

文章编号: 1002-1582(2025)04-0400-08

长距离光纤通信系统的非线性损伤补偿方法

袁瑛^{1*}, 沈袁勋², 沈平³

(1. 湖北职业技术学院 信息工程学院, 湖北 孝感 432000)

(2. 东北大学 计算机与通信工程学院, 河北 秦皇岛 066004)

(3. 湖北职业技术学院 教务处, 湖北 孝感 432000)

摘 要: 随着传输速率与传输距离的增加, 非线性损伤对长距离光纤通信系统性能的影响愈发显著, 严重制约了系统性能。为了缓解长距离光纤通信中非线性损伤的综合效应, 提出一种基于双分支混合神经网络的长距离光通信非线性损伤补偿方法。该模型利用信道记忆从时域捕捉信道损伤的全局特征, 利用历史信息优化当前符号的特征学习; 通过基于卷积神经网络的实数分支捕获星座图中符号的空间特征, 并采用通道注意力机制和空间注意力机制增强模型对非线性损伤相关空间特征的学习能力; 通过复数分支捕获复数符号相位与幅度变化的隐含信息, 从而有效补偿非线性损伤的综合效应。以自相位调制和交叉相位调制为主要非线性效应建立了数值仿真模型, 仿真结果表明, 在不同发射光功率、传输距离和符号率条件下, 所提方法均能实现较低的误码率, 并表现出良好的稳定性。

关 键 词: 光纤通信系统; 正交调制; 卷积神经网络; 深度学习; 数字反向传播; 注意力机制

中图分类号: TP394.1; TH691.9

文献标识码: A

Nonlinear impairment compensation method for Long-haul Fiber-optic communication system

YUAN Ying^{1*}, SHEN Yuanxun², SHEN Ping³

(1. School of Information Engineering, Hubei Polytechnic Institute, Xiaogan 432000, China)

(2. School of Computer and Communication Engineering, Northeastern University, Qinhuangdao 066004, China)

(3. Academic Affairs Office, Hubei Polytechnic Institute, Xiaogan 432000, China)

Abstract: With the increase in transmission rate and transmission distance, the impact of nonlinear impairments on the performance of long-haul fiber-optic communication systems becomes increasingly significant, severely restricting overall system performance. In order to mitigate integrated effects of nonlinear impairment for the long-haul fiber-optic communication system, a dual-branch hybrid neural network-based nonlinear impairment compensation method for the long-haul optical communication system is proposed. Firstly, the channel memory is leveraged by the model to capture the global feature of channel impairments in the time domain, so as to optimize feature learning of current symbols through historical information; Secondly, the spatial features of symbols in the constellation diagram are captured by the real-valued branch based on convolutional neural networks, and the channel attention mechanism and the spatial attention mechanism are adopted to enhance the learning capability of the model for nonlinear impairment-related spatial features; Finally, the latent information of phase and amplitude variations of complex symbols is captured by the complex-valued branch, thereby the combined effects of nonlinear impairments are effectively compensated. Numerical simulation is established with self-phase modulation and cross-phase modulation as the primary nonlinear effects, simulation results demonstrate that the proposed method achieves a lower bit er-

收稿日期: 2025-03-26; 收到修改稿日期: 2025-05-17

基金项目: 中国高校产学研创新基金-新一代信息技术创新项目 (2023IT160)

作者简介: 袁瑛 (1977—), 女, 副教授, 硕士, 从事数据库技术、软件技术方面的研究。

* 通信作者: allenincntt@163.com

ror rate and exhibits stability under varying conditions of transmitted optical power, transmission distance and symbol rate.

Keywords: Fiber-optic communication system; quadrature modulation; convolutional neural network; deep learning; digital back propagation; attention mechanism

0 引言

随着智能设备、云计算和人工智能技术的普及,对数据传输速率和距离均提出了前所未有的要求^[1,2]。长距离光通信^[3]以高速率、低延迟和大容量的优势,成为现代通信系统的核心部分,支撑着物联网、云计算和移动互联网的稳定运行。随着数据速率和传输距离增加,长距离光通信系统的非线性损耗加剧,导致信号质量和系统容量均有所下降。针对此问题,学者们尝试采用非线性补偿技术^[4]和新型光纤材料^[5]来提高长距离光通信的质量。

数字反向传播(Digital Backward Propagation, DBP)^[6]是一种经典的光纤通信非线性补偿技术,它基于数值模拟反向传播过程对光通信信号失真进行补偿,利用分步傅里叶求解非线性薛定谔方程,通过反向链路参数补偿信号的非线性效应^[7]。该方法对确定性损伤的补偿效果较好,但对随机性损伤的补偿效果不佳^[8]。此外,DBP需要大量的逆傅里叶变换运算,它在较小步长时计算复杂度较高^[9]。为了在非线性损伤补偿性能和效率之间取得平衡,早期研究人员利用机器学习技术对光信号进行非线性补偿,其核心思想是将光信号非线性补偿视为在空间上的信号分类任务,例如:基于支持向量机的补偿方法^[10]和基于随机森林的补偿方法^[11]。由于机器学习技术在结构上的局限性,它们仅在某种调制方式或信道参数条件下才能实现较好的性能。

近年,深度神经网络在求解复杂的非线性问题时展现出良好的性能,因此越来越多的研究人员采用神经网络缓解光通信系统的非线性信号失真,其核心思想是利用深度神经网络学习接收信号与发送信号间的关系,进而根据接收信号恢复出原始发送信号^[12,13]。文献[14]提出一种预训练卷积神经网络(Convolutional Neural Network, CNN)的长距离光通信非线性补偿方法,该方法采用分层训练和联合优化策略来提高训练效率,并引入一种增强激活函数来捕捉符号间非线性关系,最终改善了高速大容量光通信系统的性能。文献[15]提出一种基于递归神经网络(Recursive Neural Network, RNN)的均衡器,其性能优于传

统前馈或非级联神经网络均衡器,有效缓解了线性信道效应、直接调制激光器频率啁啾和器件非线性性的影响。文献[16]对三种双向RNN模型进行了仿真评估,发现双向长短期记忆(Bidirectional Long Short-Term Memory, Bi-LSTM)、双向门控循环单元(Bidirectional Gated Recurrent Unit, Bi-GRU)和双向普通循环神经网络(Bidirectional Vanilla Recurrent Neural Network, Bi-Vanilla-RNN)补偿数字相干系统非线性损伤的效果好于传统Volterra(沃尔泰拉)非线性均衡器。文献[17]提出一种基于全连接神经网络(Fully Connected Neural Network, FCNN)的非线性补偿方法,用于16-正交幅度调制(16-Quadrature Amplitude Modulation, 16-QAM)波分复用(Wavelength Division Multiplexing, WDM)通信系统,与基于DBP的非线性补偿方法相比,该方法的补偿性能更好,且计算成本显著降低。总体而言,CNN^[14]、RNN^[15]、Bi-LSTM^[16]和FCNN^[17]均为实数神经网络,且比机器学习技术的泛化性能更强。由于克尔效应的光场在非线性质中传播时,折射率随光强变化导致相位调制,因此文献[18]将QAM符号的复数特性与克尔效应激活函数结合,改善了对非线性克尔效应的补偿性能。复数神经网络^[19]利用QAM信号的幅度-相位联合表征能力,并结合非线性响应模型,能捕捉光场传输中的相位信息。

综上所述,基于实数神经网络和基于复数神经网络的补偿方法对于不同类型非线性损伤的效果不同,一方面,由于一些非线性效应产生复杂的相位和幅度变化,使用复数神经网络能保留相位信息,进而捕捉非线性效应隐含的复杂关系;另一方面,实数神经网络能学习星座图中符号的空间特征,所提取特征对符号聚类中心和噪声分布的判别性较强。由于长距离光通信非线性损伤具有多样性,增强失真补偿方法的通用性和鲁棒性才能对多种非线性效应进行有效补偿,进而提升通信系统的性能和容量。

为了缓解长距离光通信线性损伤和非线性损伤的综合效应,提出一种双分支混合神经网络(Dual-Branch Hybrid Neural Network, DBHNN),以期在提高长距离光通信系统性能的情况下,改

善补偿方法的通用性和鲁棒性。本文主要贡献如下：(1) 建立了基于PDM-64QAM (Polarization Division Multiplexing-64 Quadrature Amplitude Modulation, PDM-64QAM) 的多信道长距离高速光通信模型，建模过程考虑了光纤衰减、色散、自相位调制 (Self-Phase Modulation, SPM) 和交叉相位调制 (Cross-Phase Modulation, XPM)。(2) 提出一种结合实数神经网络和复数神经网络的双分支混合神经网络模型，该模型利用信道记忆捕捉历史符号间的前后相关性，使用实数分支捕获星座图中符号的空间特征，使用复数分支捕获复数符号相位与幅度变化的隐含信息，从而实现了对多样化非线性效应的有效补偿。

1 系统模型

1.1 光通信系统

图1为一个经典的长距离光纤通信系统结构图，采用偏振多路复用-64阶正交幅度调制方式，以提高长距离光通信的频谱效率。发送端使用外腔激光器 (External Cavity Laser, ECL) 产生连续光载波，将高速电信号加载到光载波上，运用I/Q调制器 (由两个马赫-曾德尔调制器 (Mach-Zehnder Modulator, MZM) 组成) 进行64-QAM调制，波特率为64Gbaud。偏振保持掺铒光纤放大器放大光信号，然后通过偏振多路复用 (Polarization Division Multiplexing, PDM) 将两个独立的64-QAM信号分别加载到正交的偏振态上，产生PDM-64QAM信号。多个发送器的信号通过波分复用实现多信道光纤传输，信道间隔为50GHz，使用掺铒光纤放大器 (Erbium Doped Fiber Amplifier, EDFA) 放大光纤传输中的光信号。

接收端通过波分解复用将不同波长的光信号分离，光电探测器将分离后的光信号转换成电信号，电信号经过匹配滤波器来最大化信噪比，失真信号传入DBHNN模型进行失真补偿，以逼近原始发送信号。

1.2 系统模型

将自相位调制和交叉相位调制视为多通道光通信系统中克尔效应非线性损伤的核心因素，并将光纤衰减和色散整合到长距离光通信系统中。使用薛定谔方程描述光场在长距离光纤中传播的状态，光场复包络随传播距离的变化可表示为^[20, 21]

$$\frac{\partial C_a^{u/v}}{\partial d} = -\alpha \frac{\partial \gamma C_a^{u/v}}{\partial t} - i\beta_2 \frac{\partial^2 C_a^{u/v}}{\partial t^2} + i\gamma \left(|C_a^u|^2 + |C_a^v|^2 \right) + 2 \sum_{z \neq a} \left(|C_z^u|^2 + |C_z^v|^2 \right) C_a^{u/v} \quad (1)$$

式中， α 、 β_2 和 γ 分别为光纤衰减系数、二阶色散系数和克尔非线性系数， γ 通常与非线性折射率和有效模场面积有关； d 为传输距离； t 为传播时间； u 和 v 为两个正交的偏振方向， $C_a^{u/v}$ 为第 a 个信道在 u 或 v 偏振方向上的复包络， $|C_a^u|^2$ 为第 a 个信道在 u 偏振方向上的光场强度之和， $|C_a^v|^2$ 为第 a 个信道在 v 偏振方向上的光场强度之和。式(1)等号右边第1、2、3和4项分别对应光纤损耗、色散、自相位调制和交叉相位调制。




图1 长距离光纤通信系统结构图

使用分步傅里叶法求解广义非线性薛定谔方程，以仿真光脉冲在长距离光纤中的传播特性。分步傅里叶法将传播距离 d 划分成若干个短距离的步长，在每个步长中独立计算线性效应和非线性效应，线性效应主要包括色散，非线性效应包括克尔效应（自相位调制和交叉相位调制），最终得到光脉冲在光纤中的传播特性。对薛定谔方程线性部分求解，可得到光场在传播步长 Δd 后由线性效应引起的光场变化

$$C_a(d + \Delta d) = e^{-i\beta_2 \frac{\partial^2}{\partial t^2} \Delta d} C_a(d) \quad (2)$$

式中， $C_a(d)$ 为第 a 个信道传播距离 d 时的光场复包络， $\partial^2/\partial t^2$ 描述光脉冲的展宽或压缩， Δd 为步长， $e^{-i\beta_2 \frac{\partial^2}{\partial t^2} \Delta d}$ 为线性效应引起的光场相位变化。

对薛定谔方程非线性部分求解，可得到光场在步长 Δd 后由非线性效应引起的光场变化

$$C_a^{u/v}(d + \Delta d) = e^{i\gamma(|C_a^u|^2 + |C_a^v|^2)\Delta d} C_a^{u/v}(d) \quad (3)$$

式中， $C_a^{u/v}(d)$ 为第 a 个信道传播距离 d 时在 u 或

v 偏振方向上的光场复包络, $e^{i\gamma(|c_v^s|^2 + |c_v^s|^2)\Delta d}$ 为非线性效应引起的光场相位变化。

2 DBHNN 模型

2.1 DBHNN 模型结构

图2为所提DBHNN模型的结构图。使用一个滑动窗口实现信道记忆, 滑动窗口从匹配滤波器符号流中选取目标符号 x_i 之前 $s-1$ 个符号构成一个长度为 s 的符号向量, 即信道记忆。实数分支将接收符号向量的每个符号分成实部和虚部, 得到的 $2s$ 个实数, 传入输入层; 复数分支直接将 s 个符号传入输入层, 保持其复数形式。




图2 DBHNN模型结构图

DBHNN由实数分支和复数分支构成, 结合两者优势以提高对多种损伤综合效应的补偿效果。复数分支为一个全连接神经网络, 包含一个输入层、两个隐藏层和一个输出层。两个隐藏层的神经元数量相等, 均为输入层节点数的两倍, 输出层的神经元数量为 o 。实数分支是一个卷积神经网络, 包含两个路径: 主路径由两个一维卷积块、一个注意力模块、一个平坦层和一个全连接层组成; 次路径为一个全连接层。每个一维卷积块包括一维卷积层、批标准化层和激活层。

复数分支输出的复数特征分离成实部和虚部, 与实数分支输出的实数特征拼接, 全连接层通过线性变换将拼接特征投影到同一特征空间, 最终输出估计符号 y_i 的同相分量 (I 分量) 和正交分量 (Q 分量)。

2.1.1 复数分支

由于QAM调制符号为复数, 使用复数神经网络能更好地拟合克尔效应。复数分支采用全连接神经网络结构, 包含一个输入层、两个隐藏层和一个输出层。输入层的神经元数量等于 s , 两个隐

藏层的神经元数量相等, 输出层的神经元数量为 s , 如图3所示。每个复数神经元由一对实数 (I, Q) 构成, I 和 Q 分别为同相分量和正交分量, 使用复数激活函数拟合复数信号的非线性损伤。




图3 复数分支结构图

复数分支每个隐藏层依次进行线性变换和非线性激活处理, 线性变换的数学形式可表示为

$$\begin{cases} I^{k+1} = U^k \cdot I^k - V^k \cdot Q^k \\ Q^{k+1} = V^k \cdot I^k + U^k \cdot Q^k \end{cases} \quad (4)$$

式中, (I^k, Q^k) 为第 k 层复数神经元向量, $(U_{(i,j)}^k, V_{(i,j)}^k)$ 为第 k 和第 $k+1$ 层间连接的复数权重矩阵。

使用克尔效应激活函数进行激活处理^[21], 激活函数为

$$f^k(x) = e^{-|g_k| |x|^2} x \quad (5)$$

式中, g_k 为神经网络第 k 层的训练参数。

2.1.2 实数分支

实数分支将接收的复数符号分解成实部和虚部, 输入层大小为 $2s$ 。该分支分为主路径和次路径, 主路径依次为一维卷积层、批标准化 (Batch Normalization, BN)、ReLU激活层、一维卷积层、批标准化、ReLU激活层、注意力模块、平坦层和一个全连接层。一维卷积层通过参数共享能高效地提取一维符号序列的局部特征, BN的作用是加快模型训练收敛速度, 并提高训练稳定性。ReLU激活层提供非线性特性, 增强对非线性损伤的拟合能力, 全连接层节点数为 $2s$, 因此该路径的输出尺寸为 $2s$ 。次路径包含一个全连接层, 将输入数据通过权重矩阵和偏置向量映射为 $2s$ 个输出值。次路径不仅具有残差连接功能, 还相当于一个最小均方 (Least Mean Square, LMS) 均衡器。主路径和次路径的输出相加, 得到实数分支的特征向量。

将一维卷积特征传入注意力模块, 进一步丰富特征信息并突出关键特征的重要性。图5展示了注意力模块的运算流程。该模块通过为特征图的各通道及通道内的特征分量分配不同权重, 并采用适量的跨通道交互来降低运算复杂度。




图 4 实数分支结构图




图 5 注意力模块的运算流程

ESCA 模块主要由通道注意力和空间注意力构成。首先，使用平均池化将 $W \times H \times C^A$ 的特征图各通道空间信息压缩成一个特征，可表示为

$$\dot{x}_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (6)$$

式中， $x_c(i, j)$ 为第 c 个通道 (i, j) 处的值。

使用一维卷积和 sigmoid 函数计算通道注意力权值，可表示为

$$\mathbf{w}_1 = \text{sigmoid}(\text{Conv}_{1D}(\dot{\mathbf{x}})) \quad (7)$$

式中， $\text{Conv}_{1D}()$ 为一维卷积运算； $\text{sigmoid}()$ 为 Sigmoid 函数。

包含通道注意力的特征图可表示为

$$\ddot{x}_c(i, j) = \mathbf{w}_{(1,c)} \cdot x_c(i, j) \quad (8)$$

式中， $\mathbf{w}_{(1,c)}$ 为第 c 个通道的注意力权值。

为捕获通道内空间位置的重要性，使用平均池化在通道维度上进行信息聚合，可表示为

$$\mathbf{q}_{AP}(i, j) = \frac{1}{C^A} \sum_{c=1}^{C^A} \ddot{x}_c(i, j) \quad (9)$$

使用最大池化在通道维度上进行信息聚合，

可表示为

$$\mathbf{q}_{MP}(i, j) = \max_c \ddot{x}_c(i, j) \quad (10)$$

将尺寸为 $H \times W$ 的 $\mathbf{q}_{AP}$ 和 $\mathbf{q}_{MP}$ 拼接成 $2 \times H \times W$ 的 $\mathbf{q}$ ，使用二维卷积计算每个通道内空间位置的注意力权值，可表示为

$$\mathbf{w}_2 = \text{sigmoid}(\text{Conv}_{2D}(\mathbf{q})) \quad (11)$$

式中， $\text{Conv}_{2D}()$ 为二维卷积运算。

包含空间注意力的特征图可表示为

$$\ddot{\ddot{x}}_c(i, j) = \mathbf{w}_2(i, j) \cdot \ddot{x}_c(i, j) \quad (12)$$

通道注意力通过对各通道进行加权，突出重要通道；空间注意力通过对每个通道内的空间位置进行加权，突出重要空间特征。引入注意力模块能为符号失真的关键信息分配更高的权重，增强神经网络对非线性损伤的拟合能力，进而提高长距离光通信的非线性损伤补偿性能。

2.2 模型复杂度分析

DBHNN 模型复数分支的运算量主要来自于线性变换和非线性激活运算，单层的线性变换乘法次数为 $8MN$ ，非线性激活的乘法次数为 $7M$ ，其中 N 和 M 分别为第 k 层和第 $k+1$ 层的神经元数量。单层的总乘法次数为 $8MN+7M$ ，复数分支的总复杂度近似为 $O(MN+M)$ 。实数分支的运算量主要来自于 1D 卷积、全连接层和注意力模块，三者的复杂度分别为 $O(2KD^2s)$ 、 $O(2Ds^2+s^2)$ 和 $O(D^2)$ ，实数分支的总复杂度为 $O(2KD^2s+2Ds^2+s^2)$ ，其中 D 为注意力模块的输入通道数， s 等于输入符号向量长度。全连接层和输出层的总复杂度为 $O(s)$ 。DBHNN 模型的总复杂度为 $O(1) + O(s^2) + O(s) = O(s^2)$ 。

2.3 DBHNN 模型训练

利用滑动窗口建立 DBHNN 的训练集和测试集，如图 6 所示。将匹配滤波器输出的符号序列分为两部分，分别为训练序列和测试序列，两者的长度分别为 L_t 和 L_s 。滑动窗口每次滑动 1 个符号，生成 L_t-s+1 个长度为 s 的符号向量构成训练集，生成 L_s-s+1 个长度为 s 的符号向量构成测试集。

使用均方误差 (MSE) 作为损失函数，MSE 能有效反映 QAM 星座图的几何信息，增加输出符号数 s 会使输出层尺寸线性增长，从而支持多个高阶 QAM 输出符号。损失函数的表达式为

$$\ell = \frac{1}{2n} \sum_{i=1}^n \left((y_i^I - y_i'^I)^2 + (y_i^Q - y_i'^Q)^2 \right) \quad (13)$$

式中， y_i^I 和 $y_i'^I$ 分别为网络输出和真实的 I 分量幅

值; y_i^Q 和 $y_i'^Q$ 分别为网络输出和真实的 Q 分量幅值; n 为样本总数。由于 DBHNN 输出为 I 分量和 Q 分量的幅度, 而非判决符号, 因此通信系统可使用软判决前向纠错 (Soft Decision Forward Error Correction, SD-FEC) 处理。




图6 训练集和测试集建立方法

3 仿真分析

3.1 仿真建立

使用分步傅里叶法求解非线性薛定谔方程, 交替计算线性 (色散) 和非线性效应, 由此模拟光信号在不同场景下的光纤传输过程, 重点观察非线性损伤对信号传输的影响。基于图1所示的模块图建立仿真通信系统。单模光纤分为若干跨段, 每段长100km, 使用噪声系数为4.5dB的掺铒光纤放大器补偿每段损耗。使用滚降因子为0.1的根升余弦滤波器生成信号, 使用格雷编码星座图, 信道数为20, 30GBaud以下的信道间频率间隔为50GHz, 30GBaud以上的信道间频率间隔为75GHz。ECL波长为1550nm, 光纤衰减系数为0.2 (dB/km), 色散为17 (ps/nm/km), 二阶色散系数为-19 (ps²·km⁻¹), 色散斜率为-19 (ps/nm²/km), 非线性相移为3mrad, 调制方式为64-QAM, 非线性损伤包含SPM和XPM, 克尔效应非线性系数为1.4 (W⁻¹·km⁻¹)。选取第10和第11信道进行性能分析, 信道间隔为50GHz时, 中心信道左右各2个相邻信道参与XPM补偿, 信道间隔为75GHz时, 中心信道左右各1个相邻信道参与XPM补偿。

3.2 模型参数

DBHNN模型复数分支的输入层、输出层节点数均等于窗口尺寸, 两个隐藏层的节点数均为输入层节点数的两倍。卷积核尺寸越大, 感受野越大, 这会导致一些重要细节被忽略, 较小的卷积核则能更好地捕捉信道记忆的局部细节和局部相关性, 因此将卷积核尺寸设为2×1, 卷积层的卷积核数设为8。

DBHNN的全连接层层数为2, 节点数均为64, 输出层节点数为2, 分别输出当前符号的 I 分量和 Q 分量。

通过仿真生成200000个样本 (每个中心信道各100000个), 训练集和测试集的样本比例为8:2, 训练集中随机选取10%用于模型验证, 剩余90%用于模型训练。采用Adam (Adaptive Moment Estimation) 优化器训练DBHNN模型, 最大训练轮数 (epoch) 设为100, 学习率为0.001, 批量大小 (batch size) 为100。

3.3 参数分析

DBHNN模型基于滑动窗口构造信道记忆, 并基于多个相邻符号推理当前符号, 因此输入符号向量长度 s 对模型性能具有关键影响。将传输距离设为200km, 光功率为0dBm, 符号率分别设为20、40和60GBaud, 评估模型在测试集上的平均误码率性能, 结果如图7所示。高阶调制的高速光纤通信系统对误码率要求较高, BER阈值线设为 1×10^{-4} , 以确保软判决前向纠错后BER可将至 1×10^{-15} 以下。由图7可知, 在60GBaud符号率下, 信道误码率性能受信道记忆尺寸影响较小。随着符号率降低, 信道误码率大幅降低, 但受信道记忆尺寸的影响逐渐增大。当符号率较低时, 非线性损伤较小, 误码率较低, 使用DBHNN对非线性损伤进行主动补偿, 能显著改善长距离光通信的性能; 当符号率较高时, 非线性损伤变得显著, DBHNN的补偿效果较低。为了在补偿性能和复杂度之间取得平衡, 输入符号向量长度 s 设为31。




图7 输入符号向量长度对误码率的影响

3.4 仿真结果

选取基于DBP的补偿方法和基于神经网络的补偿方法作为对比方法, 综合评估所提DBHNN对长距离光通信非线性损伤补偿的性能。基于DBP的方法为PA-LDBP^[22], 该方法将微扰理论和DBP结合, 并将交叉相位调制集成到DBP模型中来提高DBP的性能。基于神经网络的方法包括

CNN^[14]、Bi-LSTM^[16]和CFNN^[18]。此外，将DBHNN复数分支和实数分支的非线性激活函数关闭，得到其线性版模型，记为DBHNN_Linear。

为综合评估DBHNN对非线性损伤的补偿效果，在不同通信参数下进行了数值仿真。将符号率设为20Gbaud，传输距离为200km，ECL发射光功率从-8dBm逐步增加至4dBm，分别统计长距离光通信的误码率性能，结果如图8所示。由图8可知，当发射功率等于-6dBm时，Bi-LSTM的误码率较高，而其它四种方法的误码率较低。其原因可能为：一方面，Bi-LSTM为实数神经网络，因此对QAM复数符号的学习能力不足；另一方面，虽然Bi-LSTM可学习符号序列的前后相关性，但它无法区分符号序列中的重要模式，导致对非线性损伤的捕获能力不足。长距离光通信系统常用的里德-所罗门码(255,239)前向纠错算法阈值约为 10^{-4} ，因此五种方法在-6dBm至4dBm范围内均满足需求。尽管CNN具有很强的空间特征提取能力，其性能明显优于CFNN，但CNN以每符号一个样本的方式运行，导致其整体性能受到限制。PA-LDBP通过将微扰理论和交叉相位调制引入DBP模型，取得了较好的补偿效果。经比较，在不同发射功率下，所提DBHNN对非线性损伤的补偿效果均显著优于其它四种方法。这表明所提方法在不同发射功率下均能保持较好的性能，展现出良好的鲁棒性和稳定性。




图8 光通信系统误码率与发射功率的关系

将光功率设为0dBm，传输距离为200km，符号速率从20Gbaud逐步增加至64Gbaud，分别统计长距离光通信的误码率性能，结果如图9所示。图中显示，各方法的误码率均随着符号速率的提高而升高，Bi-LSTM在40Gbaud时达到前向纠错阈值，CFNN在48Gbaud时达到前向纠错阈值，PA-LDBP和CNN在52Gbaud时达到前向纠错阈值，DBHNN在56Gbaud时达到前向纠错阈值。总体而言，DBHNN可以支撑更高速的长距离光通信传输，并

且所提方法在不同符号速率下均能保持较好的误码率性能，展现出良好的鲁棒性和稳定性。




图9 光通信系统误码率与符号速率的关系

将光功率设为0dBm，符号速率为20Gbaud，将传输距离从200km逐步增加至1000km，分别统计长距离光通信的误码率性能，结果如图10所示。从图中可以看出，随着传输距离增加，光通信系统的损伤增大。Bi-LSTM与CFNN在400km达到前向纠错阈值，PA-LDBP和CNN在500km达到前向纠错阈值，DBHNN在600km达到前向纠错阈值。总体而言，DBHNN可以支撑更长距离的光通信传输，并且所提方法在不同距离下均能保持较低的误码率性能，展现出良好的鲁棒性和稳定性。




图10 光通信系统误码率与传输距离的关系

在多信道高速长距离光通信系统中，非线性损伤是限制通信性能的主要因素。本文提出一种双分支混合神经网络DBHNN来缓解多种非线性损伤引起的光信号失真，该模型结合了实数神经网络和复数神经网络的优势，并在实数分支中引入了通道注意力和空间注意力机制，进一步增强了模型的表达能力和泛化能力。通过数值仿真验证，所提方法在不同光信号功率、传输距离和传输速率下均表现出更优的误码率性能，进一步证明了模型较强的泛化能力。

4 结 论

为了缓解长距离光通信中多样化的非线性损

伤效应,提出一种双分支混合神经网络模型。该模型结合了实数网络和复数网络的优势,以提升对多种损伤综合效应的补偿效果,其中,复数神经网络能够更好地拟合光通信系统中的克尔效应,而实数神经网络则用于捕捉光信号在空间上的非线性损伤效应,从而增强了模型在不同通信参数下的主动补偿能力。文中使用固定的训练集、验证集和测试集对模型进行训练和测试,当模型应用于不同参数的通信系统时,只需在少量新数据上微调即可达到良好的性能。

本文是混合神经网络在长距离光通信非线性损伤补偿任务中的初步尝试,未来研究将从以下方面展开:首先,所提模型的复数分支采用了基于克尔效应的激活函数,未来将研究其它激活函数的效果;其次,还将探索使用性能和效率更高的神经网络来捕捉信号中隐藏的复杂非线性特征。

参考文献:

- [1] 邵进,刘辰屹,杨莞,等.低成本大规模直播流量工程[J].清华大学学报(自然科学版),2024,64(3):591—601.
Tai Jin, Liu Chenyi, Yang Yuan, et al. Low-cost traffic engineering for large-scale live streaming[J]. Journal of Tsinghua University(Science and Technology), 2024, 64(3):591—600.
- [2] 卞玲艳,曾艳萍,蔡莹,等.大数据时代光电共封装技术的机遇与挑战[J].激光与光电子学进展,2024,61(9):65—76.
Bian Lingyan, Zeng Yanping, Cai Ying, et al. Opportunities and challenges of optoelectronic co-packaging technology in the era of big data[J]. Laser & Optoelectronics Progress, 2024, 61(9):65—76.
- [3] Kaur P, Dhawan D, Gupta N. Design and analysis of a soliton-based WDM system for performance enhancement of long-haul communication[J]. Optoelectronics and Advanced Materials-Rapid Communications, 2024, 18(3/4):144—149.
- [4] Cui J, Kong W, Liu Z, et al. Dynamic secure key distribution based on dispersion equalization and cellular automata for optical transmission[J]. Photonics, 2023, 10(12):1308—1317.
- [5] 施伟华,蔡萌雅,娄跃,等.新型宽带低损耗单模空芯反谐振光纤的研究[J].激光与光电子学进展,2025,62(07):0706004.1—0706004.8.
Shi Weihua, Cai Mengya, Lou Yue, et al. Novel broadband low-loss single-mode hollow-core anti-resonant fiber[J]. Laser & Optoelectronics Progress, 2025, 62(7):0706004.1—0706004.8.
- [6] Chi X, Bai C, Yang F, et al. Joint intra and inter-channel nonlinear compensation scheme based on improved learned digital back propagation for WDM systems[J]. Optics Express, 2024, 32(4):22—32.
- [7] Huang J, Yi A, Yan, et al. Fast fiber nonlinearity compensation method for PDM coherent optical transmission systems based on the Fourier neural operator[J]. Optics Express, 2024, 32(2):2245—2256.
- [8] 陈志江,刘逢清. OBP与DBP联合补偿的112Gb/s DP-16QAM信号传输性能分析[J].光通信技术,2017,41(4):16—19.
Chen Zhijiang, Liu Fengqing. Transmission performance analysis of 112Gb/s DP-16QAM signal using OBP combined with DBP compensation[J]. Optical Communication Technology, 2017, 41(4):16—19.
- [9] Hadjadji N, Hamdi R. Nonlinearity mitigation of self-phase modulation effect in coherent optical system[J]. Journal of Optical Communications, 2024, 45(4):853—862.
- [10] Nguyen T, Mhatli S, Giacomidis E, et al. Fiber nonlinearity equalizer based on support vector classification for coherent optical ofdm[J]. IEEE Photonics Journal, 2017, 8(2):1—9.
- [11] Torkaman P, Latifi S M, Feng K M, et al. Nonlinearity-robust im/dd thz communication system via two-stage deep learning equalizer[J]. IEEE Communications Letters: A publication of the IEEE Communications Society, 2024, 28(8):1805—1809.
- [12] Wang Y, Guo Q, Liu X Y. Doubly selective channel estimation and equalization based on ICI/ISI mitigation for OQAM-FBMC systems[J]. Physical Communication, 2023, 59(8):102120.1—102120.10.
- [13] Bakhshali A, Najafi H, Hamgini B Z Z. Neural network architectures for optical channel nonlinear compensation in digital sub-carrier multiplexing systems[J]. Optics Express, 2023, 31(16):26418—26434.
- [14] Sidelnikov O, Redyuk A, Sygletos S, et al. Advanced convolutional neural networks for nonlinearity mitigation in long-haul wdm transmission systems[J]. Journal of Lightwave Technology, 2021, 39(8):2397—2406.
- [15] Xu Z, Sun C, Ji T, et al. Cascade recurrent neural network-assisted nonlinear equalization for a 100Gb/s PAM4 short-reach direct detection system[J]. Optics Letters, 2020, 45(15):4216—4219.
- [16] Deligiannidis S, Mesaritakis C, Bogris A. Performance and complexity analysis of bi-directional recurrent neural network models vs[J]. Volterra Nonlinear Equalizers in Digital Coherent Systems, 2021, 39(18):5791—5798.
- [17] Sidelnikov Oleg, Redyuk Alexey, Sygletos Stylianos. Equalization performance and complexity analysis of dynamic deep neural networks in long haul transmission systems[J]. Optics Express, 2018, 26(25):32765—32776.
- [18] Bogdanov S A, Sidelnikov O S. Use of complex fully connected neural networks to compensate for nonlinear effects in fibre-optic communication lines[J]. Quantum Electronics, 2021, 51(5):459—462.
- [19] Freire P J, Neskornik V, Napoli A, et al. Complex-valued neural network design for mitigation of signal distortions in optical links[J]. Journal of Lightwave Technology, 2020, 39(6):1696—1705.
- [20] Pan J T, Zhu B H, Ma L L, et al. Nonlinear geometric phase coded ferroelectric nematic fluids for nonlinear soft-matter photonics[J]. Nature Communications, 2024, 15(1):8732—8743.
- [21] Xu H, Jin Y. The asymptotic expansion for a class of nonlinear singularly perturbed problems with optimal control[J]. Journal of Nonlinear Sciences & Applications (JNSA), 2016, 4(9):2718—2726.
- [22] Lin X, Luo S, Soman S K O, et al. Perturbation theory-aided learned digital back-propagation scheme for optical fiber nonlinearity compensation[J]. Lightwave Technology, IEEE/OSA Journal of (J-LT), 2022, 40(7):1981—1988.