equalizer are adaptively adjusted, and small changes in the weight values are utilized to track channel fluctuations, thereby alleviating the problem of weight offset caused by variations in the fiber channel parameters due to changes in environmental conditions. Experimental results show that compared to a non-adaptive ANN, the proposed adaptive ANN has advantages in terms of overall gain, computational complexity, and memory requirements. The model demonstrates strong robustness in optical fiber communication under noisy conditions and has practical value.

Keywords: fiber optic communication; nonlinear distortion; Artificial Neural Network(ANN); training samples; self-adaption

光纤^[1-2]现已广泛部署于现代电信系统和网络中, 如地铁和媒体接入网络、数据中心网络、云无线电接入网络、无源光网络和移动前传网络等短距离光纤通信应用。在短距离应用中, 强度调制和直接检测(IMDD)^[3-5]因其成本低、实现简单和鲁棒性强被广泛使用, 但由于 IMDD 系统的平方律检测, 由光纤不可避免的色散现象引起的线性光学失真转变为电域中的非线性损伤, 传统的线性电均衡器(如前馈均衡器(Feed-Forward Equalizer, FFE)和判决反馈均衡器(Decision Feedback Equalizer, DFE)无法减轻接收器端的非线性信号失真。因此, 有必要在接收机侧采用非线性均衡器完美补偿非线性失真。

目前, 许多学者提出了多种均衡技术用于缓解 IMDD 光纤通信系统的光纤失真。如, 文献[6]提出一种基于

查找表的极大似然序列估计(Maximum Likelihood Sequence Estimator, MLSE)用于提供光纤基准补偿,但 MLSE 的计算成本较高,且需大量的计算资源。部分学者将非线性均衡技术,如基于单层人工神经网络^[7]、双层人工神经网络^[8]、径向基函数神经网络^[9]、卷积神经网络^[10]等神经网络均衡器引入光纤失真补偿,可有效降低计算成本。神经网络的拟合性能随着网络层数的加深而加强,但随之带来计算资源的不断提高。因此,需合理搭建神经网络,在满足拟合精确度的要求下尽量减少计算资源。此外,光纤失真数据样本通常较少,需合理增强数据样本,提高模型的泛化能力和鲁棒性,增强噪声情况下模型拟合性能。

为减轻 IMDD 短距离光纤通信系统中引起的非线性失真,本文提出一种自适应 ANN 均衡器,可最大限度地减少接收机端信号恢复所需的计算开销和复杂性。通过数据扩展,所提出的自适应 ANN 均衡器能够在较优的补偿性能下降低计算成本。

1 基于自适应 ANN 的均衡器

短距离光纤通信中引起的线性光学失真可转换为电域中的非线性损伤,主要是因为直接检测器(Direct Detector, DD)的平方律检测丢失了相位信息。因此,在数字信号处理(Digital Signal Processing, DSP)单元处需要非线性电均衡器补偿非线性失真,从而恢复传输数据。目前神经网络因其强大的拟合能力已广泛用于图像、信号处理、生物医学、化学工程等领域,由于 ANN 优越的线性和非线性建模能力,在适当的训练之后,ANN 可用来补偿光纤通信中非线性系统失真,从而校正光纤通道和直接光检测系统的响应。




Fig.1 Schematic diagram of ANN's nonlinear equalizer
图1 ANN的非线性均衡器示意图

所提自适应 ANN 的非线性均衡器示意图如图 1 所示,包含输入层、单个隐藏层和输出层。输入层包括 $N(N=2k+1)$, 为码间串扰(Intersymbol Interference, ISI)跨度的长度)个节点,每个节点由接收(失真)信号 $y[N]$ 的采样触发。即每个时刻 i 的输入向量表示为当前输入样本及其 $k/2$ 个先前样本和 $k/2$ 个后续样本。连接 2 个节点的每一行表示一个乘法器,该乘法器将前一层的输出乘以相应的权重。隐藏层和输出层分别包括 m 个节点和 1 个节点,每个节点都是一个计算单元,将非线性激活函数用于加权输入的总和。最终,输入向量 $\mathbf{Y} = [y_{-k}, y_{-k+1}, \dots, y_k]$ 和 ANN 输出 $\hat{\mathbf{X}}$ 之间的关系为:

$$\hat{\mathbf{X}} = f_o \left(\sum_{j=1}^m w_j^o f_h \left(\sum_{l=1}^N w_{jl}^h y_l \right) \right) \quad (1)$$

式中: w_{jl}^h 为分配给隐藏层的第 l 个输入 y_l 和第 j 个节点之间的权重; w_j^o 为分配给第 j 个隐藏层节点和输出层节点之间的权重; $f_h(\cdot)$ 和 $f_o(\cdot)$ 分别为隐藏层和输出层的非线性激活函数。

对 ANN 均衡器的训练过程如下: 已知数据流首先通过光纤通道传输到接收器,形成一组已知的输入-输出训练数据对;然后,调整 ANN 均衡器的权重,最小化均衡器输出(均衡信号样本)和期望输出(传输信号样本)之间的均方误差(Mean Square Error, MSE)。训练过程可描述为:

$$\min_{\mathbf{W}} E(\mathbf{W}) = \frac{1}{N_{tr}} \sum_{k=1}^{N_{tr}} \left\| \hat{\mathbf{X}}_k(\mathbf{W}, \mathbf{Y}_k) - \mathbf{X}_k \right\|_2^2 \quad (2)$$

式中: $\mathbf{W} = [\mathbf{W}_h^T \mathbf{W}_o^T]$ 为包含将输入参数连接到隐藏层节点的权重集合($\mathbf{W}_h^T$)和将隐藏层节点连接到输出层节点的权

重集合($\mathbf{W}_0^T$)的向量; $\|\cdot\|_2$ 为欧几里得范数; N_{tr} 为训练样本的数量; $\mathbf{Y}_k$ 为对应于第 k 个训练样本的输入均衡器向量; $\hat{X}_k$ 和 X_k 分别为第 k 个训练样本的均衡器输出和相应的期望输出参数。

为实现最有效的 ANN 均衡性能, 需确定输入层、隐藏层节点以及训练样本的数量。结合光通信网络特点, 将输入层等效于均衡器抽头的数量 N , 该值可由信道的 ISI 的长度确定。即根据调制格式、光纤长度 L 和光纤信道的色散参数 β_2 , 估计可能干扰当前样本的相邻样本 k 的数量(即 ISI 的跨度)。基于以上分析, 本文设置均衡器所需抽头的数量为 $N=2k+1$ 。

隐藏层节点数量可通过收敛性分析获得。首先, 将隐藏节点数 m 设置为某个较小的数, 并基于式(2)开始训练 ANN, 计算终止的 MSE; 然后, 逐渐增加 m 的值, 并继续根据式(2)获取 MSE, 直到终止的 MSE 值达到一定的精确度, 此时的 m 值即为隐藏层节点的数量。

对训练样本的数量 N_{tr} 进行扩展。对于 M 个调制数据和 N 个 ISI 跨度长度, 训练数据样本存在 MN 个不同模式的总组合, 即样本集可扩展为 $N \times M^N$ 个不同的输入训练向量和相应的期望输出 $1 \times M^N$ 。考虑到所有可能接收到的可能性组合, 本文提出一种样本扩展模式, 即在每个基本样本的两侧添加 k 个冗余保护样本。样本扩展模式示意图如图 2(a)所示, 首先, 生成 M^{N+2k} 个不同的样本, 并通过光纤进行传输。在 DSP 单元中, 将冗余保护样本丢弃, 并仅使用与原始数据有关的样本训练均衡器。因此, 扩展后使用的训练数据的数量为 $N_{tr} = M^{N+2k}$ 。此外, 为提高 ANN 均衡器对于噪声的鲁棒性, 在扩展后样本中添加多个噪声集。添加噪声集样本示意图如图 2(b)所示, 首先, 生成 M^{N+2k} 个不同的样本; 其次, 将样本数据流通过光纤系统传输, 并在光纤系统增加噪声以及由色散引起的失真; 之后, 离散化接收信号样本并通过 DSP 单元丢弃与冗余保护数据相对应的样本, 并使用与原始训练集及其传输对应的信号样本制定输入-输出训练对。考虑信道噪声, 将 M^{N+2k} 个模式组成的相同数据流通过光纤系统重新发送 n 次; 然后在 DSP 单元上重复相同的程序, 形成共 n 组不同的输入-输出训练对, 每个训练对由输入训练向量 $N \times M^{N+2k}$ 和相应的期望输出 $1 \times M^{N+2k}$ 组成; 最终, 融合噪声数据后, 训练集中数据的总数为 $N_{tr} = n \times M^{N+2k}$ 。

需注意, 在实际数据传输过程中, 光纤通道的参数(如色散系数 β_2)可能会因环境条件的变化而发生波动。尽管这些波动比传输数据速率慢得多, 但仍可能会略微恶化 ANN 均衡器的性能。为此, 对传统 ANN 均衡器进行自适应处理, 重新调整其权重, 并使用权重值的小变化跟踪这些信道波动。通过单步梯度优化, 最小化期望信号 $\hat{a}_i$ 和均衡器输出 $\hat{X}_i$ 之间的均方误差(MSE)损失函数。因此, 自适应条件下, 式(2)的目标函数变为:

$$E(\mathbf{W}) = [\hat{X}_i(\mathbf{W}, \mathbf{Y}_i) - \hat{a}_i]^2 \quad (3)$$

确定了输入-输出训练数据对后, 可基于优化算法训练 ANN 获得最优权重。本文基于 Adam 算法训练 ANN。Adam 算法是基于随机梯度的优化算法之一, 已广泛用于解决神经网络和深度神经网络的训练问题。Adam 对于解决具有大量数据和参数的优化问题性能较优, 且对内存的需求很小。

基于自适应 ANN 均衡器的训练算法流程图如图 3 所示。首先, 初始化参数(随机 ANN 权重值、ANN 的隐含层数量、训练样本数、




Fig.2 Sample expansion

图2 样本扩展




Fig.3 Training algorithm flowchart based on adaptive ANN equalizer

图3 基于自适应 ANN 均衡器的训练算法流程图

最小MSE阈值、最大迭代次数等);其次,利用样本扩展方法生成ANN训练输入-输出数据集;然后,计算当前均衡器输出和期望输出之间的相应MSE,调整ANN权重,判断是否满足预定义的停止阈值(如是否满足最大迭代次数或最小MSE阈值)。如果满足,则算法终止,并保存最佳的ANN模型权重;否则,采用Adam优化算法更新当前ANN权重,使当前MSE不断减小,重复上述过程,直至输出最优ANN权重。

完成ANN均衡器的训练后可通过信道发送实际的未知数据,并在接收机的DSP单元处利用训练后的ANN均衡器补偿系统失真,从而恢复发送的数据。此时,ANN均衡器在时刻 i 的输入矢量为:

$$\mathbf{Y}_i = [y_{-K_r+i}, y_{-K_r+i+1}, \dots, y_{K_r+i-1}, y_{K_r+i}]^T, \quad i = K_r, K_r+1, K_r+2, \dots, \quad (4)$$

式中: y_i 为在时刻 i 接收到的采样信号; K_r 为干扰信号的数量。对于每个输入向量 $\mathbf{Y}_i$, ANN均衡器产生一个均衡信号样本 $\hat{X}_i$, 该样本被定义为实际传输信号样本 X_i 的可靠估计。

2 试验与分析

2.1 试验设置

为验证所提基于自适应ANN均衡方法的有效性,建立一种光纤通信系统,其框架示意如图4所示。在发射机侧,随机生成独立且相同分布的输入信号 a_i 。首先,将数据映射为通断键控调制格式的具有不归零编码的升余弦脉冲整形,其滚降因子为0.6。电调制激光器(Electrically Modulated Laser, EML)将电信号转换到光域,获得输出的透射光信号 $x(t)$ 。光传输信道为标准线性单模光纤(Single-Mode Fiber, SMF),其色散系数 β_2 为 $-21 \text{ ps}^2/\text{km}$, 损耗系数 α 为 0.2 dB/km 。SMF之后接一个完全补偿光纤损耗的掺铒光纤放大器(Erbium Doped-Fiber Amplifier, EDFA), EDFA的输出分别在10 Gbaud或28 Gbaud系统下通过带宽为50 GHz或100 GHz的光学高斯带通滤波器(Band-Pass Filter, BPF)。由于光纤通信系统设计不是本文研究的重点,数据在其中传输的底层表征详见文献[11]。




Fig.4 Schematic diagram of fiber optic communication system framework

图4 光纤通信系统框架示意图

在接收器处, DD接收器首先用于光电转换,其输出与失真的光接收信号 $r(t)$ 的幅度的平方成正比关系。由于DD采用平方律检测,光域中色散的线性失真被转换为电域中的非线性失真,即接收到的光信号的相位信息在电域中丢失。在DD之后放置高斯低通滤波器减少噪声,需注意,DD添加的高斯白噪声 $n(t)$ 由散粒噪声和热噪声组成。在DSP单元,使用模数转换器(Analog-to-Digital Converter, ADC)将采样率从每个信号16个样本降低到每个信号2个样本;然后采用所提出的自适应ANN均衡器补偿非线性电信号失真;最后,决策电路放置在DSP单元的末端,将均衡数据 $\hat{X}_i$ 分类到其最近的信号 $\hat{a}_i = \{0, 1\}$ 。

2.2 对比指标和参数设置

在存在噪声的通信系统中,通过误码率(Bit Error Rate, BER)、均衡器的计算成本和存储需求3个指标验证所提自适应ANN的性能。其中,均衡器所需的每个信号的计算成本与ANN的计算复杂度正相关。根据自适应ANN均衡器的输入-输出关系(式(1)),可以看出ANN的计算复杂度按 $m \times N$ 的比例缩放。均衡器的存储要求通常由网络权重参数的数量决定,对于包括 N 个输入和具有 m 个节点的单个隐藏层的ANN均衡器,权重的总数为 $mN + n$, 其中 mN 为连接输入层和隐藏层之间的权重数量, n 为连接隐藏层和输出层之间权重的数量。考虑到ANN均衡器的权重通常为实数,因此所提出的自适应ANN均衡器的内存存储要求为 $m(N+1)$ 个浮点数。

以图4所示的光纤通信系统模拟地铁和媒体接入网络领域的典型通信场景。在波特率为10 Gbaud的IMDD短

距离光纤通信系统中，对器件非线性及色散引起的失真进行补偿。模拟光纤通信场景中的光纤长度 L 为 140 km。由于色散和 DD 的平方律效应导致的脉冲增宽，在没有均衡和噪声的情况下，接收机的 BER 为 4×10^{-2} 。试验过程中参数设置如下：融合噪声后，训练数据的总数为 $10 \times M^{N+2k}$ ，其中 85% 的数据用于训练，15% 的数据用于验证；神经网络的隐藏激活函数和输出激活函数均为校正线性单元 (Rectified Linear Unit, ReLU) 函数；均衡器输入层和隐藏层节点的数量分别设置为 7 和 6。

2.3 结果与分析

将所提基于样本扩展方法与传统合成少数类过采样技术 (Synthetic Minority Over-sampling Technique, SMOTE) 方法进行对比。对比指标选取平均精确度。样本扩展方法对比结果如表 1 所示。可以看出，与 SMOTE 方法相比，所提样本扩展方法平均精确度提升约 13.24%。这是因为传统 SMOTE 方法通过复制样本提升样本多样性，导致部分数据过多造成过拟合，因此平均精确度反而下降；与之相反，所提样本扩展方法通过添加噪声集，提升了样本的多样性与均衡器泛化能力。

光纤长度为 140 km 时，不同机制下 BER 性能如图 5 所示。可以看出，无均衡器下性能最差。与背靠背 (Back-to-Back, B2B) 传输相比，所提自适应 ANN 在 -0.7 dBm 的接收光功率下 BER 为 10^{-3} ，功率损失约为 0.9 dB；为使 BER 达到 10^{-9} ，自适应 ANN 所需的接收光功率为 3.3 dBm，功率损失较小，约为 0.3 dB。传统 ANN，在 1.3 dBm 的接收光功率下 BER 为 10^{-3} ，相较于 B2B 传输，功率损失高达 2.9 dB；当 BER 为 10^{-9} 时，传统 ANN 需 4.4 dBm 的接收光功率，功率损失约为 1.4 dB。得益于自适应和数据扩展方案，所提自适应 ANN 在误码率分别为 10^{-3} 和 10^{-9} 时，功率损失较传统 ANN 减小了 2 dB 和 1.1 dB。综合以上分析，所提自适应 ANN 具有较优性能。

为进一步证明所提自适应 ANN 均衡器的性能，在 BER 为 10^{-3} 时，对比 3 种常见的均衡方案：前馈均衡器 (FFE)、判决反馈均衡器 (DFE) 和最大似然序列估计器 (MLSE) 的接收光功率与光纤传输距离的关系，如图 6 所示。从图 6 中可以看出，如果不使用均衡，可行的传输距离被限制在 120 km 以内；FFE 和 DFE 的传输距离分别限制在 140 km 和 180 km，表明线性均衡器无法补偿较长传输距离下的非线性失真。所提自适应 ANN、ANN 和 MLSE 可显著扩展传输距离，基本达到 220 km。与非线性均衡器 ANN 和 MLSE 相比，所提自适应 ANN 显示出优越的 BER 性能。

表 1 样本扩展方法对比结果

Table1 Comparison results of sample expansion methods

model	average precision/%
SMOTE	74.34
sample expansion method	87.58




Fig.5 BER performance under different mechanisms at 140 km
图 5 140 km 时不同机制下 BER 性能




Fig.6 Relationship between received optical power and fiber transmission distance under different equalization schemes
图 6 不同均衡方案下接收光功率与光纤传输距离的关系

表 2 不同均衡器的计算开销成本和内存使用统计情况

Table2 Calculation cost and memory usage statistics of different equalizers

equalizer	calculate the cost of expenses in bits/characters	memory usage/bit
FFE $\{N\}$	N	N
DFE $\{N_1, N_2\}$	$N_1 + N_2$	$N_1 + N_2$
adaptive ANN $\{N, m\}$	mN	$M(N+1)$
MLSE $\{N\}$	2^N	2^N

不同均衡器的计算开销成本和内存使用情况如表 2 所示。可以看出，FFE 和 DFE 的计算开销成本和存储器需求最小，但根据图 6 分析，FFE 和 DFE 补偿性能效益较差。主要是因为这些均衡器抵抗非线性系统失真的能力有限。MLSE 在均衡过程中占用内存最高，主要是 MLSE 需要在存储中查找表的所有条目，与接收到的失真序列进

行比较,并确定最可能的传输序列。所提自适应 ANN 计算开销成本和内存介于线性均衡器(FFE、DFE)和 MLSE 之间,但根据图 6 分析,MLSE 的功率效益低于所提自适应 ANN 均衡器。综合以上分析,从增益、计算复杂性和内存需求的角度看,所提自适应 ANN 均衡器具备最优性能。

3 结论

本文对光纤通信中非线性失真问题进行研究,提出了基于自适应 ANN 的光纤通信网络链路均衡方法。首先,采用 ANN 补偿光纤通信中非线性系统失真,从而反转光纤通道和直接光检测系统的响应;其次,提出了一种样本扩展方案,并引入噪声数据提升模型鲁棒性;最后,考虑到环境或干扰可能会影响 ANN 训练性能,提出一种自适应权重调节方案,提升模型适应性。通过试验仿真,验证了所提自适应 ANN 模型对噪声环境的光纤通信具备较强的鲁棒性。未来可对所提模型工程化应用进行研究,提升所提模型在电网的实际应用效果。

参考文献:

- [1] 彭博文. 现代光纤通信技术的特点及应用[J]. 数字通信世界, 2023(4):104–106. (PENG Bowen. Characteristics and application of modern optical fiber communication technology[J]. Digital Communication World, 2023(4):104–106.) DOI:10.3969/J.ISSN.1672–7274.2023.04.034.
- [2] KHONINA S N,KAZANSKIY N L,BUTT M A,et al. Optical multiplexing techniques and their marriage for on-chip and optical fiber communication:a review[J]. Opto–Electronic Advances, 2022,5(8):210127.
- [3] 宋新宇. 基于动态可调谐 DPLL 的 IM/DD OOFDM 系统相位补偿研究与实现[D]. 北京:北京邮电大学, 2021. (SONG Xinyu. Research and implementation of phase compensation for IM/DD OOFDM systems based on dynamic tunable DPLL[D]. Beijing: Beijing University of Posts and Telecommunications, 2021.) DOI:10.26969/d.cnki.gbydu.2021.002259.
- [4] 安韶华. 高速直接检测光纤传输系统中的数字信号处理技术研究[D]. 上海:上海交通大学, 2021. (AN Shaohua. Research on digital signal processing technology in high speed direct detection fiber optic transmission systems[D]. Shanghai, China: Shanghai Jiao Tong University, 2021.)
- [5] ZHOU Ji,LI Liangchuan,HE Jiale,et al. Clipping discrete multi-tone for peak-power-constraint IM/DD optical systems[J]. Science China Information Sciences, 2023,66(5):152302. DOI:10.1007/s11432–022–3555–y.
- [6] CHEN Zhuo,DAI Xiaoxiao,NIE Junyuan,et al. Complexity curtailed MLSE equalizer based on a compact look-up-table for C-band DSB IM/DD transmission[J]. Optics Letters, 2022,47(21):5606–5609. DOI:10.1364/OL.475764.
- [7] 蔡启明,张磊,许宸豪. 基于单层神经网络的流程相似性的研究[J]. 计算机工程与应用, 2022,58(7):295–302. (CAI Qiming, ZHANG Lei,XU Chenhao. Research of process similarity based on single-layer neural network[J]. Computer Engineering and Applications, 2022,58(7):295–302.) DOI:10.3778/j.issn.1002–8331.2010–0073.
- [8] 杨延勇,孟祥剑,高峰,等. 一种基于双层人工神经网络的多时间尺度区域光伏功率预测方法[J]. 华北电力大学学报(自然科学版), 2021,48(2):55–63. (YANG Yanyong,MENG Xiangjian,GAO Feng,et al. A multi-time scale regional PV power forecasting method based on double-layer artificial neural network[J]. Journal of North China Electric Power University, 2021,48(2):55–63.) DOI:10.3969/j.issn.1007–2691.2021.02.07.
- [9] 刘轲,张冉,崔志斌,等. 云模型优化径向基函数神经网络算法研究[J]. 河南科技大学学报(自然科学版), 2023,44(5):49–55. (LIU Ke,ZHANG Ran,CUI Zhibin,et al. Research on cloud model optimization radial basis function neural network algorithm[J]. Journal of Henan University of Science & Technology(Natural Science), 2023,44(5):49–55.) DOI:10.15926/j.cnki.issn1672–6871.2023.05.007.
- [10] KALLA S C K,GAGNÉ C,ZENG M,et al. Recurrent neural networks achieving MLSE performance for optical channel equalization[J]. Optics Express, 2021,29(9):13033–13047. DOI:10.1364/OE.423103.
- [11] 邵婉婷. 光纤通信系统中色散补偿光子晶体光纤的研究[D]. 南京:南京邮电大学, 2023. (SHAO Wanting. Research on dispersion compensation photonic crystal fibers in fiber optic communication systems[D]. Nanjing,China:Nanjing University of Posts and Telecommunications, 2023.) DOI:10.27251/d.cnki.gnjdc.2023.000379.

作者简介:

宇文骊敏(1985–),男,硕士,高级工程师,主要研究方向为光纤通信、电力通信 .emial:Yixiucongming@163.com.