光电技术及应用

DOI: 10.16818/j.issn1001－5868.20251230001

基于RC-LLR网络的OFDM光通信系统解调优化算法

马博文，曹欣雨*

（河北地质大学 华信学院电子信息学院，石家庄 050073）

摘 要： 为提升系统的实时性能并降低传统正交频分复用（OFDM）系统中对数似然比（LLR）解调的计算复杂度，设计了一种基于储备池计算（RC）的OFDM光通信系统解调优化方法。该方法将接收信号进行归一化和四维特征扩展后输入储备池，利用储备池的非线性动态映射特性，将接收信号映射至高维特征空间，再利用稀疏连接的递归神经元完成状态更新。由于储备池参数固定，只需要通过岭回归训练输出权重，避免了反向传播的高复杂度，能够实现LLR的快速近似计算。仿真结果表明：在16QAM调制的AWGN信道下，RC-LLR在误码率为1×10^{-3}时的信噪比为14.69 dB，与理论最佳方案相差仅0.12 dB，单符号平均处理时间为2.01 μs。在80 km光纤传输场景中，其链路预算达27.90 dB，较MMSE硬判决方案提升3.57 dB。结果验证了所提方法兼具高精度、强鲁棒性与优异实时性，为高速光通信系统的智能化、低时延解调提供了优化方案。

关键词： OFDM；光通信；储备池计算；对数似然比；解调优化

中图分类号： TN929.11 **文章编号：** 1001－5868(2026)02－0396－11

Demodulation Optimization Algorithm for OFDM Optical Communication System Based on RC-LLR Network

MA Bowen, CAO Xinyu

(**School of Electronic Information, Huaxin College of Hebei Geo University, Shijiazhuang 050073, CHN**)

Abstract: To enhance the real-time performance and reduce the computational complexity of log-likelihood ratio (LLR) demodulation in conventional orthogonal frequency-division multiplexing (OFDM) systems, a reservoir computing (RC) based demodulation optimization method is proposed for optical OFDM optical communication systems. In this approach, the received signals are first normalized and extended using four-dimensional features before being fed into a reservoir. The nonlinear dynamic mapping properties of the reservoir are then exploited to project the signals onto a high-dimensional feature space, where sparsely connected recurrent neurons perform state updates. Because the reservoir parameters remain fixed, only the output weights must be trained via ridge regression, circumventing the high complexity of backpropagation and enabling rapid LLR approximation. Simulation results demonstrate that under 16QAM modulation in an AWGN channel, the RC-LLR method achieves a signal-to-noise ratio of 14.69 dB at a bit error rate of 1×10^{-3}, deviating from the theoretical optimum by only 0.12 dB, with an average per-symbol processing time of 2.01 μs. In an 80 km fiber transmission scenario, a link budget of 27.90 dB is attained,

收稿日期：2025－12－30.

基金项目：2024年度河北省自然科学基金项目（A2024205006）.

* **通信作者：**曹欣雨

representing a 3.57 dB improvement over the MMSE hard-decision scheme. These results confirm that the proposed method provides high accuracy, robustness, and excellent real-time performance, offering an efficient solution for intelligent low-latency demodulation in high-speed optical communication systems.

Key words: OFDM; optical communication; reservoir computing; log-likelihood ratio; demodulation

0 引言

随着现代社会的不断发展，全球数据流量的传输需求呈现爆发式增长，光通信系统成为支撑信息传输的核心设施[1]。正交频分复用（OFDM）因其频谱效率高、抗色散能力强，被广泛应用于光通信系统中[2]。Song等将OFDM用于无源光网络传输，通过混沌序列控制子频段的数量和大小，将信号灵敏度提高了3.3 dB，并显著提升了安全性[3]。然而，在高速传输场景下，OFDM容易受光纤色散、非线性效应及噪声干扰的影响，导致接收端的信号解调性能下降[4]。基于此，研究者提出了多种优化方法以提升系统解调精度和鲁棒性。例如，Qasaymeh针对OFDM的载波频率偏移问题，提出一种基于前馈神经网络的估计方法，该方法可通过输入特征精确估计连续参数，并在低信噪比（SNR）的条件下保持较高的解调精度[5]。Babaroglu等则将数字后失真技术与最大似然（ML）准则相结合，并用于OFDM预编码，通过基于真实参考信号的参数估计增强接收信号，从而提升系统能效[6]。由此可见，现有算法虽提升了OFDM解调性能，但计算复杂度随调制阶数和子载波数呈指数级增长，仍难以满足高速光通信的实时处理需求。

另一方面，对数似然比（LLR）作为软判决译码的核心指标，能够为信道译码器提供可靠性信息，在误码率（BER）优化与信号恢复中发挥着重要作用[7]。Tan等结合LLR对解调器进行了相位噪声导向，证明其能够有效降低OFDM的BER[8]。然而，传统LLR的计算复杂度较高，且在强非线性和低SNR场景下容易受到限制[9]。储备池计算（RC）作为新型递归神经网络，其训练简单、非线性映射能力强，在时序信号处理和信道均衡等领域展现出良好的应用潜力[10]。黎祥远等通过平衡与分段处理后的训练数据为输入，采用RC优化深度学习模型的并行训练以提升训练效率，结果表明RC优化后的模型损失更小、收敛更快，且更早趋于稳定[11]。与传统方法相比，RC的核心优势在于其固定随机储备池设计，仅需通过简单的岭回归训练输出层权重，避免了反向传播的高复杂度。同时，RC的稀疏随机连接结构对硬件实现更加友好，适用于实时部署[12]。因此，如果采用RC辅助LLR计算，可以在保持较优解调性能的同时降低计算复杂度，为OFDM光通信系统的解调提供新思路。然而，标准RC面向通用时序任务设计，难以直接适配OFDM光通信系统。由于光纤色散会引起相位旋转，非线性克尔效应会导致幅相畸变，标准RC的二维输入无法有效解耦这两种失真；同时，标准RC的瞬时映射会忽略色散的记忆效应，OFDM的逐比特训练方法也会使开销随调制阶数线性增长，这限制了RC在高速光通信解调中的应用。

基于此，针对OFDM光纤信道的物理特性对RC进行适配性改进，设计了一种融合信道先验知识的RC-LLR网络。主要创新点包括：（1）引入幅相解耦的四维特征扩展机制，将接收信号的实部、虚部、幅度和相位同时输入储备池，以分别刻画色散与非线性失真；（2）设计滑动时间窗口与储备池的协同映射机制，利用RC的动态记忆特性建模色散的时序累积效应；（3）构建多比特位联合训练框架，通过矩阵化岭回归一次性学习全部比特位的输出权重，避免重复训练。研究旨在为复杂的光纤信道条件实现低复杂度、高精度的软信息计算，为高速OFDM光通信系统提供兼具性能与实时性的解调方案。

1 OFDM光通信与LLR解调原理

1.1 OFDM技术与光通信系统

OFDM技术的核心是将高速数据流分解为多个低速子数据流，分别调制到相互正交的子载波上并行传输。与传统的频分复用（FDM）不同，OFDM允许各子载波频谱相互重叠，从而大幅提高频谱利用率。FDM与OFDM频谱对比如图1所示。

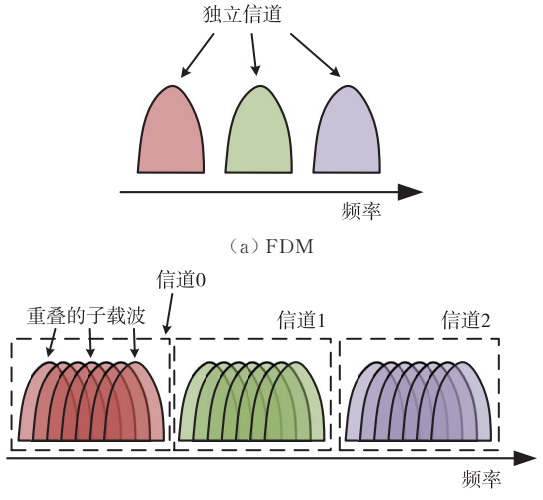


图1 FDM与OFDM频谱对比

从图中可以看出,OFDM能够通过子载波间的正交性实现频谱的高效利用,使其在光通信系统中具备优势[13]。在光通信系统中,OFDM的发送端将数据经串并转换、子载波调制和逆快速傅里叶变换后,通过电光转换注入光纤信道,接收端则经光电检测、快速傅里叶变换恢复频域信号[14]。然而,光纤信道的色散效应和非线性克尔效应会导致信道频率响应产生幅度和相位畸变,从而使接收端的符号检测和解调面临挑战。

1.2 LLR解调原理与计算复杂度

LLR作为软判决译码的核心指标,通过量化各比特取值为1或0的置信度,并将该信息传递给信道译码器,从而实现信号恢复。LLR定义为比特b_i为1与为0的后验概率之比的对数,基于ML准则,其在计算时需遍历所有可能的发送符号并累加其似然值[15]。计算式为:

$$LLR(b_i)=\ln\frac{\sum_{x\in\chi_i^1}\exp\left(-\frac{\left|Y[k]-H[k]x\right|^2}{2\sigma^2}\right)}{\sum_{x\in\chi_i^0}\exp\left(-\frac{\left|Y[k]-H[k]x\right|^2}{2\sigma^2}\right)} \tag{1}$$

式中,χ_i^1与χ_i^0分别为第i比特位为1和0的符号集合,$Y[k]$为接收信号,σ^2为噪声方差。对于采用M阶调制的系统,每个子载波的LLR计算复杂度为$O(M)$,总复杂度为$O(NmM)$。当采用高阶调制时,计算量将会呈指数级增长。此外,光纤的非线性效应导致信道估计偏差,进一步降低了传统LLR方法的解调性能。

2 基于RC-LLR网络的OFDM解调优化

2.1 RC-LLR网络架构设计

为解决传统LLR在复杂光通信系统中的计算和适应性,提出利用RC对接收信号特征进行建模,实现对LLR计算的高效近似与优化,构建RC-LLR网络并将其用于OFDM光通信系统的解调优化。首先,RC是通过非线性动态映射将接收信号转换至高维特征状态空间,从而增强LLR对复杂信道的表达能力,映射前后对比如图2所示。

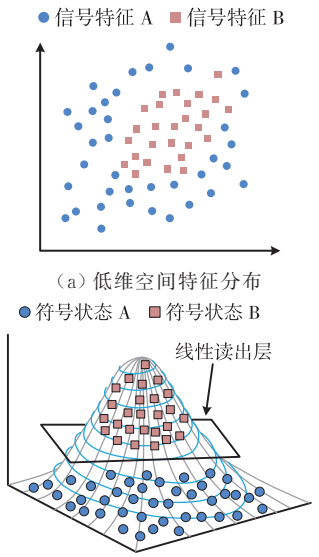


图2 非线性动态映射前后对比

在图2(a)的低维特征空间中,不同符号的特征相互混叠,无法通过线性方法进行区分。经非线性动态映射,这些特征被投影至图2(b)中的高维状态空间,在该空间中隐式编码信道特性和符号状态信息,将复杂的ML-LLR计算转化为简单的线性加权过程[16]。映射的核心在于RC储备池中的K个稀疏连接的非线性神经元,其n时刻的状态向量$\boldsymbol{h}(n)$为:

$$\begin{aligned}\boldsymbol{h}(n)=&(1-\alpha)\boldsymbol{h}(n-1)+\\&\alpha f\left[\boldsymbol{W}_{\text{res}}\boldsymbol{h}(n-1)+\boldsymbol{W}_{\text{in}}\boldsymbol{u}(n)\right]\end{aligned} \tag{2}$$

式中,$\boldsymbol{W}_{\text{res}}$为储备池的内部连接权重矩阵,连接密度为5%~10%;α为泄漏率参数,用于控制储备池对历史状态的记忆程度;$\boldsymbol{W}_{\text{in}}$为输入权重矩阵;$f(\cdot)$为非线性激活函数。对OFDM中的接收信号$Y[k]$,RC在输入层将其分解为二维实数向量$\boldsymbol{u}(n)=[\text{Re}(Y[k]),\text{Im}(Y[k])]^{\text{T}}$。RC的基本结构如图3所示。

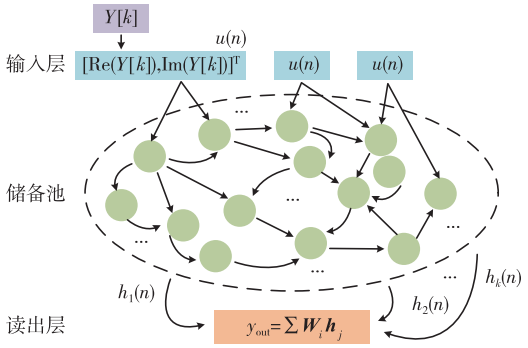


图 3　RC 基本结构示意图

图 3 中，RC 的输入层将 $Y[k]$ 的实部和虚部信息的复数信号分解为二维实数向量，经 K 个神经元进行状态更新，以状态向量的形式来到读出层，在此对这些高维状态进行线性加权，得到最终输出。储备池的稀疏连接结构和随机权重设计使 RC 具备丰富的动态行为，从而能够提取光纤信道中的非线性失真特征[17]。而储备池的稳定性和动态行为由内部连接矩阵的谱半径决定，谱半径为矩阵所有特征值中模最大者的绝对值，其定义及约束式为：

$$\begin{cases}\rho(\boldsymbol{W}_{\text{res}})=\max\limits_{i=1,\cdots,k}\left|\lambda_i(\boldsymbol{W}_{\text{res}})\right| \\ \rho(\boldsymbol{W}_{\text{res}})<\rho_{\text{target}},\ \rho_{\text{target}}\in[0.5,1.2]\end{cases} \tag{3}$$

式中，λ_i 为 $\boldsymbol{W}_{\text{res}}$ 的第 i 个特征值。较小的谱半径会使储备池趋于稳定，但动态响应较弱；较大则会增强动态性，但可能导致混沌行为。不同于传统的 ML-LLR，RC-LLR 利用储备池状态作为中间特征表示，通过状态向量的线性组合进行近似，计算式为：

$$LLR(b_i)\approx \boldsymbol{W}_{\text{out}}^{(i)}\boldsymbol{h}(n)+\beta_i \tag{4}$$

式中，$\boldsymbol{W}_{\text{out}}^{(i)}$ 为第 i 比特位对应的输出权重向量，β_i 为偏置项。在此过程中，储备池状态 $\boldsymbol{h}(n)$ 编码了接收信号的非线性特征，输出权重 $\boldsymbol{W}_{\text{out}}^{(i)}$ 则学习了从这些特征到 LLR 值的映射关系。这种线性读出机制将 LLR 计算的复杂度从传统的 $O(M)$ 降至 $O(K)$，储备池神经元 K 在实际应用中通常取 100～500，远小于高阶调制的星座点数 M。当 $M\geqslant 256$ 时，K 仍可保持在 300～500 范围内，此时 $O(K)$ 远小于 $O(M)$ 的优势更加显著。最后，为便于多个比特位的 LLR 同时计算，将所有比特位的输出权重组织成矩阵形式。定义 $\boldsymbol{W}_{\text{out}}\in\mathbb{R}^{m\times K}$，第 i 行为 $\boldsymbol{W}_{\text{out}}^{(i)}$，偏置向量 $\boldsymbol{\beta}=[\beta_0,\beta_1,\cdots,\beta_{m-1}]^{\text{T}}$，则所有比特位的 LLR 为：

$$\boldsymbol{L}(n)=\boldsymbol{W}_{\text{out}}\boldsymbol{h}(n)+\boldsymbol{\beta} \tag{5}$$

这种矩阵化表示简化了计算过程，还有利于后续的批量训练和并行处理。通过以上过程，研究设计的 RC-LLR 网络的运行流程如图 4 所示。

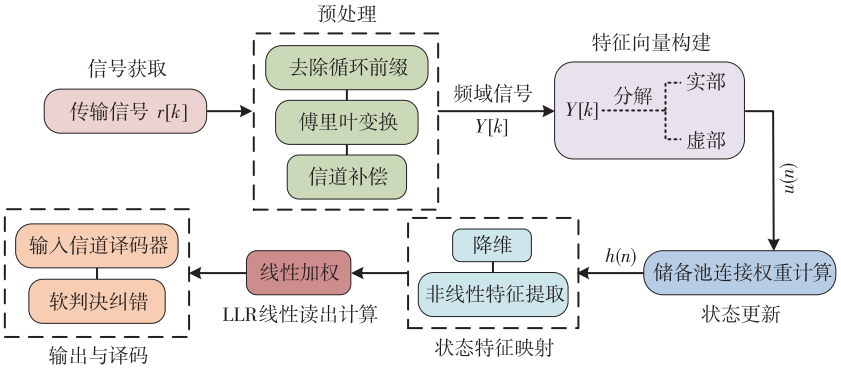


图 4　RC-LLR 网络运行流程图

图 4 中，RC-LLR 网络首先会对光纤传输的接收信号进行预处理与特征构建，再通过储备池计算完成动态非线性映射，提取信道特征信息。随后读出层根据储备池状态实现对 LLR 值的线性近似，输出的软信息被送入信道译码器完成最终的比特恢复。该网络的构建实现了从接收信号到软信息的高效映射，为后续的 OFDM 解调优化提供了基础。

2.2　基于 RC-LLR 的 OFDM 解调优化算法

在构建完成 RC-LLR 网络后，将其应用于 OFDM 光通信系统的接收端，替换传统的软判决模块。由于 RC-LLR 是以数据驱动的方式计算 LLR，不需要精确的信道估计，能够提升系统在非线性失真条件下的解调性能。在实际的 OFDM 光纤信道中，接收信号 $Y[k]$ 可表示为发送符号 $x[k]$ 经信道频率响应作用，并叠加复高斯噪声 $N[k]\sim(0,\sigma^2)$ 的结果，表现形式为[18]：

$$Y[k]=H[k]x[k]+N[k] \tag{6}$$

式中，$k\in\{1,2,\cdots,n\}$ 为子载波索引；$H[k]$ 表示信道频率响应，包含光纤色散和非线性效应的影响。RC-LLR 网络通过储备池的非线性映射能力隐式

地学习 $Y[k]$到LLR的映射关系，避免了传统解调中复杂的信道估计过程。为了更充分利用实际OFDM中接收信号的结构信息，对 $Y[k]$的特征进行扩展，其在复平面上的示意图如图5所示。

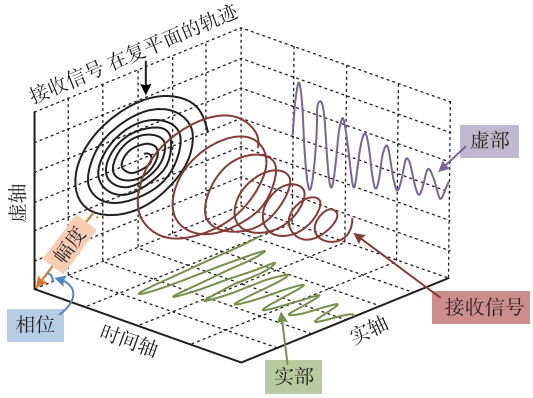


图5 时域轨迹及幅相特征示意图

由图5可以看到，信号在复平面上的位置由实部和虚部确定，其从原点到固定点的距离为幅度，该距离与实轴的夹角为相位。光纤色散主要导致相位畸变，而非线性克尔效应则同时影响幅度和相位[19]。为更好捕捉信号特征，提出四维特征扩展策略，在将 $Y[k]$分解为实部与虚部的基础上进一步构建包含幅度和相位的四维特征向量，即：

$$\boldsymbol{u}(k)=[\mathrm{Re}(Y[k]),\mathrm{Im}(Y[k]),\left|Y[k]\right|,\angle Y[k]]^{\mathrm{T}} \tag{7}$$

式中，$|\cdot|$表示复数模，$\angle$表示复数幅角。将幅度和相位作为独立输入维度，因为色散主要表现为线性相位旋转，而克尔非线性则同时调制幅度和相位，四维输入使储备池能够通过不同的神经元子集分别响应这两类失真，增强了对信道物理机制的表征能力。另外，在应用中，光纤色散具有显著的记忆效应，第 k个符号的接收状态不仅取决于当前发送符号，还受到前序符号的影响，标准RC虽具备动态记忆，但单时刻输入的瞬时映射难以充分利用这一先验。为此，研究设计了滑动窗口与储备池的联合建模机制，将连续 $L-1$个时刻的四维特征拼接输入，使储备池在高维空间中同时感知当前状态和历史轨迹，从而隐式建模色散的时序累积特性。这一过程如公式(8)所示：

$$\boldsymbol{u}_{(k)}^{\mathrm{ext}}=[\boldsymbol{u}_{(k)}^{\mathrm{T}},\boldsymbol{u}_{(k-1)}^{\mathrm{T}},\cdots,\boldsymbol{u}_{(k-L+1)}^{\mathrm{T}}]^{\mathrm{T}} \tag{8}$$

式中，L为时间窗口长度，用于控制储备池对历史信息的利用程度。L较大则能捕捉更长的时序依赖关系，但也会增加输入维度和计算开销[20]。光纤色散导致的符号间干扰范围由色散系数、传输距离和信号带宽决定。在80 km标准单模光纤场景下，色散时延约为1.36 ns，对应约5～6个符号周期，时间窗口 L设置为5能够覆盖约90%的符号间干扰能量。处理后的信号将用于网格训练，训练的核心是使基于储备池状态计算的LLR能够逼近真实的最优LLR。实验采用岭回归方法求解，同时加入正则化项防止过拟合，目标函数为：

$$\min_{\boldsymbol{W}_{\mathrm{out}},\boldsymbol{\beta}}\sum_{i=1}^{S}\left\|\boldsymbol{W}_{\mathrm{out}}\boldsymbol{h}_i+\boldsymbol{\beta}-\boldsymbol{L}_{\mathrm{true}}(i)\right\|^2+\gamma\left\|\boldsymbol{W}_{\mathrm{out}}\right\|_F^2 \tag{9}$$

式中，S为训练样本总数，$\boldsymbol{h}_i$为第 i个训练样本对应的储备池状态向量，γ为正则化系数，$\|\cdot\|_F$表示Frobenius范数。正则化项能够限制权重矩阵的规模，提高RC-LLR在未见数据上的泛化能力[21]。为了高效求解该目标函数，将所有训练样本的储备池状态按行堆叠成状态矩阵 $\boldsymbol{R}\in\mathbb{R}^{N_r\times N_r}$，将真实LLR值组织成矩阵 $\boldsymbol{L}_{\mathrm{true}}\in\mathbb{R}^{N_r\times m}$，其中 m为每个符号的比特数。基于矩阵形式，输出权重的闭式解可通过方程直接计算，即：

$$\boldsymbol{W}_{\mathrm{out}}=(\boldsymbol{R}^{\mathrm{T}}\boldsymbol{R}+\gamma\boldsymbol{I})^{-1}\boldsymbol{R}^{\mathrm{T}}\boldsymbol{L}_{\mathrm{true}} \tag{10}$$

式中，$\boldsymbol{I}\in\mathbb{R}^{N_r\times N_r}$为单位矩阵。在标准RC中，需要输出 $\log_2 M$个LLR值，通常采用逐比特独立训练策略，即为每个比特位训练一个独立的输出权重向量和偏置，这需要重复 M次训练过程。而提出的联合训练框架通过这一闭式解一次性完成所有比特位的权重学习，将复杂度降低至 $O(N_r^2N_t+N_r^3)$，相比传统解调中的迭代优化方法训练效率更高。同时，不同比特位对应的符号集合存在星座结构上的对称性和重叠性，而储备池状态编码的信道特征对所有比特位是共享的。这使矩阵的多个行向量在同一状态空间中协同优化，相比独立训练能够更充分地利用数据中的统计规律，从而提升泛化性能。在完成以上训练后，RC-LLR网络即可部署到OFDM接收端进行实时解调，优化的完整解调流程如图6所示。

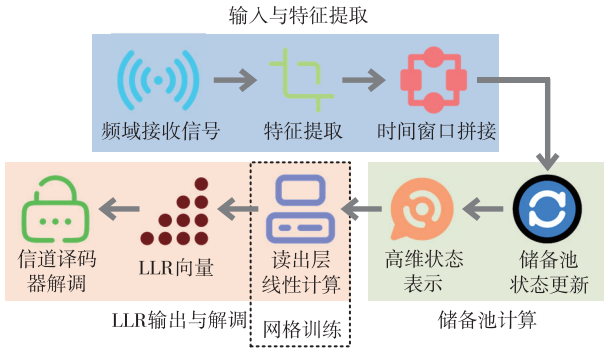


图6 基于RC-LLR的OFDM解调算法流程图

由图 6 可以看到，基于 RC-LLR 的解调过程包含三个核心步骤：特征提取、储备池计算和 LLR 输出。RC-LLR 首先针对 OFDM 光通信系统的色散和非线性特性设计了四维特征表示和时间窗口机制，通过数据驱动的岭回归训练学习信道到 LLR 的非线性映射，并将输出的 LLR 向量直接送入信道译码器进行迭代译码，以低复杂度的线性读出完成解调。综上所述，研究通过创新的 RC-LLR 网络为 OFDM 光通信系统的实时、高效解调提供了新的技术方案，实现了计算效率与解调性能的有效平衡。

3　仿真结果与应用分析

3.1　超参数敏感性分析结果

为评估 RC-LLR 对超参数的鲁棒性，对储备池规模、谱半径、泄漏率、时间窗口长度四个关键参数进行了敏感性分析。当各参数在基准值±20% 范围内变化时，系统在 1×10^{-3} 目标 BER 下的 SNR 需求，以及单符号处理时间和训练时间的变化如表 1 所示。

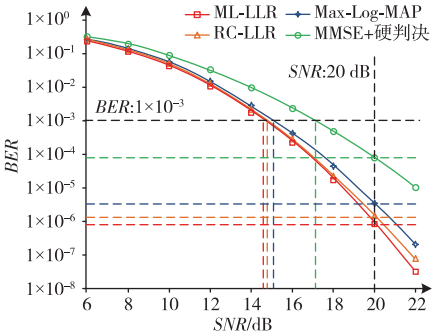
表 1　RC-LLR 超参数敏感性分析

参数	取值	*SNR*/dB	性能波动/dB	处理时间/μs	训练时间/min
储备池规模 K	240	14.97	+0.28	1.67	1.45
	300	14.69	基准	2.01	2.03
	360	14.61	−0.08	2.38	2.89
谱半径 ρ	0.76	14.84	+0.15	2.01	2.01
	0.95	14.69	基准	2.01	2.03
	1.14	14.91	+0.22	2.03	2.07
泄漏率 α	0.16	14.76	+0.07	2.00	2.02
	0.20	14.69	基准	2.01	2.03
	0.24	14.73	+0.04	2.02	2.04
时间窗口长度 L	3	14.89	+0.20	1.45	1.68
	5	14.69	基准	2.01	2.03
	7	14.63	−0.06	2.67	2.51

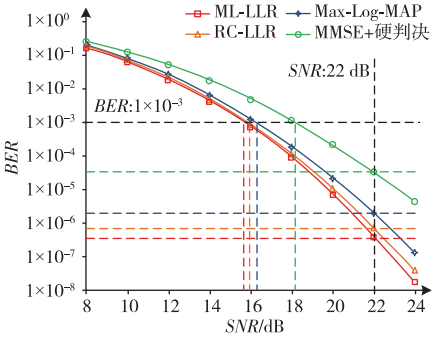
由表 1 可以看出，储备池规模对性能影响最显著，但即使 K 值从 300 降至 240，SNR 需求也仅从 14.69 dB 变化到 14.97 dB，增加 0.28 dB。谱半径在 0.76～1.14 的范围内，性能波动小于 0.22 dB。泄漏率的敏感性最低，波动仅 0.07 dB，这是因为时间窗口机制已显式提供了历史信息。当时间窗口 L 为 3 时会因历史信息不足，性能下降 0.20 dB；当 L 为 7 时虽改善 0.06 dB，但处理时间增加 0.66 μs，涨幅为 33%。因此，$L=5$ 是性能与效率的最佳取值。综上所述，在所有参数±20% 扰动下，SNR 波动不超过 0.28 dB，说明 RC-LLR 具有良好的参数鲁棒性。

3.2　误码性能与计算复杂度对比

为了验证 RC-LLR 网络的基础性能，首先对其误码性能与计算复杂度进行实验。仿真系统采用 128 个子载波的 OFDM 架构，调制方式 16 阶正交幅度调制 16QAM 和 64QAM。采用该调制方式的原因是其能提供足够的特征维度，并为未来扩展到更高阶调制预留空间。信道为标准加性高斯白噪声（AWGN）信道与 80 km 的线性色散信道。RC-LLR 网络的储备池规模设置为 300，谱半径为 0.95，泄漏率为 0.2，时间窗口长度为 5。实验硬件平台为 Intel Core i7-12700K 处理器、32 GB DDR4 内存。使用 ML-LLR 作为性能的理论上界，并加入最大对数最大后验概率（Max-Log-MAP）、最小均方误差（MMSE）均衡器结合硬判决两种方案进行对比。首先对四种方案在不同信道中 BER 与 SNR 的关系进行对比，结果如图 7 所示。



（a）AWGN 信道结果



（b）线性色散信道结果

图 7　16QAM 调制下的 BER-SNR 曲线对比

图 7(a)中，当 BER 为 1×10^{-3} 时，ML-LLR 作为理论最优方案，接收机的 SNR 为 14.57 dB。而 RC-LLR 通过储备池的非线性动态映射，在所有方案中最接近 ML-LLR，所需 SNR 为 14.69 dB，仅损失 0.12 dB，优于 Max-Log-MAP 的 0.53 dB。在 SNR 为 20 dB 的高 SNR 区间，RC-LLR 的 BER 为 1.53×

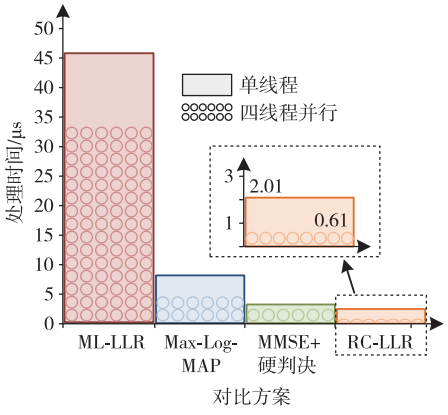
10^{-6}，仅次于ML-LLR的8.91×10^{-7}。图7(b)中，由于色散信道引入了符号间干扰，所有方案的误码率均有上升，Max-Log-MAP达到1×10^{-3}目标BER需要的SNR为16.21 dB，MMSE+硬判决由于缺乏软信息传递，需要18.06 dB，而RC-LLR仅需要15.98 dB，仍最接近ML-LLR。接下来对比各方案的计算复杂度，结果如表2所示。

表2 计算复杂度理论对比

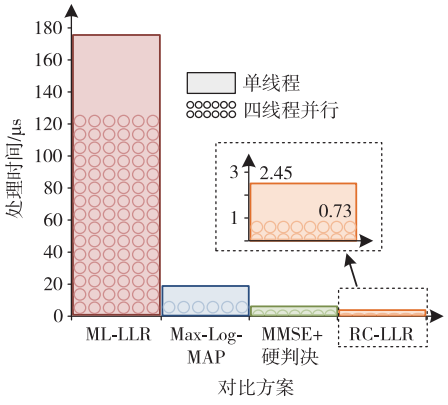
方案		计算次数	复杂度	计算模式	并行化潜力	硬件友好度
ML-LLR		131 072	$O(NM2^m)$	遍历星座点，计算指数/对数	低（强数据依赖）	低（复杂超越函数）
Max-Log-MAP		8 192	$O(NMm)$	遍历星座点，计算距离与最大值	中（子载波级并行）	中（含非线性操作）
MMSE+硬判决		32 768	$O(NM^2)$	矩阵求逆与乘法	低（矩阵求逆瓶颈）	低（不规则矩阵运算）
RC-LLR	推理	153 600	$O(NN_rm)$	纯线性加权（矩阵乘法）	高（全流程可并行）	高（纯线性计算）
	训练	2.4×10^6	$O(N_r^2N_t)$	纯矩阵运算		

从表2可以看到，ML-LLR的计算模式是遍历所有可能的发送符号并累加似然值，因此其计算次数与星座点数M呈指数关系，单个符号的乘法计算量超13万次，难以实时处理。而Max-Log-MAP通过对数域的最大值近似将复杂度降低至$O(NMm)$，但仍需要逐星座点计算距离与最大值，乘法次数为8 192次。MMSE+硬判决方案的复杂度主要源于信道矩阵的求逆和均衡操作，虽然计算次数最少，但这是一个复杂且难以并行化的过程，综合能力差。RC-LLR的推理阶段复杂度为$O(NN_rm)$，单符号处理需要约15万次运算，虽较高，但RC-LLR的计算均为简单的线性加权，可高度并行化且无需复杂的对数和指数计算，实际效率更高。此外，RC-LLR在训练中虽然需要约240万次运算，但这是一次性的离线过程，训练后的权重矩阵可长期使用，将此开销分摊到大量符号的处理中后几乎可以忽略不计。基于此，研究进一步在不同信道条件下对比了各方案的单符号平均处理时间，如图8所示。

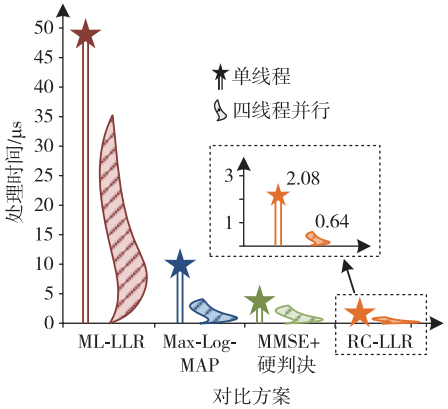
图8(a)和(b)中，在AWGN信道下，ML-LLR的单线程处理时间随调制阶数从45.67 μs增加至178.23 μs，即使采用四线程并行也需126.78 μs。Max-Log-MAP在两种调制下的单线计算时间分别为8.23 μs和18.91 μs，虽明显小于ML-LLR，但在三种优化方案中耗时最长，较RC-LLR的2.01 μs和2.45 μs分别增加了6.22 μs和16.46 μs。在图8(c)和(d)的线性色散信道实验中，四线程64QAM下ML-LLR运行时间增加至137.89 μs，Max-Log-MAP为11.23 μs，MMSE+硬判决为3.34 μs，而RC-LLR仅需0.76 μs。结果表明，RC-LLR在不同信道、不同调制、单线与并行情况下运行时间均最短，均控制在3.00 μs内。



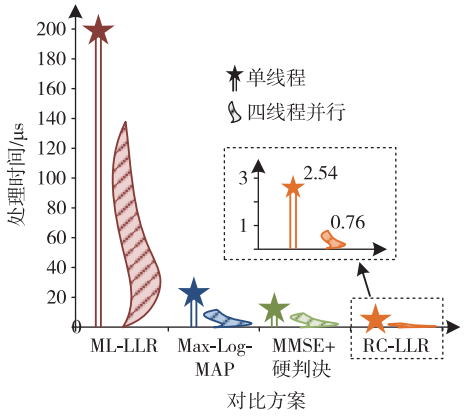
(a) AWGN信道16QAM调制结果



(b) AWGN信道64QAM调制结果



(c) 线性色散信道16QAM调制结果



（d）线性色散信道64QAM调制结果

图8　单符号平均处理时间结果对比

为验证RC-LLR相比其他机器学习方法的优越性，进一步将其与前馈神经网络（FNN）和一维卷积神经网络（1D-CNN）即两种轻量级网络进行对比。FNN采用3层全连接结构，输入层4维，隐藏层128-64节点，输出层$\log_2 M$维。1D-CNN采用2个卷积层加全连接层，核大小为3，通道数为32-64。三种网络在16QAM调制、AWGN信道、SNR=15 dB条件下的性能对比如表3所示。

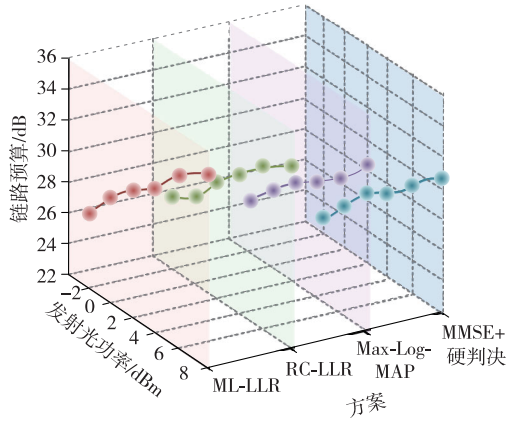
表3　RC-LLR与其他机器学习方法的对比结果

方案	$SNR@BER=1\times10^{-3}$/dB	训练时间/min	推理时间/μs	参数量	硬件友好度
ML-LLR	14.57	\	178.23	\	低
FNN	14.58	23.4	2.13	8 836	中
1D-CNN	15.34	8.9	3.67	7 264	中
RC-LLR	14.69	2.03	2.01	1 204	高

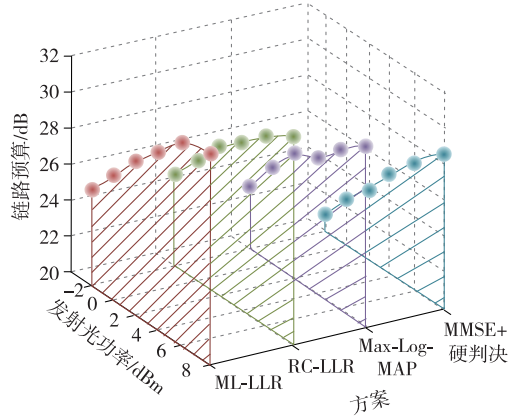
由表3可以看到，虽然FNN在解调精度上略优于RC-LLR，但其训练时间高达23.4 min，是RC-LLR的2.03 min的11.5倍，在需要频繁重训练的实际光通信场景中，FNN的部署成本过高。而1D-CNN的解调精度为15.34 dB，明显劣于RC-LLR的14.69 dB，同时其推理时间也更长，比RC-LLR的2.01 μs多1.66 μs。参数规模方面，RC-LLR仅有1 204个参数，为FNN的13.6%、1D-CNN的16.6%，存储需求大幅降低。并且RC-LLR的稀疏随机连接加线性读出结构使其硬件实现复杂度远低于FNN和1D-CNN的密集连接，适合FPGA等嵌入式平台的实时部署。综合来看，RC-LLR虽然损失了0.11 dB的解调精度，但训练效率提升了11倍、参数量减少85%以上，在精度、效率和可部署性之间取得了最佳平衡，能够为动态光纤信道的实时解调提供更实用的解决方案。

3.3　实际OFDM光通信系统中的应用验证

为验证RC-LLR算法在实际系统中的部署可行性，搭建了基于商用光模块的OFDM传输测试平台。系统采用10 Gbaud符号速率，128个子载波，循环前缀长度为16。发射端通过马赫-曾德尔调制器将电信号转换为1 550 nm波段的光信号，经标准单模光纤传输。接收端采用PIN光电二极管进行直接检测，后接50 GSa/s采样率的高速ADC。对比方案依旧为ML-LLR，Max-Log-MAP与MMSE+硬判决。首先在城域网距离（40～80 km）和长途传输场景（80～120 km）下对比了各方案在达到目标$BER=1\times10^{-3}$时的链路预算，结果如图9所示。



（a）城域网场景

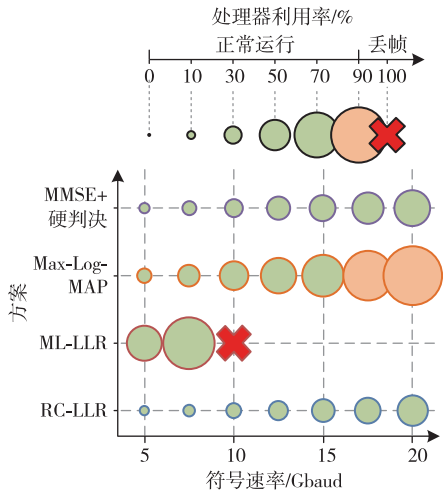


（b）长途传输场景

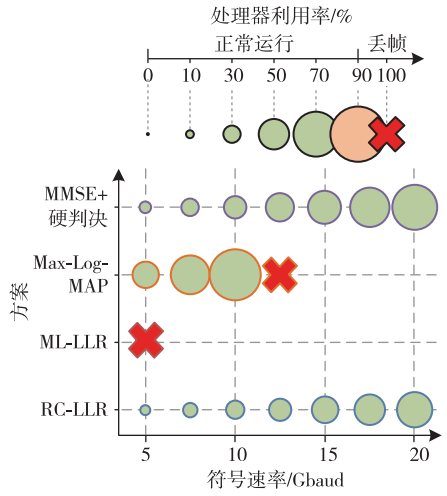
图9　不同传输场景下的链路预算对比

图9中，链路预算越高表示系统抗干扰能力越强，传输余量越大。从图9(a)中可以看到，在城域网场景中，RC-LLR在各功率点的链路预算比ML-LLR低0.50～0.70 dB，但始终高于Max-Log-MAP与MMSE+硬判决方案。当发射光功率为0 dBm时，RC-LLR的链路预算为27.90 dB，比Max-Log-MAP的26.70 dB提升了1.20 dB，相比MMSE+硬

判决的 24.33 dB 提升了 3.57 dB。在图 9(b)的长途传输场景中，RC-LLR 的性能优势进一步显现，在 6 dBm 功率下，RC-LLR 的链路预算为 29.16 dB，比 MMSE＋硬判决高 3.87 dB，这一增益可直接延长传输距离或降低发射端激光器的功耗要求，为系统设计与部署提供了灵活性。接下来，测试了各方案在不同数据速率下的处理器利用率，结果如图 10 所示。



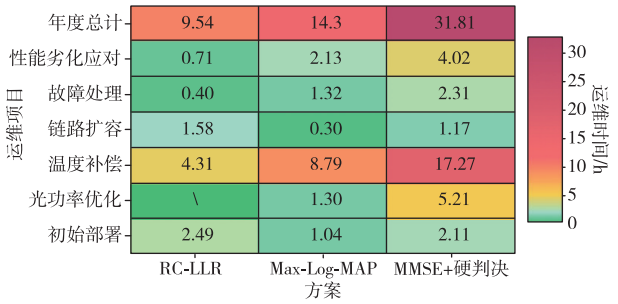
(a) 16QAM 调制



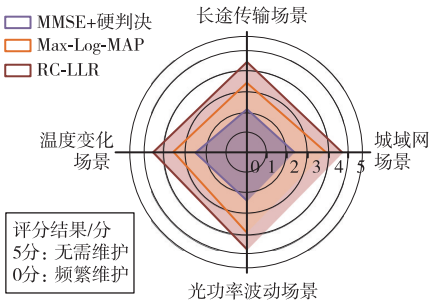
(b) 64QAM 调制

图 10　不同符号速率下的处理器利用率对比

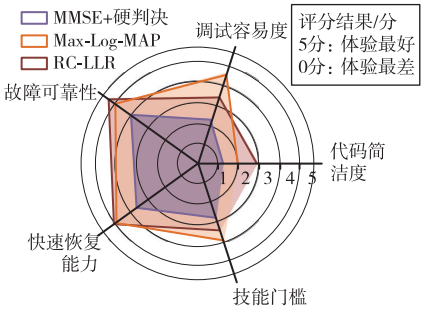
由图 10(a)可以看出，在 16QAM 调制下测试时，ML-LLR 作为理论性能最佳的方案，在实际应用中，传输速率仅达 10 Gbaud 时处理器利用率就已超过 100%，出现丢帧情况。而相同速率下的 RC-LLR 利用率仅为 24%，在 20 Gbaud 的高速率下也只需 48%。如图 10(b)的 64QAM 调制下，ML-LLR 在 5 Gbaud 时就已丢帧，Max-Log-MAP 在符号速率为 7.5 Gbaud 时也出现丢帧情况。表现相对较好的 MMSE＋硬判决方案由于不涉及软信息计算，在符号速率为 15 Gbaud 时利用率为 54%，但仍高于相同条件下 RC-LLR 的 42%。以上结果说明，RC-LLR 通过离线训练学习，在运行时利用低复杂度的线性计算，避免了困难的精确信道估计过程，有效降低了系统利用率。最后，对各方案的运维成本进行了测试，而 ML-LLR 由于仅存在理论最优，在部署中实用性差，不参与此次测试。同时还邀请了多位具备现场部署经验的工程师对各方案的运维便利性进行量化评估，结果如图 11 所示。



(a) 年度运维工作时间成本对比



(b) 不同信道的参数鲁棒性评分



(c) 现场部署工程化指标评分

图 11　系统部署与维护特性对比

图 11(a)的运维工作时间中，RC-LLR 的初始部署时耗时较长，达 2.49 h，但其在之后的日常运维中不再需要长时间的人工干预，面对最复杂的温度补偿时也仅需 4.31 h，较 Max-Log-MAP 的 8.79 h 提升了 50.9%。RC-LLR 的年度运维总时长为 9.54 h，仅为 MMSE＋硬判决方案的 29.9%。图 11(b)与(c)的评分中可以看出，RC-LLR 通过储备池的非线性映射

能力，表现出良好的参数稳定性和工程适应性。在长途传输场景下，RC-LLR的鲁棒性评分为4.52，显著高于Max-Log-MAP的3.48和MMSE＋硬判决的2.13。同时，RC-LLR在工程化维度获得了最高的代码简洁度评分2.98，并且在故障可靠性、快速恢复能力上均优于对比方案。综上所述，所提出的RC-LLR网络在OFDM光通信系统中达到了解调性能与复杂度工程实现之间的良好平衡，为高速光通信系统的高性能解调优化提供了有效方案。

4　结束语

本文提出一种基于RC-LLR网络的OFDM光通信系统解调优化方法，用于解决传统方案在进行LLR解调计算时复杂度高、实时性差的问题。仿真与实际应用结果表明，在16QAM调制的AWGN信道下，当SNR为20 dB时，RC-LLR的误码率为1.53×10^{-6}，仅次于理论最优的ML-LLR方案（8.91×10^{-7}）。计算效率方面，64QAM调制下RC-LLR的单符号处理时间仅为2.45 μs，较Max-Log-MAP的18.91 μs缩短了87%，同时在并行化场景下优势更加显著。实际部署中，在长途传输场景的6 dBm发射功率下，RC-LLR的链路预算达到29.16 dB，在20 Gbaud高速率下处理器利用率仅为48%，年度运维总时长为9.54 h，并且在鲁棒性评分（4.52分）和代码简洁度（2.98分）上均显著优于对比方案。结果表明，所提方法在解调性能与计算复杂度之间实现了有效平衡，为OFDM光通信系统的高速实时解调提供了工程化可行的技术路径。未来将考虑引入自适应储备池结构与联合信道补偿机制，以进一步提升算法在动态信道下的鲁棒性与适应性。

参考文献：

[1] 张　萌，谷栎娜，薛少童，等. 基于嵌入式技术的光通信信号智能处理系统[J]. 激光杂志，2025，46(2)：168-173.
Zhang Meng，Gu Lina，Xue Shaotong，et al. Intelligent processing system for optical communication signals based on embedded technology [J]. Laser Journal，2025，46 (2)：168-173.

[2] 贾科军，连江龙，张常瑞，等. 基于改进K-means算法的室内可见光通信O-OFDM系统信道均衡技术[J]. 电讯技术，2025，65(1)：96-102.
Jia Kejun，Lian Jianglong，Zhang Changrui，et al. Channel equalization based on improved K-means algorithm for O-OFDM indoor visible light communication [J]. Telecommunication Engineering，2025，65(1)：96-102.

[3] Song P，Liu Y，Hu Z，et al. Toward secure and high-speed OFDM-PONs leveraging variable multi-band chaotic non-orthogonal matrices [J]. Journal of Lightwave Technology，2024，42(24)：8702-8712.

[4] 王婵飞，杨　婧，许亚美，等. 深度学习驱动的OFDM索引调制信号检测[J]. 计算机科学，2025，52(S1)：792-797.
Wang Chanfei，Yang Jing，Xu Yamei，et al. OFDM index modulation signal detection based on deep learning [J]. Computer Science，2025，52(S1)：792-797.

[5] Qasaymeh M M. A novel machine learning approach for blind carrier offset estimation in OFDM systems [J]. International Journal of Electrical and Electronic Engineering & Telecommunications，2024，13(4)：286-292.

[6] Babaroglu H，Anttila L，Xu G，et al. Digital post-distortion for multi-layer MIMO-OFDM [J]. IEEE Wireless Communications Letters，2024，13(7)：1803-1807.

[7] 钟兆根，谭继远，谢存祥. 基于对数条件似然比的无偏自同步扰码识别[J]. 电子与信息学报，2024，46(7)：2757-2764.
Zhong Zhaogen，Tan Jiyuan，Xie Cunxiang. Unbiased self-synchronous scrambler identification based on log conditional likelihood ratio [J]. Journal of Electronics & Information Technology，2024，46(7)：2757-2764.

[8] Tan J，Xiao Y，Dan L，et al. Efficient LLR approximation for coded constant envelope OFDM [J]. IEEE Transactions on Vehicular Technology，2023，72(5)：6194-6208.

[9] 吕亚倩，赵守江. Cox-Ingersoll-Ross过程对数似然比的精细大偏差[J]. 数学杂志，2024，44(1)：35-46.
Lü Yaqian，Zhao Shoujiang. Sharp large deviations for the log-likelihood ratio of the cox-Ingersoll-ross process[J]. Journal of Mathematics，2024，44(1)：35-46.

[10] Lee O，Wei T，Stenning K D，et al. Task-adaptive physical reservoir computing [J]. Nature Materials，2024，23 (1)：79-87.

[11] 黎祥远，吕峻闽，徐胜超. 基于储备池计算的深度学习模型数据并行训练优化方法[J]. 计算机测量与控制，2025，33(7)：227-233，242.
Li Xiangyuan，Lv Junmin，Xu Shengchao. Data parallel training optimization method for deep learning model based on reservoir computing[J]. Computer Measurement & Control，2025，33(7)：227-233，242.

[12] Liang X，Tang J，Zhong Y，et al. Physical reservoir computing with emerging electronics[J]. Nature Electronics，2024，7(3)：193-206.

[13] 杨　光，吴朝阳，聂　敏，等. 基于CWGAN-SLM的多小波OFDM系统峰均比抑制算法研究[J]. 通信学报，2023，44(4)：99-110.
Yang Guang，Wu Chaoyang)，Nie Min，et al. Research on PAPR reduction algorithm based on CWGAN-SLM for multi-wavelet OFDM system [J]. Journal on Communications，2023，44(4)：99-110.

[14] 谭 钢，鄢社锋，叶子豪，等. OFDM系统迭代脉冲噪声抑制与信道估计方法[J]. 系统工程与电子技术，2024，46(8)：2841-2849.
Tan Gang, Yan Shefeng, Ye Zihao, et al. Iterative impulsive noise mitigation and channel estimation method for OFDM system [J]. Systems Engineering and Electronics, 2024, 46(8): 2841-2849.

[15] Tsao M. Regression model selection *via* log-likelihood ratio and constrained minimum criterion [J]. Canadian Journal of Statistics, 2024, 52(1): 195-211.

[16] 于添阔，姚秋彦，杨 辉，等. 一种基于图表示学习的光网络算力调度方法[J]. 光通信技术，2024，48(5)：46-50.
Yu Tiankuo, Yao Qiuyan, Yang Hui, et al. Optical network computing power scheduling method based on graph representation learning [J]. Optical Communication Technology, 2024, 48(5): 46-50.

[17] 王 鑫，张建国，王云才. 具有延时反馈的单节点储备池设计与实现[J]. 电子器件，2023，46(4)：951-958.
Wang Xin, Zhang Jianguo, Wang Yuncai. Design and implementation of single-node reservoir with time-delay feedback [J]. Chinese Journal of Electron Devices, 2023, 46(4): 951-958.

[18] 康国辉，冯晋霞，李渊骥，等. 压缩态光场在光纤信道传输过程中的量子误差修正[J]. 量子光学学报，2024，30(2)：20003.
Kang Guohui, Feng Jinxia, Li Yuanji, et al. Quantum error correction of squeezed states transmitted over optical fiber channel [J]. Acta Sinica Quantum Optica, 2024, 30(2): 20003.

[19] 陈品儒，华 楠，朱康奇，等. 应用于光通信网络的高精度双频时间间隔测量方法[J]. 光通信技术，2023，47(5)：78-83.
Chen Pinru, Hua Nan, Zhu Kangqi, et al. High-precision double-frequency time interval measurement method in optical communication networks [J]. Optical Communication Technology, 2023, 47(5): 78-83.

[20] 王秀莲，朱 建，张 蕾，等. 工业5G的非授权频段多优先级动态接入方法[J]. 电讯技术，2024，64(10)：1691-1697.
Wang Xiulian, Zhu Jian, Zhang Lei, et al. A dynamic multi-priority access method for industrial 5G in unlicensed bands [J]. Telecommunication Engineering, 2024, 64(10): 1691-1697.

[21] 方欲晓，何可人. 基于节点路径重构和ELM的无线通信网络DDoS攻击源追踪[J]. 现代电子技术，2024，47(13)：93-96.
Fang Yuxiao, He Keren. Tracking of DDoS attack source in wireless communication network based on node path reconstruction and ELM [J]. Modern Electronics Technique, 2024, 47(13): 93-96.

作者简介：

马博文(1991—)，女，河北省石家庄市人，讲师，主要研究方向为计算机应用技术；

曹欣雨(1995—)，女，河北省石家庄市人，讲师，主要研究方向为计算机应用技术。