

引用本文:朱宏娜,刘仲涛,朱宇轩,等.深度学习赋能的水下无线光通信研究进展[J].光通信技术,2026,50(3):1-11.

深度学习赋能的水下无线光通信研究进展

朱宏娜¹,刘仲涛¹,朱宇轩¹,于水¹,郎子义²,罗斌²,吴宗玲^{2*}

(1.西南交通大学 物理科学与技术学院,成都 610031;2.西南交通大学 信息科学与技术学院,成都 610031)

摘要:水下无线光通信(UWOC)兼具宽带宽、高数据传输速率以及低成本小体积发射器等优势,是海洋通信领域的重要支撑技术。然而水下信道环境复杂,受到吸收、散射、湍流等多种因素影响,传统方法在复杂动态场景中性能受限。近年来,深度学习(DL)因凭借强大的非线性拟合能力和数据驱动优势,为UWOC的研发提供了重要支撑。总结了DL在UWOC中信道估计、信号检测、调制格式识别、轨道角动量(OAM)模态识别、组网优化等关键技术方向,最后对DL在未来UWOC中的应用进行了总结和展望。

关键词:水下无线光通信;深度学习;信道估计;信号检测;调制格式识别;轨道角动量模态识别;组网优化

中图分类号:TN256 **文献标志码:**A **文章编号:**1002-5561(2026)03-0001-11

DOI:10.13921/j.cnki.issn1002-5561.2026.03.001

Advances in deep learning-enabled underwater wireless optical communication

ZHU Hongna¹, LIU Zhongtao¹, ZHU Yuxuan¹, YU Shui¹, LANG Ziyi², LUO Bin², WU Zongling^{2*}

(1. School of Physical Science and Technology, Southwest Jiaotong University, Chengdu 610031, China;

2. School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Underwater wireless optical communication(UWOC) offers advantages such as wide bandwidth, high data transmission rates, and low-cost, compact transmitters, making it a key supporting technology in the field of marine communication. However, the underwater channel environment is complex and affected by various factors including absorption, scattering, and turbulence, which limit the performance of traditional methods in complex dynamic scenarios. In recent years, deep learning (DL), with its powerful nonlinear fitting capabilities and data-driven advantages, has provided important support for the development of UWOC. This paper summarizes the application of DL in key technical areas of UWOC, including channel estimation, signal detection, modulation format recognition, orbital angular momentum(OAM) mode recognition, and network optimization. Finally, the future application of DL in UWOC is summarized and prospected.

Key words: underwater wireless optical communication, deep learning, channel estimation, signal detection, modulation format recognition, modal identification of orbital angular momentum, networking optimization

0 引言

随着国家“海洋强国”战略的深入推进,海洋资源

收稿日期:2026-03-28。

基金项目:国家重点研发计划项目(2021YFC3101402)资助;中央高校基本科研业务费专项(2682025XJ020)资助。

作者简介:朱宏娜(1979—),女,山东烟台人,博士,教授。长期从事光纤通信、分布式光纤传感及智能信息处理领域的研究工作,已发表学术论文80余篇。作为负责人或主要成员,承担了国家自然科学基金项目、四川省科技厅项目、重点研发计划项目及多项企业合作项目。

***通信作者:**吴宗玲(1987—),男,硕士,实验师,主要从事光纤通信及人工智能方面的研究工作。



勘探、环境监测及水下目标探测等领域对高速、低延迟水下无线通信技术的需求日益迫切^[1-2]。其中,水下无线光通信(UWOC)利用蓝绿激光波段在海水中低衰减的特性,凭借宽带宽、高传输速率及发射端低成本小型化等优势,已成为构建海底观测网、自主水下航行器(AUV)集群协作及跨介质通信的关键支撑技术^[3-5]。典型的UWOC系统通过激光器发射准直光束,经海水信道传输后由光电探测器接收并转换为电信号,再经信道估计、信号检测等处理恢复信源信息^[3]。

国内外研究学者已在UWOC领域积累了丰富的成果。韩笑天等人^[6]、黄诺等人^[7]、Ramley I等人^[8]分别对

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

UWOC的系统组成、信道补偿、蒙特卡洛仿真架构及安全挑战等方面进行了系统梳理,但该领域仍面临系列严峻挑战。传统 UWOC 系统多依赖解析模型(如 Beer-Lambert 定律)或线性信号处理算法,包括最小二乘、最小均方误差均衡(LS/MMSE)、自适应阈值检测。这类系统在复杂动态海域中,常因模型失配或参数整定困难,造成误码率(BER)恶化甚至链路中断^[4-5]。特别是在高阶调制格式识别、轨道角动量(OAM)模态解复用及多节点组网等高维信号处理场景中,传统基于人工特征提取的方法难以有效抑制非线性畸变与模态串扰。

近年来,深度学习(DL)技术凭借其强大的非线性拟合能力和数据驱动优势,在自然语言处理、计算机视觉等领域实现突破^[9-10],并逐渐被引入到水下通信信号分析之中^[11-12]。与传统方法相比,DL能够直接从数据中学习信道的高维特征分布,无需依赖严格的解析模型,从而有效克服水下信道的非线性畸变与长记忆效应。目前,DL已广泛应用于UWOC的信道估计、信号检测、调制识别及组网控制等链路环节,展现出显著的性能增益与鲁棒性优势。然而,现有综述多聚焦于传统物理层技术或初步应用,缺乏对近五年DL赋能机制的系统梳理,尤其缺少对算法与物理机制映射关系、不同场景下的性能边界及工程落地挑战的深度剖析。鉴于此,本文重点梳理2021—2026年间的最新研究进展,深入剖析DL在UWOC五大关键技术方向——信道估计、信号检测、调制格式识别、OAM模态识别及组网优化中的应用机理与性能对比。在此基础上,本文进一步探讨当前面临的数据匮乏、模型轻量化及物理可解释性等挑战,并展望物理信息神经网络、语义通信及数字孪生等未来发展方向,以期构建智能、高效、鲁棒的UWOC系统提供理论参考与技术指引。

1 DL赋能UWOC的理论映射机制

UWOC系统的性能受限于复杂多变的水下信道特性。DL并非孤立存在,而是通过与物理层信号处理流程的深度耦合,解决传统解析模型难以应对的非线性与时变性问题。本文从UWOC物理层架构与信道特性、信号处理流程中的DL介入节点,以及DL核心网络机制与UWOC物理问题的映射关系3个维度,阐述DL赋能UWOC的理论基础。

1.1 UWOC物理层架构与非线性信道特性

UWOC系统的核心任务是将数字信息调制到光

载波上,通过海水介质完成高速信息传输。系统主要包括光发射端、水下信道和光接收端三部分^[13]。发射端将电信号转换至蓝绿光波段的准直光束;接收端则通过光学带通滤波器进行波长选择与噪声抑制,并由光电探测器将光信号还原为电信号。而水下信道的光学特性与温度、盐度、水质、气泡等多参数强相关^[14-15];盐度与温度梯度引起折射率随机波动,导致光束闪烁与波前畸变;悬浮颗粒及溶解物质引发吸收与散射效应,造成能量衰减与脉冲展宽;气泡扰动进一步加剧信道非平稳性。这些因素共同导致UWOC信道呈现强非线性、时变性与非高斯分布特征。

传统研究多基于 Beer-Lambert 定律、辐射传输理论或蒙特卡洛仿真建立信道模型^[16-21],并采用线性均衡器进行补偿。然而,此类方法依赖理想线性假设或精确先验统计信息,在面对强湍流、动态散射等复杂场景时,易因模型失配导致性能瓶颈。为克服这一困难,数据驱动的DL方法被引入UWOC领域中,利用DL强大的非线性拟合能力,直接从数据中学习信道隐含的高维特征分布,无需依赖严格的解析模型假设,从而突破传统方法的性能上限。

1.2 UWOC信号处理流程与DL介入点

在上述物理架构支撑下,信息比特的端到端传输遵循严格的信号处理层级,主要涵盖发射端、水下信道及接收端3个关键环节^[7]。DL可灵活介入以下流程以突破传统算法瓶颈:

1)发射端。原始比特流首先进入信道编码模块,通过冗余映射提升传输可靠性;编码后比特经成帧处理,插入同步头与导频符号,为接收端同步与信道估计提供基准;帧封装后的信号送入调制模块,映射为适配光传输的符号序列,经驱动电路转换为驱动电流,最终驱动光源将电信号转换为蓝绿光准直光束发射至水下信道。在调制方式选择、发射功率分配与编码策略优化中,DL可根据信道状态动态调整发射端配置,增强链路对复杂水环境的适应性。

2)水下信道。光信号在水下传输时,吸收效应造成能量衰减,限制通信距离,散射效应引发光束扩散与信噪比降低,温度、盐度变化与气泡扰动带来的湍流效应进一步导致光强波动与波形畸变,接收端仅能获取被信道污染、叠加噪声的失真信号。水下信道的复杂畸变难以用精确物理模型完整表征,借助DL的自适应特征学习与非线性拟合手段,可实现对信道衰减、散射与湍流效应的精准感知与建模,为接收端补偿校正提供可靠依据。

3)接收端。接收端通过光学带通滤波器完成波长选择与噪声抑制,光电探测器将光信号转换为电信号,经放大与模数采样后得到数字信号序列;同步模块利用同步头完成相位与频率偏移补偿,同步后的基带信号进入信道估计与均衡环节,依托导频符号获取信道状态并抑制码间干扰;后续经信号检测、解调与信道解码,最终还原原始信息比特。针对信道估计精度不足、信号检测鲁棒性差、调制格式与模态识别易受干扰等问题,基于数据驱动的DL方法可将信道估计、均衡、检测、识别等模块融合优化,直接以系统传输性能为目标完成端到端信号恢复,有效突破传统方法在强干扰、动态信道下的性能瓶颈。

1.3 DL与UWOC信号处理的内在契合

DL作为机器学习的重要分支,通过构建包含输入层、多层隐藏层及输出层的深层神经网络,实现从原始数据到高层抽象特征的逐层非线性映射^[9-10]。与传统浅层学习依赖人工特征提取不同,DL能够利用海量数据自动学习最优特征表示,具备强大的复杂函数逼近能力。在UWOC领域,DL的网络架构特性与水下信道信号处理需求存在深刻的内在契合,主要体现在以下3个维度:

1)非线性畸变补偿与空间特征提取。水下信道的吸收、散射及湍流效应导致接收信号呈现强烈的非线性畸变。卷积核作为卷积神经网络(CNN)的核心计算单元,本质是一组可训练的自适应滤波器系数。对接收信号执行一维卷积,在数学上等效于进行一次滤波器处理,但区别于传统固定系数的匹配滤波器,CNN通过反向传播算法最小化损失函数,自动更新卷积核参数以抑制信道干扰。此外,在处理时频图、星座图或OAM光强分布等二维信号时,CNN的局部感受野与权值共享机制能高效提取空间判别性特征,有效应对模态串扰与波前畸变。

2)长记忆效应建模与时序依赖捕捉。散射引起的光脉冲展宽使得水下信道具有显著的长记忆效应,码间干扰(ISI)往往跨越数十个符号周期。传统时域均衡器受限于抽头长度,难以有效建模此类远距离依赖关系。循环神经网络及其变体长短时记忆网络(LSTM)和门控循环单元(GRU),通过引入门控机制实现历史状态的选择性保留与遗忘,从而显式地对信道的记忆效应进行非线性建模。特别是双向结构(BiLSTM/BiGRU),能同时利用当前时刻的前向与后向信息,在信道估计任务中实现对非导频位置信道响应的精确插值重构。

3)端到端全局优化与误差累积抑制。传统接收机采用模块化设计,各环节指标不一致易导致误差的传播与累积。DL支持构建端到端通信系统,将调制、信道传输和解调视为一个整体黑盒。以恢复比特流的均方误差(MSE)损失或交叉熵等可微指标作为损失函数,梯度可反向传播至网络每一层,迫使各隐藏层学习到对最终通信性能最有利的中间表征。这种全局优化机制打破了传统模块化的性能瓶颈,显著提升了系统在复杂动态环境下的鲁棒性。

综上所述,DL凭借其在非线性拟合、时序建模及全局优化方面的独特优势,为突破UWOC传统物理模型限制提供了全新的技术路径。

2 基于DL的UWOC关键技术研究进展

UWOC信号在实际传输中,受海水吸收、散射、湍流等复杂环境因素影响,信道呈现出强烈的非线性、时变性与非平稳特征。传统信号处理方法因依赖线性假设与精确先验统计信息,在精准信道估计、干扰抑制及可靠性提升等方面面临性能瓶颈。相比之下,DL凭借强大的非线性拟合能力、自适应特征提取优势及数据驱动建模机制,能够有效突破传统算法对物理模型精度的依赖,为UWOC系统核心模块的性能优化提供了全新路径。鉴于此,本文围绕信道估计、信号检测、调制格式识别、OAM模态识别及组网优化五大关键技术方向,系统梳理了DL赋能UWOC的最新研究进展与应用成果。

2.1 信道估计

在UWOC系统中,信道估计旨在从接收信号中恢复信道状态信息,为后续信号恢复提供依据。经典的信道估计算法如最小二乘(LS)和最小均方误差(MMSE)各有局限:LS算法结构简单、计算量小,但对噪声敏感且易过拟合;MMSE算法虽抗噪能力强、理论最优,但需统计先验且计算复杂。为降低复杂度,线性最小均方误差(LMMSE)算法被应用于正交频分复用(OFDM)系统,但其性能仍高度依赖准确的信道自相关矩阵^[21]。这些传统算法难以充分挖掘信道的内在结构特征,在水声或水下光等具有天然稀疏或多径结构的信道中存在固有瓶颈^[23]。此外,LMMSE作为线性估计方法,即使获知失真项的二阶统计信息,本质上仍将失真视为独立的有色噪声处理;然而,实际硬件中的非线性失真与发射信号间存在复杂耦合关系,无法等效建模为加性噪声模型^[24]。

针对传统方法的不足,DL通过数据驱动方式展现

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

出显著优势。为了充分利用信道的频域相关性,倪文正等人^[25]提出了一种结合双向长短期记忆网络(BiLSTM)与自注意力机制的信道估计方法。该方法将子载波索引作为序列维度,利用BiLSTM的前向与后向单元捕捉频域响应的长距离相关性,推断非导频位置的信道状态;同时引入自注意力机制计算子载波特征的权重,最后通过深度神经网络(DNN)对发射与接收信号间的复杂非线性关系进行拟合。实验表明,在低导频开销且无循环前缀辅助的极端条件下,该网络仍能维持较低的BER。

在此基础上,Priyalakshmi B^[26]进一步拓展思路,提出了名为JCESR-Net的网络,将信道估计与信号恢复深度融合。该方案采用多级二阶注意力网络结合多池化方法进行信道估计,通过二阶特征统计量捕捉信道间的复杂相关性,并引入深度树训练分类器实现水体类型的精确判别;随后构建生成对抗信号检测网络,其中生成器根据估计的信道信息恢复原始信号,判别器评估恢复信号的真实性和真实性,两者通过对抗训练提升检测精度。实验结果显示,该方案在不同水体类型下的信噪比增益均优于传统的DNN、LS和LMMSE方法。

然而,DL辅助接收机通常采用“离线训练、在线部署”模式。当实际信道环境与训练环境不匹配时,性能会严重下降,而重新采集数据并训练模型耗时耗力,难以快速适应新环境。为解决这一动态适配问题,王新歌^[27]提出了基于模型不可知元学习的DNN接收机。该方法在多类水质上进行元训练,学习一组通用且泛化能力强的初始化参数;当部署至未知新环境时,仅需使用少量数据进行梯度微调即可快速适应新信道,无需从头训练,有效解决了DL接收机在动态水下环境中的适配难题。

除了电信号处理,Jia Yan等人^[28]突破了传统导频辅助的信道估计框架,提出了一种基于机器视觉的智能湍流感知机制。该机制借助光学成像与光通信的物理关联,通过相机实时捕捉光束传播图像,建立光束图像像素强度变化与闪烁指数的精确量化关系。实验结果显示,在温盐梯度主导的湍流条件下,该方法获得的闪烁指数与传统光电探测器采样数据的RMSE仅为0.015;在气泡与温度梯度共同作用的湍流条件下,RMSE仅为0.028 5。该方法无需插入导频信息,避免了频谱资源的额外消耗,为信道状态感知提供了全新的非接触式解决方案。

2.2 信号检测

信号检测是接收端的核心环节,其目标是从受信

道污染和噪声干扰的接收波形中准确恢复原始信息。传统检测方法(如自适应阈值法或线性均衡器)在强湍流或非线性失真下性能受限。DL通过构建可训练的非线性映射网络,直接学习接收信号与发送符号间的复杂关系,为提升检测精度与系统鲁棒性提供了高效路径。根据应用场景与网络架构的不同,现有研究主要聚焦于以下3个方向:

1)面向单载波与复杂接收机的非线性检测优化。针对广泛应用的单载波开关键控(OOK)系统,传统自适应阈值法在强湍流下易因判决门限漂移导致BER恶化。叶鹏飞^[29]构建了综合吸收、散射及湍流效应的信道模型,利用DNN直接拟合接收电平与发送比特的非线性映射。仿真与实验表明,在5 Mbit/s速率下,DNN在3种实验信道中均优于传统阈值法,水流信道接收光功率为-18 dBm时BER改善达2个数量级。对于弱光长距离场景,单光子雪崩二极管(SPAD)接收机虽灵敏度高,但存在严重的信号相关噪声(SDN)与硬件非线性失真。Xie Sheng等人^[30]提出嵌入SDN方差的DNN检测方案,将接收信号与SDN方差联合输入,通过双输出结构同步实现均衡与比特判决。在清澈海水中,当传输距离为90~110 m时,该方案使BER稳定保持在 3.8×10^{-3} 以下,有效克服了SPAD的非理想特性。

为平衡检测性能与计算开销,研究者致力于网络结构的轻量化与加速。Chi Nan等人^[31]针对传统DNN收敛慢的问题,提出高斯核辅助深度神经网络(GK-DNN)。通过在隐藏层引入高斯核对接收序列进行加权预处理,使网络更快聚焦有效特征。在传输距离为1.2 m的盐水8阶脉冲幅度调制(PAM8)实验中,GK-DNN训练迭代次数减少47.06%,最终BER较普通DNN降低约25%,且性能优于Volterra均衡器。Sheikhian M H等人^[32]则设计了仅含全连接层的轻量级4层多层感知机均衡器(MLP),结合缩放指数线性单元(SELU)激活函数与Adam优化器实现快速收敛。实验表明,该方法在20 Mbit/s 16阶正交幅度调制(16QAM)和30 Mbit/s (PAM8)速率下BER能够降低1~2个数量级,推理时间低于1.25 s,满足资源受限边缘设备的实时性需求。

2)导频受限与无循环前缀(CP)的极端场景恢复。常规研究多基于充足导频与CP假设,但实际UWOC系统常面临频谱资源紧张或延迟敏感问题。石佳等人^[33]针对导频开销受限与CP缺失2种极端场景,提出端到端DNN联合信道估计与信号检测方案。该架构跳过传统显式均衡步骤,直接从频域接收信号映射至

比特流,自动学习信道逆特性。实验表明,当导频数从64锐减至8时,传统MMSE性能急剧恶化,而DNN仍能维持较低BER;在完全去除CP导致严重子载波间干扰(ICI)时,传统正交性假设失效,DNN则凭借隐式建模能力依然有效工作,展现出极强的鲁棒性。

3)动态未知水体的自适应分类与联合检测。水下信道随深度、浊度及温盐分布剧烈变化,单一固定模型难以跨场景泛化。为此,研究者引入“先分类、后检测”的自适应框架。Lu Huaiyin等人^[34]提出DL辅助的联合信道分类与信号检测架构,前置CNN模块实时识别水体类型并输出概率权重,对多个预训练检测网络的结果进行自适应加权融合,显著提升了接收机在多变水域的鲁棒性。Xu Kaidi等人^[35]进一步优化该思路,提出LCNN-BiLSTM网络。该方案利用LSTM在线识别当前信道类型,动态调用匹配的CNN-BiLSTM子模型进行联合特征提取与信号恢复。在直流偏置光正交频分复用(DCO-OFDM)系统中,该方法无需大量导频与复杂均衡,即可同步建模信号局部空间特征与双向长时序依赖,兼容7种不同水质与传输距离。相较于传统LS/MMSE算法,该方案大幅降低了导频开销与高散射、强ISI下的估计误差,尤其在远距离、高码率、高浊度恶劣信道中优势突出。

综上所述,DL在UWOC信号检测中已呈现出从“单一非线性拟合”向“极端场景鲁棒恢复”及“动态环境自适应”演进的趋势。DNN及其变体有效克服了传统线性均衡器在强湍流下的性能瓶颈;端到端架构突破了导频与CP的资源约束;而基于分类-检测联合的自适应框架则解决了跨水质泛化难题。未来研究需进一步关注模型在高速实时处理中的算力能效比优化、小样本条件下的快速适配机制,以及与其他物理层模块(如信道估计)的更深层次联合设计,以实现复杂动态水下环境中的极致检测性能。表1系统对比了上述信号检测方法的核心特性与适用场景。

2.3 调制格式识别

为提高UWOC系统的频谱效率与传输容量,QAM、幅度相位键控(AMPSK)等高阶调制格式被广泛引入。接收端准确识别发射端所采用的调制格式,是实现自适应解调与信息可靠恢复的关键。然而,海洋湍流引起的信号幅度起伏与相位抖动,叠加发射机非线性失真,导致接收星座图发生严重畸变与轨迹重叠,传统基于人工特征(如高阶累积量、直方图阈值)的识别方法在复杂信道下鲁棒性急剧下降^[36-37]。DL通过端到端网络自动提取信号的时频域分布、高阶统计

表1 相关文献中信号检测方法对比

方法	优点	局限性	适用场景
DNN ^[29]	无需精确信道模型,直接拟合从接收电平到发送比特的非线性映射	依赖大量标注训练数据,单一网络在多信道数据上训练时效果较差	中低速、短距离链路,信道特性相对稳定
DNN-SDN ^[30]	无需精确的信道状态信息,能够针对SPAD的非线性失真和SDN进行补偿	需要预先建立SPAD的精确统计噪声模型以生成训练数据。	SPAD接收机、长距离弱光链路
GK-DNN ^[31]	高斯核使网络更快聚焦局部有效特征,加速训练收敛	核函数参数需根据信道非线性程度手工设定,输入特征数量需人工优化	中高速、短距离链路
MLP ^[32]	参数量小,推理延迟低,与传统判决反馈均衡器相比BER降低	模型复杂度显著高于传统判决反馈均衡器	资源受限的边缘设备、低延迟系统
端到端DNN ^[33]	导频开销极低,不依赖CP,鲁棒性更好	网络设计难度高,隐式信道估计的有效性难以验证	导频受限、CP缺失的极端场景
分段联合检测 ^[34-35]	自适应多种水体,鲁棒性强,无需人工切换	需多类型数据与多个预训练模型,结构较复杂	信道类型实时未知场景

量及非线性流形特征,构建高维分类边界,为UWOC调制格式识别(MFR)提供了全新范式。根据网络设计导向与应用场景的不同,现有研究主要聚焦于以下3个方向:

1)基于特征空间变换与时序建模的识别。常规IQ信号在直角坐标系下受湍流相位噪声影响易发生旋转与扩散,导致相邻调制簇难以区分。高文笛等人^[38]提出将接收IQ信号从直角坐标系转换至极坐标系,利用极坐标天然分离幅度与相位的特性抑制湍流引起的联合抖动,随后将极坐标特征序列输入双向门控循环单元(BiGRU)网络捕获长时序依赖关系。在2QAM至64APSK共10种调制格式的识别任务中,该算法在不同发射电压条件下识别准确率均超过96%,且在低信噪比与非线性失真环境下展现出显著鲁棒性,验证了“坐标变换+时序建模”在解耦信道畸变方面的有效性。

2)面向资源受限节点的轻量化识别。水下终端

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

(如传感器、微型 AUV)算力与功耗严格受限,复杂 DL 模型难以部署。为突破模型复杂度瓶颈,研究者致力于轻量化架构设计。Yao Li 等人^[39]引入通信信息引导的知识蒸馏机制,利用高复杂度教师网络的全局特征分布指导仅由单层线性密集层构成的学生网络训练。实验表明,该超轻量级学生模型在识别 PAM4、QPSK、16QAM 等 8 种调制格式时推理准确率达 100%,参数量仅为教师模型的 18%,大幅降低了边缘侧部署门槛。Li Fujie 等人^[40]则采用储备池计算(Reservoir Computing)替代传统循环网络,结合坐标变换与折叠算法提取时序特征。该方法固定储备池权重,仅训练输出层连接,可训练参数仅为传统深度网络的 0.3%,对 OOK、4QAM 等 6 种调制格式识别准确率均超 90%,在超低算力场景下实现了精度与效率的平衡。

3)多域特征融合与强泛化架构。单一时域或频域特征难以全面表征多因素耦合信道畸变,多域协同与注意力机制成为提升泛化能力的关键。Zhang Yufeng 等人^[41]提出了时频融合 Transformer 架构,该方法首先融合 IQ 通道提取原始复信号特征,频域编码器对输入执行快速傅里叶变换后,经由可学习的复数权重矩阵实现自适应频带增强或抑制,再经逆变换返回时域;时域编码器则采用 ReLU 线性注意力机制捕捉全局时序依赖。在涵盖 19 种调制格式的水下数据集中,该网络在不同驱动电压条件下均表现出优异的泛化性能,即使在 0.05 V 驱动电压的极端非线性失真条件下,仍能达到 85.76% 的分类准确率,显著优于传统单域特征提取方法。

综上所述,DL 在 UWOC 调制格式识别中已从单一的特征工程替代,向轻量化部署、多域融合与强泛化方向演进。坐标变换有效解耦了相位噪声;知识蒸馏与储备池计算大幅压缩了模型参数量,契合水下节点的算力约束;而 Transformer 等多域融合架构则突破了极端非线性失真下的识别瓶颈。未来研究需进一步关注跨水质/跨距离数据集的零样本泛化能力、模型与自适应调制切换协议的协同设计,以及面向真实海况的在线增量学习机制。表 2 系统对比了上述调制格式识别方法的核心特性与适用场景。

2.4 OAM 模态识别

OAM 涡旋光束利用其螺旋波前携带的拓扑荷数实现空分复用,是突破 UWOC 系统容量瓶颈的关键技术。然而,水下信道中的吸收、散射及湍流效应会导致 OAM 光束发生严重的波前畸变、模态耦合与强度闪烁,使得接收端光强分布呈现非对称扩散或环形断

表 2 相关文献中不同调制格式识别方法对比

方法	优点	局限性	适用场景
BiGRU+坐标变换 ^[38]	使信号结构特征更显著,对非线性失真鲁棒性强,低信噪比下性能稳定	预处理步骤增加了系统前端的复杂度,计算量略增	需要准确识别 QAM 和 APSK 调制格式
知识蒸馏 ^[39]	轻量化,参数量小,推理速度快,蒸馏后保持高精度	学生模型特征提取能力弱,严重依赖教师质量	计算资源受限且需快速推理
储备池计算 ^[40]	结合坐标变换与折叠算法提取特征,训练参数极少,训练速度快	需要人工设计超参数和特征提取方式	计算资源受限且需快速推理
时频融合 Transformer ^[41]	频域编码器和时域编码器同时利用时域和频域信息,泛化能力强	Transformer 计算复杂度较高,相比轻量模型推理延迟更高	多种调制格式、多种场景通用识别

裂,传统基于相位展开或模式分解的方法难以实现高精度解复用^[42-44]。DL 通过从畸变光强图中自动提取高阶空间特征,构建鲁棒的分类边界,为 OAM 模态识别提供了全新范式。根据网络架构与设计导向的不同,现有研究主要聚焦于以下 4 个方向:

1)基础 CNN 架构与特征增强。早期研究证实了 CNN 在 OAM 解码中的可行性。Cui Xiaozhou 等人^[42-43]利用 LeNet-5 网络在水箱模拟环境中实现了拉盖尔-高斯光束的模态解码;Liu Wenyi 等人^[44]则进一步验证了 CNN 对海洋湍流信道中贝塞尔-高斯光束的有效识别。为解决单一特征提取能力不足的问题,Li Xiaoji 等人^[45]提出了一种基于 Adam 优化的双通道深度卷积神经网络-随机森林(DCNN-RF)模型。该模型分别提取 OAM 光强图的 RGB 颜色特征与 HSV 色彩空间的 V 通道亮度特征,通过多维度信息融合提升判别力,最后由随机森林分类器决策。实验表明,该方法在弱、中湍流环境下识别率达 100%,强湍流下仍保持 97%,在实际 OAM 实验系统中达到 99.5% 的高准确率。

2)全光学衍射神经网络(DDNN)。传统电学处理受限于光/电转换延迟与算力功耗。Zhan Haichao 等人^[46]提出了基于 DDNN 的全光学 OAM 识别方案。该方案利用多层被动衍射层在物理层直接以光速完成特征提取与分类,无需光/电转换与数字计算,推理延

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

迟极低。在无湍流环境下,其准确率达100%;即使在强湍流条件下,准确率仍维持在82.5%,显著优于传统电子CNN,展现出全光网络在抗湍流鲁棒性与实时处理方面的独特优势。此外,Xiong Jianmin 等人^[47](见2.5节)也利用DDNN实现了大视场聚焦接收,进一步拓展了全光学处理在降低对准要求方面的应用潜力。

3)复杂态识别与多任务协同。针对叠加态OAM模态简并难以区分的问题,Zeng Linzhou 等人^[48]提出基于深度残差网络(ResNet-50)的识别方案。通过在接收端引入3次相位板产生特定远场衍射图样,使原本强度相同的简并模式产生可区分特征。ResNet-50凭借强大的外推能力,能够准确预测训练集之外的未见叠加样本,为高维信息编码提供了新思路。Zhan Haichao 等人^[49]设计了基于孪生网络的多任务框架。2个权值共享子网络分别提取畸变光束光强图与湍流相位屏特征,一方面输出OAM模态类别,另一方面预测表征波前的Zernike多项式系数以辅助校正。孪生网络不依赖绝对类别标签,而是关注特征空间距离关系,因此在小样本或不平衡数据条件下仍能实现高精度识别,且响应速度显著快于传统迭代算法。

4)轻量化网络与小样本学习。为满足水下节点低功耗部署需求,Lu Yanyu 等人^[50]提出基于高效通道注意力(ECA)优化的轻量级MobileNetV1模型。该模型采用深度可分离卷积将标准卷积分解,使参数量较传统CNN减少约77%;同时,引入ECA模块自适应捕获跨通道关系,使网络聚焦于OAM光束的环形边缘与相位奇点等关键特征。实验表明,在小样本分类任务中,该模型在中等湍流下准确率达99.67%,在强散射环境中仍超过90%,有效抑制了小样本训练时的过拟合风险。

综上所述,DL在OAM模态识别任务中,逐渐向全光学处理、多任务协同及轻量化部署等方向演进。DCNN等多维融合架构有效克服了强湍流下的特征模糊;DDNN突破了电子算力的延迟瓶颈;ResNet与孪生网络解决了叠加态与小样本难题;而MobileNet等轻量化模型则契合了水下节点的工程约束。未来研究需进一步关注全光学器件的可重构性、叠加态模态的正交性保持机制,以及面向真实海况长时运行的在线自适应校正技术。表3系统对比了上述OAM模态识别方法的核心特性与适用场景。

2.5 组网优化

水下光通信在实际海洋应用中往往面向多节点、多终端协同传输场景,系统组网能力与链路稳定性是

表3 相关文献中不同OAM模态识别方法对比

方法	优点	局限性	适用场景
DCNN-RF ^[45]	多特征融合,对湍流畸变的鲁棒性更高,在弱、中、强湍流条件下识别准确率均较高	模型复杂,训练时间长,依赖大量图像数据及预处理步骤	湍流强度变化范围与温盐比变化范围较大的场景
DDNN ^[46]	全光学OAM识别,推理延迟极低,收敛快	硬件固定不可更新,对准精度要求极高,远距离下准确率显著下降	中低湍流强度、短距离传输,实时性要求极高的场景
ResNet-50 ^[48]	使用3次相位板解决模态简并,可识别多模叠加,且识别准确率较高	需额外光学元件,系统复杂度增加,且依赖大量图像数据	需区分OAM简并模式,可接受在接收端添加相位板的UWOC系统
孪生网络 ^[49]	小样本泛化能力强,不依赖每类大量样本,强湍流条件下识别准确率较高	需构造正负样本对,训练策略特殊,样本数据不均衡时,识别准确率显著下降	样本获取困难、实验数据有限的各种湍流环境
Mobile-NetV1 ^[50]	极小样本量,参数量小,训练时间短,强湍流、强散射下性能优秀	迁移学习能力不佳	极端小样本、环境噪声多变场景

保障可靠通信的关键。在AUV协作、水下传感器网络等典型应用中,移动节点间的光束快速捕获、精准指向与稳定跟踪,以及动态链路的自适应维持,成为制约系统整体性能的核心问题。传统组网的链路控制方法依赖精确的信道模型与人工调参策略,在复杂多变的海洋环境中适应性不足。近年来,DL为水下光通信组网优化提供了高效解决方案,相关研究主要聚焦于以下3个方向:

1)基于深度强化学习(DRL)的动态链路维持与协作。针对移动场景下光束对准难、链路易中断的问题,Li Mengzhen 等人^[51]提出了基于DRL的多AUV协作移动策略。该系统首先利用扩展卡尔曼滤波预测主AUV位置,再通过深度确定性策略梯度(DDPG)算法控制从AUV实时跟踪主AUV,实现移动中的光链路保持。针对目标下沉导致链路中断的难题,设计了基于双延迟深度确定性策略梯度(TD3)算法的自适应功率调整方案。仿真结果表明,所提算法使AUV间接收光

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

强稳定在 1.04×10^{-7} 量级,端到端 BER 维持在 10^{-7} 量级,较未调整时降低 4 个数量级。DRL 的引入使得 AUV 能够在复杂动态环境中通过与环境的持续交互,自主迭代优化控制策略,无需精确的数学模型,显著提升了组网的鲁棒性。

2) 基于计算机视觉的快速捕获对准跟踪 (APT)。在传统 APT 系统中,光斑识别易受水下散射、背景光及湍流干扰,导致对准精度低、跟踪速度慢。于是,Kong Meiwei 等人^[52]将 YOLOv5s 算法引入 UWOC-APT 系统,结合大面积太阳能电池板接收器,将识别目标从微小光斑转换为大面积太阳能板,有效解决了对准精度要求高和水下图像干扰大的难题。在 3 m 水槽中测试了不同浊度、气泡湍流和背景光条件下的系统性能,结果表明,系统平均指向时间仅 5.97 ms,平均跟踪时间为 229 ms,且在恶劣水下信道条件下仍能实现 1.76 Mbit/s 的数据传输速率。

Wu Minqi 等人^[53]进一步提出了基于视觉图神经网络的发光二极管 (LED) 光源检测网络 LSDNet。该网络通过多维混合协同注意力引导的局部稀疏动态图构建方法,有效抑制散射干扰和虚影光斑。在自建水下 LED 数据集上,其平均精度达到 97.2%,中心定位误差低于 5.41 像素,在 35 m 距离上实现了 BER 低于 10^{-8} 的可靠通信,较主流检测算法 YOLO11-S 提升一个数量级以上,展现了图神经网络在处理水下复杂视觉特征方面的优势。

3) 基于全光学衍射的大视场接收。传统接收机对光束入射角极其敏感,微小的对准偏差即导致信号丢失。Xiong Jianmin 等人^[47]提出利用 DDNN 实现大视场光信号的聚焦接收,从而降低对准要求。该网络以非正入射光作为处理对象,通过多层被动衍射单元对倾斜入射光施加等效相位预调制,使不同角度的光经全光学衍射后均汇聚至同一固定探测区域。仿真结果表明, $0^\circ \sim 60^\circ$ 倾斜入射光可聚焦至探测面 6.25% 的区域,平均聚焦效率达 93.15%。该方法有效缓解了 UWOC 系统的链路对准难题,为未来集成化、宽视场接收机设计提供了新思路,尤其适用于存在较大姿态抖动的移动组网场景。

综上所述,DL 在 UWOC 组网优化中已从单一的控制算法向视觉感知、全光学处理等多模态融合方向演进。DRL 有效解决了动态拓扑下的链路维持难题;YOLO/LSDNet 等视觉算法大幅提升了 APT 系统的速度与精度;而 DDNN 则从物理层突破了传统接收机的视场角限制。未来研究可进一步关注多节点协同下

的分布式智能决策、视觉-通信联合优化的跨层设计,以及全光学器件在真实海况下的长期稳定性与可重构性。表 4 系统对比了上述组网优化方法的核心特性与适用场景。

表 4 相关文献中不同组网优化方法对比

方法	优点	局限性	适用场景
DRL ^[51]	无需精确数学模型,自主迭代优化功率,保持接收光强稳定	调整距离依赖声信号辅助,状态空间设计复杂,多个权重系数需人工调优	水深和信道水质存在变化的移动 AUV 光链路
YOLOv5s ^[52]	识别目标从光斑转换为太阳能电池板,指向和跟踪速度更快,在恶劣条件下仍可建立链路	需重新训练以适应新环境;太阳能电池板的低带宽限制了通信速率	可接受太阳能电池板作为接收器且通信速率要求较低的 UWOC 系统
LSDNet ^[53]	多种注意力分支并行工作,在复杂水下环境中鲁棒性强	多种注意力模块的训练严重依赖大规模、多样化的标注数据集	存在多种干扰的水下 LED 光源检测
DDNN 大视场接收 ^[47]	多层衍射单元实现超大视场光聚焦接收,链路对准要求小,且无需光电转换,延迟低	接收光功率被严重衰减,系统的有灵敏度降低	发射端与接收端之间存在大角度倾斜且难以快速对准的移动平台

3 UWOC 应用展望

尽管 DL 在 UWOC 的信道估计、信号检测、调制格式识别及组网优化等方面取得了显著进展,但面对真实海洋环境的极端复杂性、动态时变性及资源受限约束,现有研究仍面临诸多挑战。未来研究需从算法架构创新、物理机理融合、数据生态构建及通信方式演进 4 个维度深入探索,以推动 DL 赋能 UWOC 从“实验室仿真”走向“工程化应用”。

3.1 模型轻量化与边缘侧实时部署

水下节点(如 AUV、海底传感器)通常受限于电池容量与嵌入式算力,难以支撑参数量庞大的深层神经网络。当前多数 DL 模型虽在离线测试中表现优异,但在实际部署中面临推理延迟高、能耗大的瓶颈。针对上述挑战,未来研究可重点从以下 3 个层面展开突破:

网络剪枝与量化:未来应重点研究面向 UWOC 特定任务的模型压缩技术,如结构化剪枝、权重量化,在保持精度的前提下大幅降低存储与计算开销。

神经架构搜索:利用自动化机器学习技术,针对水下信道特征自动搜索最优轻量级网络结构,替代人工设计,实现精度与效率的全局平衡。

存算一体硬件加速:结合新兴的存内计算芯片或现场可编程门阵列/专用集成电路(FPGA/ASIC)专用加速器,实现超低延迟信号处理,满足高速实时通信需求。

3.2 物理信息神经网络与可解释性增强

纯数据驱动的 DL 模型往往被视为“黑盒”,缺乏物理可解释性,且在训练数据分布之外的场景下泛化能力较弱。将光学传播机理融入 DL,是提升模型鲁棒性的关键路径。为提升模型的可解释性与泛化能力,未来应重点关注以下 2 个融合方向:

物理信息神经网络:将 Beer-Lambert 定律、辐射传输方程(RTE)或湍流相位屏模型作为硬约束或正则化项嵌入损失函数,迫使网络输出符合物理规律。这不仅减少了对大规模标注数据的依赖,还能显著提升模型在极端未见场景下的外推能力。

可解释性分析:通过注意力可视化、梯度反向计算等方法,解析 DL 模型在信号检测或模态识别中关注的关键特征区域,对比模型决策逻辑与光学物理规律的一致性,提升智能算法的可解释性与场景适配性。

3.3 数字孪生与高保真数据生态构建

高质量标注数据的匮乏是制约 DL 在 UWOC 领域发展的重要因素。真实海试成本高昂且环境不可控,导致现有数据集规模有限、场景覆盖单一。为构建高保真数据生态,未来可从数据生成、仿真平台及标准化建设 3 个方面着手:

基于生成式人工智能(AI)的数据增强:利用生成对抗网络或扩散模型,基于少量实测数据生成具有高保真度的合成信道样本,覆盖不同水质、湍流强度及传输距离组合,弥补实测数据场景分布不均的短板。

UWOC 数字孪生系统:构建包含光学、流体动力学的多物理场耦合数字孪生平台。在虚拟场景中预训练和验证 DL 算法,使数字模型与实际流域数据发生相互作用与交流,再迁移至真实环境进行微调,大幅降低海试风险与研发周期。

标准化开源数据集:可逐步完善 UWOC 领域基准测试数据集,涵盖多种调制格式、OAM 模态及组网场

景,为各类算法的横向对比与迭代优化提供数据支撑。

3.4 语义通信与跨层智能协同

为突破传统比特传输局限,未来 UWOC 可向以下 2 个高阶演进方向发展:

端到端语义编码:传统 UWOC 以比特可靠传输为核心目标,在带宽受限、BER 偏高的水下恶劣信道中,传统传输方式资源利用率偏低。引入语义通信机制,可在受限信道下针对性提升有效信息传输效率。结合自然语言处理(NLP)与计算机视觉(CV)技术,提取信源的关键语义特征进行压缩传输,接收端基于知识库重建信息。这种模式可一定程度上降低对信道质量的要求,提升有限带宽下的有效信息承载效率。

跨层联合优化:打破物理层、链路层与应用层的独立约束,利用 DL 实现跨层资源调度。例如,根据物理层信道状态信息动态调整 MAC 层的接入策略、网络层的路由选择及应用层的编码冗余配置,构建全局最优的智能水下光网络。

综上所述,未来 UWOC 的发展将是光通信技术与 AI 深度融合的过程。通过轻量化部署、物理机理融合、数字孪生赋能及语义通信革新,有望构建出具备自感知、自学习、自适应能力的下一代智能水下光通信系统,为海洋强国战略提供坚实的技术支撑。

4 结束语

DL 的引入为 UWOC 带来了新的变革。本文系统梳理了 2021—2026 年间的代表性成果,重点剖析了其在信道估计、信号检测、调制识别、OAM 模态识别及组网优化五大方向的应用机理。研究表明,数据驱动方法凭借强大的非线性拟合与时空建模能力,有效克服了复杂水下信道的动态畸变,在低导频、强湍流及跨域适配等场景中显著优于传统算法。

然而,现有研究仍面临真实海试数据匮乏、边缘算力约束及模型物理可解释性不足等瓶颈。未来需重点突破轻量化自适应架构、物理信息神经网络融合、数字孪生数据生态构建及语义通信跨层协同等关键技术。随着“数据-机理”双驱动范式的深化,下一代智能 UWOC 系统必将为海洋观测、资源开发及跨介质通信提供更高效、鲁棒的支撑,全面助力“海洋强国”战略实施。

参考文献:

[1] 孔美巍. 水下无线光通信系统的设计与实验研究[D]. 杭州:浙江大学

朱宏娜,刘仲涛,朱宇轩,等:深度学习赋能的水下无线光通信研究进展

学,2018.

[2] Elamassie M, Miramirkhani F, Uysal M. Performance characterization of underwater visible light communication[J]. IEEE Transactions on Communications, 2018, 67(1): 543-552.

[3] 石勇,李朝阳,李江勇. 水下无线光通信技术研究分析[J]. 激光与红外, 2025, 55(7): 1155-1162.

[4] Ali M F, Jayakody D N K, Chursin Y A, et al. Recent advances and future directions on underwater wireless communications[J]. Archives of Computational Methods in Engineering, 2020, 27(5): 1379-1412.

[5] Zhu Shijie, Chen Xinwei, Liu Xiaoyan, et al. Recent progress in and perspectives of underwater wireless optical communication[J]. Progress in Quantum Electronics, 2020, 73: 100274.

[6] 韩笑天,聂文超,李鹏,等. 水下无线光通信的研究现状与发展趋势分析(特邀)[J]. 光学学报, 2025, 45(13): 289-308.

[7] 黄诺,刘伟杰,徐正元. 水下无线光通信关键技术与应用展望综述(特邀)[J]. 光学学报, 2025, 45(13): 324-340.

[8] Ramley I, Alzayed H M, Al-Hadeethi Y, et al. An overview of underwater optical wireless communication channel simulations with a focus on the Monte Carlo method[J]. Mathematics, 2024, 12(24): 3904.

[9] Khurana D, Koli A, Khatter K, et al. Natural language processing: state of the art, current trends and challenges[J]. Multimedia Tools and Applications, 2023, 82(3): 3713-3744.

[10] Guo Yanrong, Chen Tao. Semantic segmentation of RGBD images based on deep depth regression[J]. Pattern Recognition Letters, 2018, 109: 55-64.

[11] 成乐,刘悦,胡正良,等. 基于阵列的神经网络水声通信信号多参数联合估计算法[J]. 通信学报, 2025, 46(1): 67-78.

[12] 赵永胜,严志远,毛瑞霞,等. MEAS-YOLO:改进YOLOv5的水下目标智能检测算法[J]. 电子测量技术, 2024, 47(13): 183-190.

[13] Schirripa S G, Cozzella L, Leccese F. Underwater optical wireless communications: Overview[J]. Sensors, 2020, 20(8): 2261.

[14] Tian Pengfei, Chen Honglan, Wang Peiyao, et al. Absorption and scattering effects of Maalox, chlorophyll, and sea salt on a micro-LED-based underwater wireless optical communication[J]. Chinese Optics Letters, 2019, 17(10): 100010.

[15] Jamali M V, Mirani A, Parsay A, et al. Statistical studies of fading in underwater wireless optical channels in the presence of air bubble, temperature, and salinity random variations[J]. IEEE Transactions on Communications, 2018, 66(10): 4706-4723.

[16] Yu Panpan, Chen Xiaolong, Yuan Zhihong, et al. Underwater wireless optical oam-multiplexed data transmission in dynamic scattering environments[J]. Optics & Laser Technology, 2025, 192: 113896.

[17] Lu Jiangxin, Huang Nuo, Liu Weijie, et al. Lda-based signal detection method for underwater optical wireless communication system with pmt receiver[C]//IEEE. Proceedings of 2024 16th International Conference on Wireless Communications and Signal Processing (WCSP). Hefei: IEEE, 2024: 1013-1018.

[18] Kou Linlin, Yan Shenggang, Liu Jianguo, et al. The investigation of underwater wireless optical communication channel fading in multi-size particles, bubbles, and turbulence[J]. IEEE Internet of Things Journal, 2025, 12(24): 52293-52307.

[19] Zhu Yunzhou, Nie Huan, Liu Qian, et al. Research on the use of an ocean turbulence bubble simulation model to analyze wireless optical transmission characteristics[J]. Electronics, 2024, 13(13): 2626.

[20] Lou Yi, Cheng Julian, Nie Donghu, et al. Performance of vertical underwater wireless optical communications with cascaded layered modeling[J]. IEEE Transactions on Vehicular Technology, 2022, 71(5): 5651-5655.

[21] Xing Fangyuan, Tong Fei, Liu Xiaonan, et al. Precoding optimization for rate splitting enabled internet of underwater things over optical wireless underwater turbulent channels[J]. IEEE Internet of Things Journal, 2025, 12(14): 26782-26798.

[22] Van De Beek J J, Edfors O, Sandell M, et al. On channel estimation in OFDM systems[C]//IEEE. Proceedings of IEEE Vehicular Technology Conference. Chicago: IEEE, 1995: 815-819.

[23] 常清文,申晓红,常娟. OFDM水声通信系统信道估计算法应用研究[J]. 计算机工程与应用, 2013, 49(8): 85-87.

[24] Demir Ö T, Björnson E. Channel estimation under hardware impairments: Bayesian methods versus deep learning[C]//IEEE. Proceedings of 2019 16th International Symposium on Wireless Communication Systems (ISWCS). Oulu: IEEE, 2019: 193-197.

[25] 倪文正,梁赫西,丁新辰,等. 一种基于神经网络的水下光通信信道估计方法[J]. 激光与光电子学进展, 2026, 63(17): 1706005.

[26] Priyalakshmi B. JCER-Net: a joint channel estimation and signal recovery network for underwater optical communication with ADO-OFDM[J]. Wireless Networks, 2025, 31(7): 4541-4561.

[27] 王新歌. 基于深度学习的水下无线光通信信道估计与信号检测研究[D]. 大连: 大连理工大学, 2022.

[28] Jia Yan, Huang Zhitong, Xu Jie, et al. Machine vision-based intelligent turbulence perception for underwater wireless optical communication[J]. Chinese Optics Letters, 2025, 23(6): 060601.

[29] 叶鹏飞. 基于机器学习的水下光通信信号检测及处理算法研究[D]. 长春: 长春理工大学, 2024.

[30] Xie Sheng, Li Dan, Yan Dong, et al. Joint equalization-demodulation using deep neural networks with embedded signal-dependent noise variance for SPAD-based UWOC systems[J]. Applied Optics, 2026, 65(3): 755-764.

[31] Chi Nan, Zhao Yiheng, Shi Meng, et al. Gaussian kernel-aided deep neural network equalizer utilized in underwater PAM8 visible light communication system[J]. Optics Express, 2018, 26(20): 26700-26712.

[32] Sheikhan M H, Baghersalimi G, Goorani H. Deep learning-based UWOC systems employing MLP networks[J]. Physical Communication, 2025: 102831.

[33] 石佳,黄爱萍,陶林伟. 深度学习辅助水下光通信信道估计和信号检测[J]. 中国激光, 2022, 49(17): 95-102.

[34] Lu Huaiyin, Jiang Ming, Cheng Julian. Deep learning aided robust joint channel classification, channel estimation, and signal detection for underwater optical communication[J]. IEEE Transactions on Communications, 2020, 69(4): 2290-2303.

[35] Xu Kaidi, Tao Linwei, Huang Aiping. Research on channel estimation and ber of underwater wireless optical communication based on lcn-bilstm network[J/OL]. Optoelectronics Letters, 2026-01-21. <http://oelett>.

ijournals.cn/gdzkb/article/abstract/2025220.

- [36] 陈永豪. 基于深度学习的随机介质光场特征提取研究[D]. 沈阳: 沈阳理工大学, 2024.
- [37] 魏京浩. 基于深度学习的水下轨道角动量无线通信应用研究[D]. 杭州: 杭州电子科技大学, 2023.
- [38] 高文笛, 汪昀楷, 徐迟, 等. 基于BiGRU的水下可见光通信调制格式识别研究[J]. 光通信研究, 2025, 2(17): 26–32.
- [39] Yao Li, Li Fujie, Zhang Haoyu, et al. Modulation format recognition in a UVLC system based on an ultra-lightweight model with communication-informed knowledge distillation[J]. Optics Express, 2024, 32 (8) : 13095–13110.
- [40] Li Fujie, Lin Xianhao, Shi Jianyang, et al. Modulation format recognition in a UVLC system based on reservoir computing with coordinate transformation and folding algorithm[J]. Optics Express, 2023, 31 (11) : 17331–17344.
- [41] Zhang Yufeng, Zhu Xiao, Zhou Hongyu, et al. Strong generalizability neural network for modulation format recognition in multi-scenario visible light communications[J]. Chinese Optics Letters, 2026, 24 (4) : 040601.
- [42] Cui Xiaozhou, Yin Xiaoli, Chang Huan, et al. Analysis of an adaptive orbital angular momentum shift keying decoder based on machine learning under oceanic turbulence channels[J]. Optics Communications, 2018, 429: 138–143.
- [43] Cui Xiaozhou, Yin Xiaoli, Chang Huan, et al. Experimental study of machine-learning-based orbital angular momentum shift keying decoders in optical underwater channels[J]. Optics Communications, 2019, 452: 116–123.
- [44] Liu Wenyi, Jin Meng, Hao Yuan, et al. Efficient identification of orbital angular momentum modes carried by Bessel Gaussian beams in oceanic turbulence channels using convolutional neural network[J]. Optics

朱宏娜, 刘仲涛, 朱宇轩, 等: 深度学习赋能的水下无线光通信研究进展

- Communications, 2021, 498: 127251.
- [45] Li Xiaoji, Xuan Hanze, Huang Chen, et al. Orbital angular momentum mode recognition under ocean turbulence channel by DCNN-RF model based on Adma optimization[J]. Results in Physics, 2024, 63: 107875.
- [46] Zhan Haichao, Chen Bing, Peng Yixiang, et al. Diffraction deep neural network based orbital angular momentum mode recognition scheme in oceanic turbulence[J]. Chinese Physics B, 2023, 32(4): 044208.
- [47] Xiong Jianmin, Cheng Jingxuan, Deng Huan, et al. Implementation of large field-of-view detection for UWOC systems based on a diffractive deep neural network[J]. IEEE Photonics Journal, 2023, 15(3): 1–7.
- [48] Zeng Linzhou, Gao Yongchang, Tang Qiang, et al. Deep residual learning recognition of orbital angular momentum superpositions over oceanic turbulence using a cubic phase[J]. IEEE Journal of Quantum Electronics, 2023, 59(5): 1–10.
- [49] Zhan Haichao, Qu Yang, Wang Le, et al. Siamese network-based vortex beam correction and identification in oceanic turbulence[J]. Optics Express, 2026, 34(1): 281–294.
- [50] Lu Yanyu, Yang Dahai, Chen Xikun, et al. Research on the application of MobileNetV1 neural network model for small-sample OAM mode recognition[J]. Advanced Photonics Nexus, 2025, 4(6): 77–78.
- [51] Li Mengzhen, Luo Hanjiang, Tao Hang, et al. Collaborative multi-AUV optical communication via deep reinforcement learning[J]. IEEE Sensors Journal, 2024, 25(1): 1627–1640.
- [52] Kong Meiwei, Pan Yanyan, Zhou Hui, et al. Deep learning-based acquisition pointing and tracking for underwater wireless optical communication[J]. IEEE Photonics Technology Letters, 2024, 37(10): 555–558.
- [53] Wu Minqi, Liang Hexi, Li Hang, et al. LSDNet: a vision graph neural-network-based fast LED light source detector for UWOC systems[J]. Chinese Optics Letters, 2025, 23(12): 121102.