

引用本文:陈宏伟,臧裕斌,简睿洁,等. 光纤信道智能建模的发展与挑战[J]. 光通信技术,2026,50(4):1-8.

光纤信道智能建模的发展与挑战

陈宏伟^{1†}, 臧裕斌^{2†}, 简睿洁², 张祖兴^{2*}

(1. 清华大学 电子工程系, 北京 100084; 2. 南京邮电大学 电子与光学工程学院, 南京 210023)

摘要:为应对当前高速大容量光纤通信系统智能化的需求,详细介绍了光纤信道建模的传统方法,分析了传统方法的优势和局限。在此基础上,系统梳理了当前各类主流的光纤信道智能模型的构建原理、结构、适用范围和相应优势,总结了模型在计算复杂度、计算效率和泛化性能等方面的特点。最后,结合现有技术特点和未来需求,展望了光纤信道智能模型所亟待解决的问题和未来发展趋势。

关键词:光纤通信;人工智能;信道建模

中图分类号:TN256 **文献标志码:**A **文章编号:**1002-5561(2026)04-0001-08

DOI:10.13921/j.cnki.issn1002-5561.2026.04.001

Developments and challenges on intelligent optical fiber channel modeling

CHEN Hongwei^{1†}, ZANG Yubin^{2†}, JIAN Ruijie², ZHANG Zuxing^{2*}

(1. Department of Electronic Engineering, Tsinghua University, Beijing 100084, China;

2. College of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: To cater the needs of current high-speed large-scale optical fiber communications, this paper introduces traditional optical fiber modeling algorithm in detail and analyzes its advantages and drawbacks. On this basis, this paper systematically illustrates the principles, structures, applications and characteristics of the current main stream intelligent optical fiber models. It also summarizes each model's performance on computing complexity, efficiency and generalization. Finally, both the urgent problems and future trends of the intelligent optical fiber channel modeling are outlined.

Key words: optical fiber communication, artificial intelligent, channel modeling

0 引言

光纤凭借低损耗、大带宽及抗干扰等显著优势,

收稿日期:2026-04-29。

基金项目:国家自然科学基金项目(62301275)资助;南京邮电大学高水平师资启动项目(NY223032)资助。

作者简介:陈宏伟(1979—),男,博士,教授,入选国家级高层次人才计划。在 Nature Communications、Nature Nanotechnology 等学术期刊发表 SCI 论文 100 余篇,授权国家发明专利 20 余项。曾获教育部自然科学二等奖、全国发明展览会金奖等多个奖项。

臧裕斌(1995—),男,江苏省“双创博士”。2017—2023 年在清华大学电子工程系攻读博士学位;2023 年入职南京邮电大学电子与光学工程学院,主要研究方向为人工智能光学。

† 陈宏伟和臧裕斌为本文共同第一作者,对本文有同等贡献。

***通信作者:**张祖兴(1957—),男,江苏特聘教授,博士生导师。入选江苏省“六大人才高峰”高层次人才选拔培养对象,曾获欧盟玛丽·居里学者基金资助,担任日本文部科学省 GCOE 项目研究员,长期从事光纤激光器及智能光纤系统研究。



已成为支撑当今“信息高速公路”的核心传输介质^[1]。据统计,截至 2025 年底,我国光纤光缆部署总里程已逾 7.4×10^7 km,终端接口数量突破 12 亿个,标志着光纤通信已深度融入国民经济与社会生活^[2]。在这一庞大基础设施之上,如何实现信号的可靠、高效与智能化传输,成为信息通信领域亟待突破的关键问题。其中,光纤信道建模作为系统设计与优化的基础性环节,通过揭示损耗、色散、非线性效应及噪声干扰对信号演化的影响规律,为调制格式选择、编码策略设计及数字信号处理算法开发提供理论依据。信道建模的精度与可靠性,直接决定了系统在传输速率、距离、频谱效率及能耗控制等关键指标上的性能上限^[3-4]。

传统光纤信道建模基于描述电磁波传播的非线性薛定谔方程(NLSE),该方程精准刻画了光信号在复杂物理环境下的幅度与相位变化^[5-8]。由于 NLSE 解析解稀缺,一般采用分步傅里叶方法(SSFM)进行数值求

陈宏伟,臧裕斌,简睿洁,等:光纤信道智能建模的发展与挑战

解^[9-10]。SSFM通过“微分—解耦—迭代”思路,在频域和时域交替处理色散与非线性算子,具有计算准确、适用范围广的优势,是各类仿真软件的底层核心。然而,SSFM存在显著局限:其计算复杂度随传输距离增加而线性增长,导致长距离链路建模耗时较长;算法固有的串行迭代特征使其难以并行加速,严重制约了计算效率。特别是在高功率或强非线性场景下,计算负担进一步加重。面对高速大容量通信系统对快速建模与实时验证的迫切需求,传统方法在计算效率与复杂度一致性上的不足日益凸显,亟需引入新型智能建模技术以突破瓶颈。

为解决上述问题,近十年来,研究人员结合人工智能(AI)技术构建了多种光纤信道智能模型,旨在利用AI算力满足大容量高速通信的快速建模需求。本文梳理光纤信道模型的发展历史与现状,深入分析各类智能建模方法的优劣,凝练当前研究应聚焦的核心问题,并尝试指出未来的发展方向,以期为下一代光纤通信系统的智能化建模提供理论参考与技术指引。

1 光纤信道智能模型

根据模型自学习和自组织方式的不同,现有研究主要分为数据驱动模型(DDM)、原理驱动模型(PBM)、混合驱动型以及其他光纤信道智能模型4类。

1.1 DDM

针对SSFM在计算复杂度与效率方面的局限,随着近年来AI的兴起众多研究人员将目光聚焦于神经网络,期望依托其强大的算力与拟合能力实现光纤信道的快速建模。2020年,北京邮电大学研究团队^[11]提出了基于双向长短时记忆网络(BiLSTM)的短距离光纤传输模型,这是国内较早提出的光纤信道智能模型代表。该模型利用BiLSTM优异的时序信号处理能力,在大量预采集数据的驱动下,自适应调整BiLSTM层及后续全连接层的神经元权重,从而实现对传输信号的精准预测。经合理训练后,该模型能够对100 km传输距离下单模光纤中开关键控(OOK)和脉冲幅度调制(PAM)信号的传输进行高精度预测。由于采用神经网络进行端到端映射,模型的计算复杂度不随链路参数变化而改变;且训练完成后,其预测效率较SSFM显著提升。

同年,上海交通大学研究团队^[12]提出了基于生成对抗网络(GAN)的光纤传输模型。该模型通过生成网络与判别网络的对抗博弈,逐步提升生成网络对信号传输特征的学习能力,从而更精准地预测传输后的

信号。经训练后,该模型不仅能预测100 km传输距离下高阶调制信号的传输效果,且预测精度得到进一步提升。此后,清华大学^[13]和北京邮电大学研究团队^[14]结合Transformer架构,分别提出了适用于短距离和长距离传输预测的光纤模型。短距离模型经训练后,可灵活预测100 km以内任意距离下,速率高达160 Gbit/s的OOK、PAM、正交相移键控(QPSK)及正交幅度调制(QAM)信号传输结果;长距离模型则能有效预测四跨总计1 000 km、速率高达160 Gbit/s的QAM信号传输波形。

典型的DDM对比表如表1所示。可以看出,模型之所以能够自适应地建立起光纤信号传输前后波形的变化是因为它通过大量预先采集的数据进行训练。表中所有模型将光纤信道信号预测从实际物理背景中抽离出来,把它归结成时间序列拟合,进而通过“数据采集—模型搭建—数据驱动”的模式进行模型训练。这样的模型构建方式训练效率高,符合神经网络理论一贯的训练测试流程,但从表1中也能发现,此类模型对训练数据规模的依赖性较强,且其距离泛化性能较为一般模型的适用场景严格依赖于预先采集数据的分布。然而在实际应用中,数据采集往往面临获取困难或成本高昂的问题,这对DDM而言是不可接受的——即使训练样本略有不足,模型的预测精度也会显著下降,更遑论数据严重缺乏的情形。此外,将光纤信道信号预测完全抽离于实际物理背景,也对模型的应用可靠性提出了挑战。

1.2 PBM

与DDM不同,PBM通过引入物理知识——即NLSE对神经网络进行约束,从而引导模型收敛至符合物理规律的解。

2022年,清华大学和北京邮电大学研究团队^[15-16]结合同期兴起的物理信息神经网络(PINN)技术^[17-18],首次提出了基于PINN的原理驱动型光纤物理效应模型和光纤传输模型。该模型采用简单的多层全连接网络,其与DDM的主要区别体现在输入/输出定义及损失函数设计上。对于DDM,输入和输出分别为光纤链路传输前后的信号;对于PBM,输入为时延坐标系中的时间 t 和距离 z 坐标,输出则为信号包络演化结果的实部与虚部。因此,PBM本质上可视为一种NLSE数值求解器。由于神经网络处理的是离散数据,PBM同样需对时间和距离坐标进行离散化和归一化处理。在损失函数设计方面,PBM摒弃了数据驱动型常用的归一化均方误差,转而构建基于NLSE残差和初始条

表1 典型的DDM对比表

时间/单位	模型名称	模型结构	适用场景/数据集规模	预测精度	距离泛化性能	复杂度
2020年,北京邮电大学 ^[11]	基于BiLSTM的光纤短距离传输模型	BiLSTM	单模光纤; 传输距离为10~80 km; 符号速率为10 GBd; 调制方式为OOK、PAM; 每个距离采样点含 2^{13} 个符号	信号功率归一化均方误差 (NMSE) ≤ 0.02	覆盖10~80 km; 误差随距离增长而增长	与外界链路参数无关;约为SSFM的20%
2020年,上海交通大学 ^[12]	基于GAN的光纤短距离传输模型	GAN	单模光纤; 传输距离跨段数 ≤ 20 ; 跨段长度为50 km; 符号速率为30 GBd; 调制方式为QAM; 每个距离跨段含 10^6 个信号样本	信号功率 NMSE ≤ 0.01	覆盖0~1 000 km; 误差随距离增长而增长	与外界链路参数无关;约为SSFM的2%
2022年,清华大学 ^[13]	基于多头注意力机制的光纤短距离传输模型	Transformer	单模光纤; 传输距离 ≤ 100 km; 符号速率 ≤ 40 GBd; 调制方式为OOK、PAM、QPSK、QAM; 每个距离采样点含 3×10^4 个符号	还原传输端后 信号功率 NMSE $\leq 10^{-3}$	覆盖0~100 km; 误差随着调制格式、符号速率的增加而增长,随传输距离两头大中间小	与外界链路参数无关;约为SSFM的2%
2022年,清华大学 ^[14]	基于多头注意力机制的多跨光纤长距离传输模型	Transformer	单模光纤; 传输距离跨段数 ≤ 4 ; 跨段长度为50 km; 符号速率 ≤ 40 GBd; 调制方式为OOK、PAM、QPSK、QAM; 每个距离跨段总量上线含 6×10^7 个符号	还原传输端后 信号功率 NMSE $\leq 10^{-5}$	覆盖0~1 000 km; 误差随着调制格式、符号速率与传输距离的增加而增长	与外界链路参数无关; 约为SSFM的2%

件(传输前信号波形)的物理约束损失函数。在训练过程中,神经网络预测的信号演化结果需代入NLSE计算残差,并利用该残差反向传播更新梯度,直至损失函数收敛。经训练后,光纤物理效应模型能够以较高精度完成脉冲演化、信号传输及线性双折射等物理过程的预测;光纤信号传输模型则可实现对OOK、PAM等调制格式信号的精准预测。

除了在损失函数中引入NLSE以增强物理可解释性外,另一种思路是通过算子学习建立函数空间之间的直接映射,从而提升模型的泛化性能。此类典型工作包括:2023年,西南交通大学研究团队^[19]提出的基于傅里叶神经算子(FNO)的PBM,以及同年北京邮电大学研究团队^[20]提出的基于深度算子网络(DeepONet)的PBM。这2类模型代表了原理驱动型方法中算子学习的典型应用,均为长距离传输模型,并采用了多跨段分布式构建策略,以抑制长距离传输中的误差积累。

PBM的结构与损失函数特性表明,其无需预先采集大量传输后的实测数据即可实现有效训练,从而克服了DDM在样本稀缺场景下的学习困境。以PINN为

代表的PBM,因在损失函数中嵌入NLSE,其底层逻辑不再是脱离物理背景的抽象数学拟合,显著增强了模型的可解释性。同时,模型训练1次即可对指定最大距离内的任意传输距离波形进行预测,距离泛化性能显著提升。然而,清华大学^[13-14]早期(如2022年)提出的PBM仍存在主要局限:由于模型针对特定参数下的NLSE求解,光纤损耗系数 α 、二阶色散系数 β_2 、非线性系数 γ (或非线性折射率 n_2)等物理参数必须固定。若更换光纤参数或信号速率,模型需重新训练。这意味着模型在不同传输场景间的可移植性较差。

为解决这一问题,2025年,南京邮电大学和清华大学研究团队^[21-22]提出了变参量光纤物理效应和信号传输模型。该模型一经训练,在切换不同场景时仅需进行小规模微调,显著提升了PBM的场景适应性。该模型旨在求解参数空间 (α, β_2, n_2) 或信号速率空间内NLSE的通解。其构建思路借鉴了数学中的“基分解”思想,即将NLSE在给定参数空间下的特解拆解为一组特征解的线性组合。换言之,改变参数取值仅改变线性组合系数,而不改变特征解本身。因此,模型结构分为两部分:若干特征解求解器(沿用2022年提出

陈宏伟,臧裕斌,简睿洁,等:光纤信道智能建模的发展与挑战

的PBM架构)和线性组合系数求解模块^[13-14]。特征解对应的参数值确定及系数模块训练采用贪心算法:首先确定参数空间边界、预期损失阈值及最大训练轮次;初始阶段随机选择第一个特征解对应的参数并训练求解器;得出特征解后,遍历参数空间中各组值以寻找最优线性系数,并计算各组的NLSE残差损失;将损失最大的1组参数值作为下一个特征解的目标参数,依次迭代,直至满足停止条件。训练完成后,该模型能够覆盖损耗 α 的范围为0~0.2 dB/km、二阶相位传播常数 β_2 的范围为 $-2\times10^{-26}\sim2\times10^{-26}\text{ s}^2/\text{m}$ 、非线性折射率 n_2 的范围为 $-2.6\times10^{-20}\sim2.6\times10^{-20}\text{ m}^2/\text{W}$ 及符号速率的范围为1~100 Gbaud的广泛传输场景。在场景转换时,只需微调线性组合系数,无需从头训练。

综上所述,PBM与DDM类似,其推理阶段的算法复杂度不受传输距离、非线性强度等外部参数影响。尽管PBM在距离泛化能力和可解释性上优于DDM,但因损失函数中引入复杂的NLSE微分算子,导致其训练难度大、收敛速度慢。2025年,南京邮电大学和清华大学团队提出的变参量模型不仅增强了场景移植能力,还客观上大幅降低了训练成本:它将原本依赖于仿真场景数量的训练次数,转化为依赖于预设特征解数量的训练过程。对于新场景,仅需快速求解最优

线性组合系数即可,极大地提升了建模效率。典型的PMB对比表如表2所示。可以看出,PBM对于训练数据的要求往往显著低于DDM,此外在模型结构、参数及损失函数的设计上也充分考量了光纤信道的物理特征。

1.3 混合驱动型模型

与DDM相比,PBM可解释性强、距离泛化能力好,也具有一定的场景移植性,但不可否认其训练效率仍然偏低。根据机器学习理论,损失函数的特性和计算难度是决定神经网络训练效率和收敛速度的重要因素。PBM为了提升物理可解释性和距离泛化性能而完全使用NLSE残差作为损失函数,相比DDM采用的NMSE,其计算更为复杂、损失函数 landscape 平坦度较差,故收敛较为困难。这类似于学生只学知识点而不做习题,虽具备举一反三的潜力,但掌握难度大、周期长。为平衡训练效率与泛化性能,一个可行的思路是在原理驱动的基础上不完全抛弃数据——正如学生既学知识点也做相应习题,这便是混合驱动型模型。

2022年前后,众多研究人员提出了各类混合驱动型模型,一些模型的提出甚至早于PBM。其中,最具代表性的是上海交通大学研究团队^[23-24,26]在2022—2025年

表2 典型的PBM对比表

时间/单位	模型名称	模型结构	适用场景	预测精度	距离泛化性能	复杂度
2022年,清华大学 ^[17-18]	基于PINN的原理驱动型光纤物理效应模型	PINN	单模光纤的物理效应:脉冲演化、信号传输和双折射效应 光纤长度 $\leq 100\text{ km}$	信号功率 $\text{NMSE}\leq 10^{-2}$	覆盖0~100 km; 误差随物理效应复杂程度而增长	与外界链路参数无关;约为SSFM的20%
2023年,西南交通大学 ^[19]	基于FNO的光纤智能传输模型	FNO	单模光纤; 传输跨段 ≤ 15 ; 单跨段距离为80 km; 符号速率为28 Gbaud; 调制方式为QAM;	信号功率 $\text{NMSE}\leq 10^{-3}$	覆盖0~1 200 km; 误差随距离增长而增长	与外界链路参数无关;约为SSFM的25%
2023年,北京邮电大学 ^[20]	基于DeepONet的光纤智能传输模型	DeepONet	传输距离为720~800 km 符号速率为28 Gbd; 调制方式为QAM;	信号功率 $\text{NMSE}\leq 2\times 10^{-3}$	覆盖720~800 km; 误差随跨段增长而增长	与外界链路参数无关
2025年,南京邮电大学 ^[21]	基于变参量的光纤物理效应模型	生成式预训练物理信息神经网络(GPT-PINN)	单模光纤脉冲演化; 光纤参数空间为: α 范围为0~0.2 dB/km, β_2 范围为 $-2\times10^{-26}\sim2\times10^{-26}\text{ s}^2/\text{m}$; n_2 范围为 $-2.6\times10^{-20}\sim2.6\times10^{-20}\text{ m}^2/\text{W}$; 传输距离 $\leq 100\text{ km}$	损失函数 残差 $\leq 10^{-4}$	覆盖0~100 km;在参数空间的边界处误差较大	与外界链路参数无关;约为SSFM的0.01%
2025,南京邮电大学 ^[22]	基于变参量的光纤信号传输模型	GPT-PINN	单模光纤物理效应; 传输距离 $\leq 100\text{ km}$; 符号速率为0~100 Gbaud; 调制方式为OOK、PAM	信号功率 $\text{NMSE}\leq 5\times 10^{-3}$	覆盖0~100 km; 在参数空间的边界处误差较大	与外界链路参数无关;约为SSFM的0.01%

间所提出的特征解耦分布式(FDD)系列模型,包括FDD-BiLSTM模型、FDD-Transformer模型以及序列-序列特征解耦分布式(Seq-Seq FDD)模型。上述模型采用多跨段分布式部署思路,能够高效解决波分复用(WDM)系统在长距离传输时的信号快速预测问题。对于光纤传输的每个跨段,由于损耗和色散的经典算法速度快且较为成熟,因此直接使用SSFM中的相应方法进行处理;而对于非线性效应,则利用BiLSTM、Transformer等结构的强大拟合能力进行建模。该团队2025年提出的模型通过迁移学习的方式,使其能够适应高速长距离的光纤信号传输。

混合驱动型模型的另一典型代表是2025年北京大学研究团队^[25]提出的稀疏分步傅里叶方法-傅里叶神经算子(S-SSFM-FNO)模型;与FDD模型类似,该模型采用分布式部署策略:对于光纤中的线性效应,直接使用SSFM进行计算;对于非线性效应,则使用FNO进行建模,从而在提升算法距离泛化性能的同时,提高了训练效率和预测精度。

2025年,南京邮电大学研究团队^[27]提出了基于色散算子模块和非线性算子模块的光纤传输模型。该模型中的色散算子借鉴SSFM中频域计算色散效应的思路,将传输信号的色散效应部分沿用SSFM的方式在频域进行计算。由于色散计算较为简单,这不仅减轻了神经网络的计算压力,也增强了模型的可解释性。而对于经典算法计算较为困难的非线性效应部分,则采用神经网络进行建模。研究团队还对比了不同网络结构计算非线性效应的性能,经对比,多头注意力-单层全连接(MHA-1FC)结构的效率最高。

相比DDM,混合驱动型模型只需采用较低复杂度的网络就能获得较好的预测精度和泛化性能;相比于PBM,由于其非线性算子网络采用NMSE作为损失函数,因此训练收敛速度更快。典型的混合驱动型模型对比如表3所示。可以看出,混合驱动模型既包含经典算法策略,又包含智能算法策略。该模型在设计上实现了计算效率与物理可解释性的平衡:对于经典算法能够快速求解的部分直接采用经典算法处理,而对于其难以高效求解的复杂部分,则引入智能算法进行快速预测。因此,混合驱动型模型在复杂度和泛化性能方便介于DDM和PBM之间。由于模型中经典算法难以快速求解的部分多采用数据驱动型神经网络进行预测,故仍存在移植性较弱、针对不同场景需要重

新训练的问题。

1.4 其他光纤信道智能模型

除了上述3类模型之外,研究人员也提出了其他重要的模型,其中典型的有端到端模型^[28-33]、增强分步傅里叶算法(ESSFM)模型^[34]以及高斯过程回归模型^[35]等。2018年,伦敦大学学院研究人员^[28]率先提出了端到端传输模型,该模型在光纤传输发送端和接收端分别构建人工神经网络,对光传输链路整体进行“一体化”优化。相比于传统光纤通信优化方式,该模型能够从全局角度提升传输性能,而无需逐模块进行改进,革新了光纤通信系统的优化思路。2020年,相关研究人员在该模型基础上分别应用双向循环神经网络^[31-32]和生成对抗网络^[33],进一步挖掘了光纤通信系统全局优化的空间。

2021年,查尔姆斯理工大学研究人员^[34]通过类比神经网络结构和SSFM算法,提出了ESSFM模型。其基本思路是利用神经网络的“线性计算”优势处理光纤中的损耗及色散效应,非线性计算部分则依旧交由SSFM处理。该工作验证了共计25跨段、每跨段长度为80/100 km的光纤通信系统预测性能。结果表明,该模型在加速光纤链路计算的同时,能够有效降低计算复杂度。同年,剑桥大学^[35]提出的高斯过程回归模型是另一个备受关注的模型,该模型通过训练优化核超参数,进而达到精准预测的效果。

2 关键挑战与未来展望

尽管近十年的科研探索表明,光纤智能模型在预测精度、覆盖场景、距离泛化性能及物理可解释性等方面均取得了显著进步,其应用不限于解决SSFM中的复杂度不一致性问题,还提供了一套适用于快速构建与验证的综合方案。然而,上述4类智能光纤模型若要更深、更广地覆盖当前光纤通信的众多实际场景^[36-41],仍面临以下亟待解决的关键挑战:

1) 预测精度的提升。当前的首要挑战在于提升模型在极端复杂场景下的预测精度,特别是针对高传输速率、高阶调制格式、强非线性效应以及超远距离传输场景。这些场景的共性问题在于信号畸变机制极为复杂,必须综合考虑高阶色散、非线性效应以及偏振模色散(PMD)等与信号偏振相关的效应。根据机器学习理论,神经网络对于高频分量及高阶效应的拟合和识别能力相对较弱。从实际模型案例中可以观察到,同一结构模型的预测精度往往随信号传输速率的增大而降低。此外,对于涉及信号偏振的效应,需

陈宏伟,臧裕斌,简睿洁,等:光纤信道智能建模的发展与挑战

表3 典型的混合驱动型光纤传输模型对比表

时间/单位	模型名称	模型结构	适用场景	预测精度	距离泛化性能	复杂度
2022年,上海交通大学 ^[23]	FDD-BiLSTM模型	分布式结构; 线性部分-经典算法; 非线性部分-BiLSTM	单模光纤; WDM跨段数目 ≤ 13 ; 单跨段长度为80 km; 符号速率为30 Gbaud; 调制方式为QAM	$NMSE \leq 7 \times 10^{-3}$	覆盖0~1 040 km; 误码随着传输距离的增加而增长	与外界链路参数无关; 约为SSFM的3%
2022年,上海交通大学 ^[24]	FDD-Transformer模型	分布式结构; 线性部分-经典算法; 非线性部分-Transformer	单模光纤; WDM跨段数目 ≤ 15 ; 单跨段长度为80 km; 符号速率为30 Gbaud; 调制方式为QAM	Q 值 ≤ 0.25 dB	覆盖0~1 200 km; 随着传输距离的增加而增长	与外界链路参数无关; 约为SSFM的1.3%
2025年,北京大学 ^[25]	S-SSFM-FNO模型	分布式结构;线性部分-经典算法; 非线性部分-FNO	单模光纤;WDM 跨段数目 ≤ 30 单跨段长度为80 km; 符号速率为64 Gbaud; 调制方式为QAM	$NMSE \leq 10^{-2}$	覆盖0~2 400 km; 误码随着传输距离的增加而增长	与外界链路参数无关; 约为SSFM的1.5%
2025年,上海交通大学 ^[26]	Seq-Seq FDD模型	线性部分-经典算法; 非线性部分-BiLSTM 迁移学习	单模光纤; WDM跨段数目 ≤ 15 ; 单跨段长度为80 km; 符号速率 ≤ 140 Gbaud; 调制方式为QAM; 每通道含 2.5×10^5 个符号	$NMSE \leq 5 \times 10^{-3}$	覆盖0~1 200 km; 随着传输距离的增加而增长	与外界链路参数无关; 约为SSFM的0.5%
2025年,南京邮电大学 ^[27]	色散与非线性算子网络模型	频域色散+BiLSTM/ MHA	单模光纤; 传输距离 ≤ 100 km; 符号速率 ≤ 40 Gbaud; 调制方式为OOK、PAM、QPSK、QAM; 每个距离采样点含 3×10^4 个符号	信号功率 $NMSE \leq 10^{-3}$	覆盖0~100 km; 误码随着调符号速率与传输距离的增加而增长	与外界链路参数无关; 约为SSFM的1.4%

要处理2个正交偏振态上的信号传输方程组(Manakov方程组)。这不仅使数据驱动型和混合驱动型模型的数据模量增加1倍,也使得PBM的损失函数构建更为复杂,从而增加了训练难度。

2)泛化能力的强化。泛化能力是指模型在超出训练数据分布之外的其他数据空间中的表现,前述的距离泛化能力仅是其中一种。当前现有模型的泛化能力高度依赖于其所学习的数据分布或预设的物理先验。一旦脱离原始数据分布范围或改变物理先验条件,模型的性能将出现显著下降。因此,如何在确保模型计算复杂度处于合理限度的前提下,尽可能增强模型对于未知数据、跨场景及跨参数条件的预测性能,是今后研究需要重点聚焦的问题。

3)随机噪声与干扰的数字孪生生成。一个具有实际工程意义的信道模型必须具备对噪声合理的仿真能力。当前众多模型所用的噪声来源多是实际采

集并预先加载于信号上的静态数据。虽然这种方式可以解决传输链路之前的噪声问题,但对于实际链路中光纤震动、应力变化、微小弯折等动态因素造成的不可避免干扰,其分布和特性与具体的扰动过程紧密相关。因此,要使模型更贴合真实传输场景,必须解决传输过程中随机干扰信号的“数字孪生”生成问题。此外,特别是在超长距离传输中存在的PMD及其他随机效应,如何实现其高精度的数字孪生生成仍有待进一步深入研究。

4)应用场景的扩增。应用场景的扩增并非一个孤立的技术难点,而是预测精度不足、泛化能力受限以及随机噪声数字孪生生成困难这三大核心挑战共同制约的结果。由于未能从根本上解决上述问题,当前光纤智能模型的应用场景较为有限。具体表现如下:

横向扩展受限:由于未能从根本上解决精度、泛

化和随机噪声生成问题, 当前模型主要聚焦于随机性效应和干扰噪声较小的情形。适用于高维复用方式、高阶调制格式以及高速率信号的模型仍在不断研究中。

特种光纤涉及较少: 当前智能传输模型的研究对象多为单模光纤, 而对空芯光纤^[42]、少模光纤^[43]、非线性光纤^[44]、光子晶体光纤^[45]、反谐振光纤^[46]等特种光纤涉及较少。这是因为大部分模型(尤其是PBM)的底层仍然基于单模光纤的NLSE。若要扩展至其他特种光纤, 要么涉及对NLSE的整体修改, 引入纤芯、模式、偏振等多维方程; 要么需要深入探究光纤结构与材料对其损耗、色散、非线性等特性的影响, 以简化NLSE。

纵向替代能力不足: 尽管PBM和混合驱动型模型在一定程度上提高了物理可解释性, 但神经网络在计算方式上仍处于“自适应黑盒状态”。加之目前神经网络在处理高非线性、宽频谱信号时准确性尚显不足, 当前光纤智能模型更多充当实际光纤通信系统传输仿真和验证的重要参考, 还无法完全替代经典算法。

3 结束语

综上所述, 光纤信道智能建模技术是基于NLSE和传统SSFM, 结合AI技术所提出的快速验证方案。截至目前, 该技术在保证计算复杂度不随外部链路变化而剧烈波动的前提下, 已展现出较高的预测精度、较好的距离泛化能力以及初步的物理可解释性能, 相关模型已在单模光纤传输领域获得了一定的应用验证。

展望未来, 随着对高阶效应拟合、泛化能力增强、随机噪声数字孪生以及特种光纤适配等关键挑战的逐步攻克, 光纤信道智能建模技术将更好地应对日益增长的高速、大容量光纤通信系统在构建效率与快速验证方面的需求, 最终实现从“辅助参考”向“核心仿真引擎”的跨越。

参考文献:

- [1] Keiser G. Optical fiber communications[M]. Atlanta: American Cancer Society, 2003.
- [2] 中华人民共和国工业和信息化部. 2025年通信业统计公报解读: 通信业运行平稳 新动能加快培育[EB/OL]. (2019-01-28) [2019-03-10]. https://www.miit.gov.cn/jgsj/yxj/xxfb/art/2019/art_ba84699fb1bc4341af494442525ad142.html.
- [3] Qi Xiaoqiong, Zhang Xiaoping. Nonlinear optical fiber channel capacity estimation[J]. Acta Photonica Sinica, 2007, 36(B06): 14-17.
- [4] Saleh B E A, Teich M C. Fiber optics[M]. Hoboken: John Wiley &

Sons, 2001.

- [5] Agrawal G P. Applications of nonlinear fiber optics[M]. Amsterdam: Elsevier, 2001.
- [6] Agrawal G P. Nonlinear fiber optics[M]. Amsterdam: Elsevier, 2012.
- [7] Weideman J A C, Herbst B M. Split-step methods for the solution of the nonlinear schrödinger equation[J]. Siam Journal on Numerical Analysis, 1986, 23(3): 485-507.
- [8] Sinkin O V, Ronald H, Zwick J, et al. Optimization of the split-step fourier method in modeling optical-fiber communications systems[J]. Journal of Lightwave Technology, 2003, 21(1): 61-68.
- [9] Gérard M. The finite element method for electromagnetic modeling[M]. New York: Wiley, 2008.
- [10] Strang G. An analysis of the finite element method[J]. Mathematics of Computation, 1974, 41(1): 115-119.
- [11] Wang Danshi, Song Yuchen, Li Jin, et al. Data driven optical fiber channel modeling: a deep learning approach[J]. Journal of Lightwave Technology, 2020, 38(17): 4730-4743.
- [12] Yang Hang, Niu Zekun, Xiao Shilin, et al. Fast and accurate optical fiber channel modeling using generative adversarial network[J]. Journal of Lightwave Technology, 2020, 39(5): 1322-1333.
- [13] Zang Yubin, Yu Zhenming, Xu Kun, et al. Data-driven fiber model based on deep neural network with multi-head attention mechanism[J]. Optics Express, 2022, 30(19): 46646.
- [14] Zang Yubin, Yu Zhenming, Xu Kun, et al. Multi-span long-haul fiber transmission model based on cascaded neural networks with multi. head attention mechanism[J]. Journal of Lightwave Technology, 2022, 40(19): 6347-6358.
- [15] Zang Yubin, Yu Zhenming, Xu Kun, et al. Universal fiber models based on PINN neural network[C]//Optical Society of America. Proceedings of Asia Communications and Photonics Conference. Beijing: Optical Society of America, 2020: M4A.196.
- [16] Zang Yubin, Yu Zhenming, Xu Kun, et al. Principle-driven fiber transmission model based on PINN neural network[J]. Journal of Lightwave Technology, 2022, 40(2): 404-414.
- [17] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707.
- [18] Lagaris I E, Likas A. Artificial neural networks for solving ordinary and partial differential equations[J]. IEEE Transactions on Neural Networks, 1998, 9(5): 987-1000.
- [19] He Xingchen, Yan Lianshan, Jiang Lin, et al. Fourier neural operator for accurate optical fiber modeling with low complexity[J]. Journal of Lightwave Technology, 2023, 41(8): 2301-2311.
- [20] Zhang Ximeng, Zhang Min, Song Yuchen, et al. DeepONet-based waveform-level simulation for a wideband nonlinear WDM system[J]. Journal of Lightwave Technology, 2023, 41(22): 6908-6922.
- [21] Zang Yubin, Hua Boyu, Tang Zhenzhou, et al. Principle driven parameterized fiber model based on GPT-PINN neural network[J]. Optics and Laser Technology, 2025, 189: 113037-113037.
- [22] Zang Yubin, Hua Boyu, Lin Zhipeng, et al. Fiber transmission model

陈宏伟, 臧裕斌, 简睿洁, 等: 光纤信道智能建模的发展与挑战

with parameterized inputs based on generative pre-trained physics-informed neural networks[J]. Optics Express, 2025, 33(1): 50–61.

[23] Yang Hang, Niu Zekun, Zhao Haochen, et al. Fast and accurate waveform modeling of long-haul multi-channel optical fiber transmission using a hybrid model-data driven scheme[J]. Journal of Lightwave Technology, 2022, 40(14): 4571–4580.

[24] Zeng Chuyan, Niu Zekun, Yang Hang, et al. Enhancing generalization in neural channel model for optical fiber WDM transmission through learned encoding of system parameters[C]//IEEE. Proceedings of Optical Fiber Communication Conference (OFC) 2024. San Diego: IEEE, 2024: 1–3.

[25] Zhang Tianhong, Pan Yutong, Zheng Jiayu, et al. Fourier neural operator accelerated fast and accurate optical fiber transmission modeling[J]. Journal of Lightwave Technology, 2025, 43(8): 3592–3604.

[26] Shi Minghui, Niu Zekun, Yang Hang, et al. Fast and accurate waveform modeling based on sequence-to-sequence framework for multi channel and high-rate optical fiber transmission[J]. Optics Letters, 2025, 50(7): 2286–2289.

[27] Zang Yubin, Hua Boyu, Lin Zhipeng, et al. Knowledge inspired operator neural network for fast and accurate fiber transmission predictions[J]. Optics Communications, 2025, 596: 132531.

[28] Karanov B, Chagnon M, Thouin F. et al. End-to-end deep learning of optical fiber communications[J]. Journal of Lightwave Technology, 2018, 36(20): 4843–4855.

[29] Karanov B, Bayvel P, Schmalen L. End-to-end learning in optical fiber communications: concept and transceiver design[C]//VDEITG. Proceedings of 2020 European Conference on Optical Communications. Brussels: VDEITG, 2020: 1–3.

[30] Karanov B, Oliari V, Chagnon M, et al. End-to-end learning in optical fiber communications: experimental demonstration and future trends [C]//VDEITG. Proceedings of 2020 European Conference on Optical Communications (ECOC), Brussels: VDEITG, 2020: 1–4.

[31] Karanov B, Chagnon M, Aref V, et al. Optical fiber communication systems based on end-to-end deep learning(invited paper)[C]//IEEE. Proceedings of 2020 IEEE Photonics Conference (IPC). Vancouver: IEEE, 2020: 1–2.

[32] Karanov B, Chagnon M, Aref V, et al. Experimental investigation of deep learning for digital signal processing in short reach optical fiber communications[C]//IEEE. Proceedings of 2020 IEEE Workshop on Signal Processing Systems(SiPS). Coimbra: IEEE, 2020: 1–6.

[33] Karanov B, Chagnon M, Aref V, et al. Concept and experimental demonstration of optical im/dd end-to-end system optimization using a generative model[C]//IEEE. Proceedings of 2020 Optical Fiber Communications Conference and Exhibition(OFC). San Diego: IEEE, 2020: 1–3.

[34] Häger C, Pfister H D. Physics-based deep learning for fiber-optic

communication systems[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1): 280–294.

[35] Nevin J W, Vaquero-Caballero F J, Ives D J, et al. Physics-informed gaussian process regression for optical fiber communication systems[J]. Journal of Lightwave Technology, 2021, 39(21): 6833–6844.

[36] Khan F N, FAN Qirui, LU Chao, et al. An optical communication's perspective on machine learning and its applications[J]. Journal of Lightwave Technology, 2019, 37(2): 493–516.

[37] Yan Shuangyi, Khan F N, Mavromatis A, et al. Field trial of machine-learning-assisted and sdn-based optical network planning with network-scale monitoring database[C]//Optica. Proceedings of 2019 Optical Fiber Communications Conference and Exhibition (OFC). San Diego: Optica, 2019: M2E.1.

[38] Tizikara D K, Serugunda J, Katumba A. Machine learning-aided optical performance monitoring techniques: a review[J]. Frontiers in communications and networks, 2022, 2: 756513.

[39] KILINÇARSLAN K, KARLIK S E. Prediction of OSNR with machine learning methods in DWDM/UDWDM long-haul transmission systems using EDFAs under the triple impact of FWM, SRS and ASE noise [J]. Optics & Laser Technology, 2019, 197: 114832.

[40] Elfiky A, Rezki Z, Cortez J, et al. End-to-end deep learning in wireless communication systems: a tutorial review[PP/OL]. arXiv (2019–03–29) [2026–04–29]. <http://arxiv.org/pdf/1903.12289>.

[41] Shi Minghui, Yang Hang, Niu Zekun, et al. Deep learning waveform channel modeling for wideband optical fiber transmission: model comparisons, challenges and potential solutions[J]. Journal of Lightwave Technology, 2019, 44(9): 3357–3382.

[42] Gharbi S, Saucourt J, Vasko K, et al. On-demand orbital angular momentum modes through hollow-core multimode fiber via a neural network model[J]. Optics Express, 2019, 34(1): 1121–1132.

[43] Gao Han, Pei Li, Wang Jianshuai, et al. Position-independent mode information extraction in optical fiber with a compatible data compression neural network[J]. Optics & Laser Technology, 2019, 193: 114099.

[44] Yin Yujia, Wang Suhua, Ren Hongliang, et al. HNLF-based feedforward photonic reservoir computing with adaptive memory[J]. Optical Fiber Technology, 2019, 99: 104569.

[45] Liu Yupeng, Wang Weijia, Wang Yan, et al. FiberGNN: a graph neural network framework for efficient photonic crystal fiber parameters prediction[J]. Expert Systems with Applications, 2019, 309: 131223.

[46] Ren Zhiyong, Gan Yang, Li Xiabin, et al. A multi-model framework for optimizing splice loss in hollow-core anti-resonant fibers[J]. Optics Communications, 2019, 445: 133021.