

基于旋转位置编码与多尺度自适应融合的水声信道均衡方法

刘淞佐^{1,2,3,4}, 张轩野^{1,2,3}, 高健乔^{1,2,3}, 吕智博^{1,2,3}, 乔钢^{1,2,3,4}

(1. 哈尔滨工程大学水声技术全国重点实验室, 黑龙江 哈尔滨 150001; 2. 工业和信息化部海洋信息获取与安全工信部重点实验室(哈尔滨工程大学), 黑龙江 哈尔滨 150001; 3. 哈尔滨工程大学水声工程学院, 黑龙江 哈尔滨 150001; 4. 哈尔滨工程大学三亚南海创新发展基地, 海南 三亚 572024)

摘要: 针对水声信道多径效应导致码间干扰严重、现有深度学习方法均衡能力不足的问题, 本文提出一种融合旋转位置编码与多尺度自适应机制的水声信道均衡网络(RoMAFNet)。首先, 引入旋转位置编码构建Transformer编码器, 以乘性方式嵌入符号间相对时延信息, 增强网络的位置感知与时变适应能力。其次, 设计多尺度自适应多径均衡模块, 以膨胀率递增的并行分支分尺度刻画不同时延的多径分量, 并由全局上下文驱动的门控机制对各分支动态加权。进一步, 在Lipschitz平滑性等假设下推导所提融合机制误差的闭式上界, 并据此分析了其在线微调稳定性。所提网络采用“离线预训练-在线微调”范式, 仿真信道中, 在线微调阶段每帧仅以约50个训练序列符号持续更新即可有效适配新信道, 南海实测信道中对训练序列符号的增量利用效率亦显著优于对比方法。

关键词: 水声通信; 信道均衡; 旋转位置编码; 多尺度自适应融合; 在线微调部署

中图分类号: TN929.3

Underwater Acoustic Channel Equalization Based on Rotary Position Embedding and Multi-scale Adaptive Fusion

LIU Songzuo^{1,2,3,4}, ZHANG Xuanye^{1,2,3}, GAO Jianqiao^{1,2,3}, LV Zhibo^{1,2,3}, QIAO Gang^{1,2,3,4}

1. National Key Laboratory of Underwater Acoustic Technology, Harbin Engineering University, Harbin 150001, China

2. Key Laboratory of Marine Information Acquisition and Security (Harbin Engineering University), Ministry of Industry and Information Technology, Harbin 150001, China

3. College of Underwater Acoustic Engineering, Harbin Engineering University, Harbin 150001, China

4. Sanya Nanhai Innovation and Development Base of Harbin Engineering University, Sanya 572024, China

Abstract: To address the severe multipath-induced inter-symbol interference in underwater acoustic (UWA) channels and the limited equalization capability of deep learning methods, this paper proposes a UWA channel equalization network (RoMAFNet) that integrates rotary position embedding (RoPE) and a multi-scale adaptive fusion mechanism. First, a RoPE-based Transformer encoder multiplicatively embeds inter-symbol time-delay information, enhancing the network's position awareness and time-varying adaptability. Second, a multi-scale adaptive multipath equalization module uses parallel branches with increasing dilation rates to characterize multipath components at different delay scales, then dynamically weights them via a global context-driven gating mechanism. Furthermore, under Lipschitz smoothness and related assumptions, a closed-form error bound for the proposed fusion mechanism is derived, and its online fine-tuning stability is analyzed accordingly. RoMAFNet adopts an "offline pre-training and online fine-tuning" paradigm: on simulated channels, continual per-frame updates with only about 50 training symbols suffice to adapt to new channels, while on measured South China Sea channels it also utilizes incremental training symbols far more efficiently than the compari-

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 乔钢, qiaogang@hrbeu.edu.cn

基金项目: 国家重点研发计划资助项目(No.2023YFC2809500), 国家自然科学基金资助项目(No.62231011)

Foundation Items: National Key Research and Development Program funding (No.2023YFC2809500), the National Natural Science Foundation of China (No.62231011)

son methods.

Key words: Underwater acoustic communication, Channel equalization, Rotary position embedding, Multi-scale adaptive fusion, Online fine-tuning deployment

0 引言

海洋作为地球上尚未被完全认知的战略疆域,其信息的有效传输对于资源勘探、环境监测具有重要意义。水声通信是目前中远距离水下无线信息交互的唯一有效手段^[1-3]。其中,单载波水声通信因峰均功率比低,对频偏不敏感等优势是水声通信长期研究的热点^[4-6]。然而,水声信道中声波经直达径、海面与海底反射径等多条路径到达接收端,各路径间显著的传播时延差会引起严重的码间干扰,对水下信息的可靠传输构成严峻挑战^[7]。因此,本文聚焦单载波水声通信中信道多径效应的均衡问题。

面对日益复杂的水下通信环境,传统均衡技术面临其性能瓶颈。以最小均方(Least Mean Square, LMS)和递归最小二乘(Recursive Least Squares, RLS)为代表的经典自适应算法,难以在收敛速度、跟踪能力与稳态性能之间取得良好折中^[8];而基于简化假设或线性统计模型的均衡方法,则难以刻画水声信道固有的强非线性与快时变特性。

近年来,以深度学习为代表的机器学习技术凭借其强大的非线性映射能力和端到端学习特性,为上述挑战提供了新思路^[9-13]。早期研究多采用全连接深度神经网络(Deep Neural Network, DNN)或卷积神经网络(Convolutional Neural Network, CNN)直接拟合信道逆模型以恢复发送信号^[14],研究重点在于优化规模以平衡估计精度与计算开销。文献[15-16]构建了规模适中的多层DNN均衡器,验证了网络在无需信道先验统计信息时挖掘导频与信道状态信息(Channel State Information, CSI)间非线性映射的能力,并证明在导频充足条件下DNN估计器可渐进逼近最小均方误差最优解,稳健性优于常规最小二乘算法。但相关结论仍以理论推导与仿真为主,缺乏实际海试验证。

针对基础DNN处理大规模输入时特征提取能力不足的问题,文献[17-18]借鉴残差学习与U-Net思想,通过跳跃连接实现深浅层特征重用,缓解了梯度消失,但对深层非线性畸变的自适应修正能力仍有限。为挖掘信道沿时间轴的演变规律,文献

[19]提出CsiPreNet架构,将一维CNN的频域特征提取能力与长短期记忆网络(Long Short-Term Memory, LSTM)的时序建模优势相耦合,实现了对时变CSI的准确预测,并在多种通信体制下得到验证^[20-21]。然而,上述方法在建模时普遍缺乏对物理信道模型的利用,可解释性有限。为此,文献[22]提出融合高斯混合先验的学习近似消息传递网络,将近似消息传递算法逐层展开为前馈神经网络,实现了对多种稀疏结构水声信道的自适应估计;但该方法侧重信道参数获取而非符号端到端恢复,且其准静态假设在快时变信道下难以严格成立。

针对上述方法在深层特征挖掘与符号恢复方面的局限,近期研究开始探索表达力更强的网络架构。文献[23]构建了基于堆叠自编码器的接收机,通过对称拓扑将高维接收信号映射至低维潜在表征,并结合相对熵(Kullback-Leibler divergence, KL)散度稀疏约束的层级化预训练,实现非线性干扰滤除与信号恢复。文献[24]提出深度展开的UDNet均衡器,将正交相移键控(Quadrature Phase Shift Keying, QPSK)均衡转化为四分类任务,以经典最小均方误差均衡器为各层先验,并借助带状信道矩阵近似缩减网络规模、支持变长信号处理。文献[25]则采用密集连接卷积网络(DenseNet),通过层间密集直连实现特征深度复用,缓解了深层网络的训练退化问题。

回顾上述深度学习水声均衡方法的演进可以发现,无论是空间特征提取还是时序状态跟踪,其核心思路均在于挖掘接收符号或信道响应沿时间轴的演化规律。在单载波体制下,接收符号序列本质上是沿时间维度强相关的观测样本,因而信道均衡在数学形式上可等价为单变量时间序列建模问题,这一视角已得到初步验证。文献[26]提出基于多尺度卷积LSTM的延迟-多普勒域预测框架,凸显了多尺度建模的潜力;文献[27]提出时频域学习模型,通过分解并分别建模长期趋势与短期季节性分量,验证了经典时序分解思想在水声信号重建中的有效性;文献[28]面向自适应水声正交频分多址系统提出核自适应滤波信道预测方法,进一步印证了时序

建模在水声场景下的适用性。然而,水声信道在不同时间尺度上呈现出截然不同的演化特性,且各尺度的主导地位随环境动态切换。如何精细分解时序模式并自适应识别主导尺度,仍是亟待深入探索的关键问题。

与水声领域的初步探索不同,通用时间序列预测领域在多尺度建模方向已取得显著进展,其中以TimeMixer^[29]和自适应多尺度分解(Adaptive Multi-Scale Decomposition, AMD)最具代表性^[30]。TimeMixer通过对原始序列多次降采样获取不同粒度的趋势分量,实现跨尺度信息整合,系统论证了多尺度建模对时序预测的价值;AMD则进一步指出“多尺度纠缠效应”,构建多尺度可分解混合、双重依赖交互与自适应多预测器合成的级联架构,为不同时序模式定制聚合策略,曾同时刷新长短期预测的最优性能。

然而,这类面向平稳数据的通用框架,既未顾及水声信道在相对时延扩展与时变衰落上的物理规律,其面向通用场景的复杂结构带来较高的参数与计算开销,难以满足均衡器部署需求,不利于直接迁移至水声通信均衡场景。鉴于此,本文紧扣单载波水声均衡的单变量时序本质,汲取AMD的核心思想,剥离其面向通用场景的冗余设计,并融入水声信道物理先验,提出一种结构精炼、性能稳健且具备理论支撑的旋转位置编码多尺度自适应融合网络(Rotary Multi-scale Adaptive Fusion Network, Ro-MAFNet)。主要贡献如下:

1) 将旋转位置编码引入水声均衡,精细刻画信道的相对时延结构。据作者所知,截至本文撰写之时,旋转位置编码(Rotary Position Embedding, RoPE)在水声通信均衡领域的应用尚少见报道。本文通过复数域旋转操作将符号间的相对位置信息内嵌于注意力计算,天然契合水声多径信道中码间干扰由相对时延主导的物理特性,在保证位置可分辨性的同时提升了网络对长时延扩展信道的建模能力。

2) 提出融入水声物理先验的多尺度自适应多径均衡模块(Multi-scale Adaptive Fusion, MAF),并给出误差有界性分析。区别于AMD面向通用平稳序列的数据驱动尺度划分与多预测器堆叠,本模块依据多径传播规律对其进行重构。以膨胀率递增的并行卷积分支将感受野锚定至直达径、中延迟与长

延迟多径,实现物理可解释的尺度分离,并经自底向上的尺度混合传递远场上下文;融合阶段以全局上下文驱动的单隐层门控逐帧生成各分支权重,以深度可分离卷积与单隐层门控分别替代AMD的多尺度堆叠与多预测器结构,降低了网络参数与计算量,并辅以基于变异系数的平衡正则化抑制分支退化。进一步,在Lipschitz平滑性等假设成立的前提下推导了该机制均衡误差的闭式上界,据此刻画其在线微调过程中的结构稳定性。

3) 构建基于小样本自适应的在线微调框架,并经仿真与海试共同验证。针对海试系统的快速适配需求,本文提出“离线大规模预训练-在线微调”的两阶段部署范式。仿真与海试结果一致表明,所提网络在部署信道上以自适应方式迭代,每帧仅利用约50个训练序列符号的标签即可持续更新模型、维持对新环境的有效适配,降低了通信开销与重新训练时间。本文进一步系统评估了每帧训练符号长度取50、100、200时的在线微调性能,量化了训练开销与性能之间的关系,为灵活部署提供了依据。

本文后续内容组织如下:第1节介绍水声单载波通信系统模型;第2节阐述所提网络的整体架构与核心模块设计,并给出多尺度融合误差有界性的理论分析;第3节通过仿真与海试实验验证方法的有效性;第4节归纳全文工作并给出结论。

1 系统模型

本文采用一个QPSK调制的单载波水声通信系统,系统模型如图1所示。在发射端,发送符号序列 $\mathbf{s} = [s(0), s(1), \dots, s(N-1)]^T, s(k) \in \mathcal{M} = \{(\pm 1 \pm j)/\sqrt{2}\}$ 发射符号数为 N ,符号周期为 T_s ,假设接收端已完成下变频、粗同步与符号定时,本文直接在符号率采样后的复基带域对接收信号进行处理与均衡,残余频偏、相位旋转与定时误差所引入的畸变统一并入下文等效信道抽头,由均衡器隐式补偿。

水声信号经直达径、海面与海底反射径等多条路径到达接收端,路径间传播时延差显著;同时,海水温盐分布不均、海面波动及收发节点相对运动使各径的复幅度增益与时延随时间缓慢漂移,信道整体呈现典型的时变多径特性。记第 l 条路径在时刻 t 的复幅度增益与传播时延分别为 $A_l(t)$ 与 $\tau_l(t)$,




图1 单载波水声通信系统模型

则信道的时变冲激响应表示为：

$$h(\tau, t) = \sum_{l=0}^{L-1} A_l(t) \delta(\tau - \tau_l(t)) \quad (1)$$

其中， L 为可分辨多径数， $\delta(\cdot)$ 为狄拉克函数。各多径间的相对时延差 $\tau_l(t) - \tau_0(t)$ 直接决定接收端码间干扰(inter-symbol interference, ISI)的强度与持续长度。经脉冲成形、信道传播、匹配滤波与符号率采样后，离散等效复基带接收信号为：

$$y(k) = \sum_{l=0}^{L_h-1} h_l(k) s(k-l) + w(k), \quad k = 0, 1, \dots, N-1 \quad (2)$$

其中， $h_l(k)$ 为时刻 k 上的第 l 个等效信道抽头，综合反映多径衰减、收发滤波级联响应与采样对齐效应； L_h 为有效抽头数，由最大时延扩展 $\tau_{\max}$ 决定； $w(k)$ 为零均值加性环境噪声。式(2)表明，接收符号 $y(k)$ 是当前发送符号 $s(k)$ 与其前 $L_h - 1$ 个符号经时变信道加权叠加的结果，在符号域引入显著ISI。

水声信道均衡的目标是在不依赖完整CSI的前提下，由接收序列 $\mathbf{y}$ 重建发送序列 $\mathbf{s}$ 。本文采用滑窗逐符号判决策略，定义时刻 k 的观测向量：

$$\mathbf{y}_k = [y(1), y(2), \dots, y(K_w)]^T \in \mathbb{C}^{K_w}. \quad (3)$$

其中滑窗长度 $K_w \geq L_h$ 以覆盖信道记忆，实际取值大于 L_h ，使自注意力能在更长上下文内捕获信道的时变相关性。将均衡器建模为参数化映射 f_θ ： $\mathbb{C}^{K_w} \rightarrow \Delta(\mathcal{M})$ ，其输出为星座集 $\mathcal{M}$ 上的后验概率分布，则当前符号的硬判决为：

$$\hat{s}(k) = \arg \max_{s \in \mathcal{M}} [f_\theta(\mathbf{y}_k)]_s, \quad k = 1, 2, \dots, K_w \quad (4)$$

参数 θ 通过在带标签符号上最小化交叉熵损失获得。由式(2)可见，接收符号在时间维度上呈现

强相关性，单载波水声信道因而可等价于单变量复值时间序列的逐位置重建问题；且多径能量在直达径、近程反射与远程混响等时延尺度上的分布与时变速率差异显著，要求模型跨尺度自适应聚合上下文。这一时序建模视角为第2节引入相对位置编码与多尺度自适应融合机制奠定了基础。

2 网络架构设计

2.1 整体架构

针对传统均衡方法在快时变多径信道下跟踪能力与稳态性能难以兼顾、现有深度学习对相对时延与多尺度多径建模不足的问题，本文设计了融合旋转位置编码与多尺度自适应融合机制的均衡网络RoMAFNet。整体架构如图2所示。网络以滑窗内的复基带接收向量 $\mathbf{y}_k$ 为输入，沿主干自下而上依次完成特征嵌入、全局特征提取、多尺度多径分解、时序特征建模、逐尺度判决与自适应融合，逐符号输出当前发送符号在QPSK星座集 $\mathcal{M}$ 上的后验概率分布。

网络由三个核心环节级联构成：图2(a)为RoPE-Transformer编码器，将输入 $(B, K_w, 2)$ 嵌入并经多层自注意力网络挖掘符号间相对时延关系，输出全局上下文表征 $(B, K_w, 256)$ ，其旋转位置编码的作用原理如图2(b)所示；图2(c)以膨胀率为1、2、4的三条深度可分离卷积分支，将编码特征分解为对应直达径、中延迟与长延迟多径的三组尺度特征，并由独立的双向长短期记忆网络(Bidirectional LSTM, BiLSTM)分别捕获各尺度的时序演化规律；图2(d)将各尺度判决经自适应门控加权融合，辅以变异系数平衡正则，最终输出符号判决 $\hat{s}(k)$ 。

上述设计以RoPE-Transformer提供相对位置感知的全局编码，以三尺度并行分支显式分离不同时延量级的多径分量，以自适应门控与平衡正则化联合调控各分支贡献，使网络在不同主导时延的信道环境下均能稳健抑制码间干扰。各模块的具体设计将在2.2~2.4节展开。

2.2 基于RoPE的Transformer编码器

水声多径信道中，码间干扰主要由各路径间的相对时延造成，而传统Transformer所采用的正弦绝对位置编码或可学习位置嵌入以加性方式注入位置信息，难以直接刻画相对位置关系。为此，本文以RoPE替代绝对位置编码，借助分组旋转矩阵将

相对位置信息以乘性方式直接嵌入注意力分数计算,使注意力自然以相对位置为变量。该设计契合水声 ISI 由相对时延主导的物理特性,在增强相对位置感知与信道建模能力的同时,对序列长度变化保持内在鲁棒性。旋转编码部分设计如下。

设接收向量 $\mathbf{y}_k$ 线性嵌入与层归一化后得到序列 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{K_w}]^T \in \mathbb{R}^{K_w \times d}$, 其中 d 为嵌入维度。在第 ℓ 层 Transformer 中, 查询、键、值矩阵由线性投影统一给出:

$$[\mathbf{Q}^{(\ell)}, \mathbf{K}^{(\ell)}, \mathbf{V}^{(\ell)}] = \mathbf{X}^{(\ell-1)} [\mathbf{W}_Q^{(\ell)}, \mathbf{W}_K^{(\ell)}, \mathbf{W}_V^{(\ell)}] \quad (5)$$

其中, $\mathbf{W}_Q, \mathbf{W}_K, \mathbf{W}_V \in \mathbb{R}^{d \times d}$ 为可学习参数。RoPE 通过分组旋转矩阵将位置信息嵌入到 Q 与 K 。对位置 m 处的查询向量 $q_m \in \mathbb{R}^{d_h}$ ($d_h = d/h$ 为单头维度, h 为注意力头数), 将其按相邻两维分组形成 $d_h/2$ 个二维子向量 $[q_m^{(2i)}, q_m^{(2i+1)}]^T, i = 0, 1, \dots, d_h/2 - 1$, 再对每个子向量施加角度 $m\omega_i$ 的二维旋转:

$$\begin{bmatrix} q_m'^{(2i)} \\ q_m'^{(2i+1)} \end{bmatrix} = \begin{bmatrix} \cos(m\omega_i) & -\sin(m\omega_i) \\ \sin(m\omega_i) & \cos(m\omega_i) \end{bmatrix} \begin{bmatrix} q_m^{(2i)} \\ q_m^{(2i+1)} \end{bmatrix} \quad (6)$$

频率参数 $\omega_i = b^{-2i/d_h}$, 基频 $b = 10000$; 键向量 $\mathbf{k}_n$ 按相同规则旋转得到 $\mathbf{k}_n'$ 。式(6)定义的分组旋转可记为正交矩阵 $\mathbf{R}(m)$, 满足 $\mathbf{R}(m)^T \mathbf{R}(n) = \mathbf{R}(n - m)$ 。故旋转后查询与键之间的内积仅取决于相对位置:

$$\langle \mathbf{q}_m', \mathbf{k}_n' \rangle = \mathbf{q}_m'^T \mathbf{R}(m)^T \mathbf{R}(n) \mathbf{k}_n = \mathbf{q}_m'^T \mathbf{R}(n - m) \mathbf{k}_n \quad (7)$$

式(7)表明, 注意力分数天然以相对位置 $(n - m)$ 为变量, 无需额外的相对位置偏置项即可获得相对位置感知能力, 这与水声多径 ISI 由相对时延主导的物理本质形成对应。基于上述旋转后的查询与键, 多头注意力的输出为:

$$\text{Attn}(\mathbf{Q}', \mathbf{K}', \mathbf{V}) = \text{softmax} \left(\frac{\mathbf{Q}' \mathbf{K}'^T}{\sqrt{d_h}} \right) \mathbf{V} \quad (8)$$

经 h 头并行计算与拼接后, 注意力输出与残差通路相加并经层归一化, 送入由两层全连接构成的前馈网络。前馈网络以高斯误差线性单元(Gaussian Error Linear Unit, GELU)作为激活函数, 对每个时间步独立进行非线性变换:

$$\text{FFN}(\mathbf{x}) = \mathbf{W}_2 \cdot \text{GELU}(\mathbf{W}_1 \mathbf{x} + \mathbf{b}_1) + \mathbf{b}_2 \quad (9)$$

其中 $\mathbf{W}_1 \in \mathbb{R}^{d_{ff} \times d}$, $\mathbf{W}_2 \in \mathbb{R}^{d \times d_{ff}}$, d_{ff} 为前馈网络隐藏维度。前馈输出再经残差连接与层归一化得到该层最终输出。本文采用 $L_E = 4$ 层 Transformer 编码器, 注意力头数 $h = 8$, 嵌入维度 $d = 256$, 单头维度 $d_h = 32$, 前馈维度 $d_{ff} = 256$, Dropout 比例为 0.1。

2.3 多尺度自适应多径均衡模块

区别于 AMD 面向通用平稳序列的尺度划分与多预测器堆叠, 本节依据水声多径传播的两条物理规律重构其结构。其一, 信道冲激响应中的多径分




图2 RoMAFNet整体架构(a)RoPE-Transformer编码器,(b)旋转位置编码原理

(c)多尺度多径分解与时序特征建模,(d)逐尺度判决与自适应融合

量按相对时延呈层次化聚簇，直达径与近程反射径集中于短时延；海面、海底反射等中长延迟分量依次分布于更远时延，形成由短至长的尺度层次。这为以膨胀率递增的并行卷积分支显式分离各时延量级的多径提供了物理依据，使尺度划分锚定于信道固有结构而非经验设定。其二，各时延层对信号畸变的主导贡献随环境动态更新，要求融合机制能以当前信道状态自适应调整各分支权重，这为以全局上下文驱动的单隐层门控替代多预测器堆叠提供了动机。后续的多尺度多径分解、自适应尺度融合与平衡正则化，即上述两条规律的结构化实现。

2.3.1 多尺度多径分解

设 RoPE-Transformer 编码器的输出 $\mathbf{Z} \in \mathbb{R}^{K_w \times d}$ 。本文采用三个并行的深度可分离卷积分支，分别以膨胀率 $r_m = 2^{m-1}$ ($m = 1, 2, 3$) 沿时间维度提取不同尺度的多径特征。卷积核尺寸取 $k = 5$ ，各分支的有效感受野 $R_m = (k - 1)r_m + 1$, $m = 1, 2, 3$ 分别覆盖 5、9、17 个符号周期，依次对应直达径与短、中、长延迟多径的能量集中区间。

需要说明的是，感受野 R_m 作用于编码器的输出特征而非原始接收符号。长度为 K_w 的全局上下文与长时延依赖已由编码器的自注意力承载，三分支的多尺度感受野则在已融合全局上下文的特征上进行由短至长的相对尺度刻画与局部精化，其“短/中/长延迟”为相对尺度划分，而非对绝对时延扩展的逐点覆盖。

为兼顾多尺度感受野与参数效率，各分支采用深度可分离卷积，即先对每个特征通道独立施加膨胀深度卷积，再通过 1×1 点卷积完成跨通道线性混合。第 m 尺度的卷积输出 $\mathbf{Z}_m^{\text{conv}} \in \mathbb{R}^{K_w \times d}$ 表示为：

$$\mathbf{Z}_m^{\text{conv}} = \varphi \left(\mathbf{W}_m^{\text{pw}} * \text{DWConv}_{r_m, k}(\mathbf{Z}^T) \right)^T \quad (10)$$

其中， $\text{DWConv}_{r_m, k}(\cdot)$ 为膨胀率 r_m 、核尺寸 k 的逐通道深度卷积， $\mathbf{W}_m^{\text{pw}} \in \mathbb{R}^{d \times d}$ 为 1×1 点卷积核， $\varphi(\cdot)$ 为 GELU 激活函数。相比标准卷积，深度可分离卷积将参数量从 $O(kd^2)$ 降至 $O(kd + d^2)$ ，在不损失感受野的前提下降低多分支并行的计算开销。

为使尺度间信息逐级传递、避免长延迟分量被孤立处理，本文采用自底向上的尺度混合策略，将长延迟尺度信息逐层注入较短延迟分支：

$$\begin{aligned} \mathbf{Z}_3 &= \mathbf{Z}_3^{\text{conv}} \\ \mathbf{Z}_2 &= \mathbf{Z}_2^{\text{conv}} + \phi_2(\mathbf{Z}_3) \\ \mathbf{Z}_1 &= \mathbf{Z}_1^{\text{conv}} + \phi_1(\mathbf{Z}_2) \end{aligned} \quad (11)$$

其中 $\phi_s(\cdot)$ 为由 Linear-GELU-Dropout 构成的尺度混合器。其物理意义在于：长延迟多径通常承载海面或海底反射能量，其变化趋势可为中短延迟分量的判决提供“远场上下文”。最终得到的三组多尺度特征 $\{\mathbf{Z}_1, \mathbf{Z}_2, \mathbf{Z}_3\}$ 分别承载由短至长不同时延尺度的多径上下文信息。考虑到各时延尺度的路径分量沿时间轴呈现相互独立的衰落规律，本方法为每个尺度配备一个独立的 BiLSTM 分支以捕获其前向与后向时序依赖：

$$\mathbf{H}_m = \text{BiLSTM}_m(\mathbf{Z}_m), \quad m = 1, 2, 3 \quad (12)$$

各分支 BiLSTM 的隐状态维度为 $d/2$ ，双向拼接为 d 维后经线性投影与层归一化稳定数值范围。每个分支末端接入一个独立分类头 $F_s(\cdot)$ （结构为 Linear-GELU-Dropout-Linear），输出该尺度对应的逐符号 logits：

$$\ell_m = F_m(\mathbf{H}_m) \in \mathbb{R}^{K_w \times |\mathcal{M}|}, \quad m = 1, 2, 3 \quad (13)$$

其中 $\mathcal{M} = 4$ 为 QPSK 星座集大小。三组 logits 将作为后续自适应融合的输入。

2.3.2 自适应尺度融合机制

不同信道环境下，三尺度对最终判决的贡献并非均等，固定权重的融合策略难以在多变环境中保持稳定。为此，本节设计基于全局上下文的门控权重生成机制，摒弃 AMD 面向通用平稳数据的多预测器堆叠结构，以单隐层的多层感知机 (Multi-Layer Perceptron, MLP) 输出各分支权重。该门控参数量仅为 $O(d^2)$ 量级，相比 AMD 按尺度堆叠多个完整预测器的方案降低了融合阶段的参数与开销。

具体地，取尺度混合后的最浅层特征 $\mathbf{Z}_1$ 为全局上下文（其已融合三个尺度的信息）。沿时间维度全局平均池化，得到反映当前测试帧整体特性的帧级表示：

$$\mathbf{g} = \frac{1}{K_w} \sum_{k=1}^{K_w} \mathbf{Z}_1[k, :] \in \mathbb{R}^d \quad (14)$$

随后经单隐层门控网络生成三个尺度的归一化权重：

$$\boldsymbol{\alpha} = \text{softmax} \left(\mathbf{W}_\alpha^{(2)} \varphi \left(\mathbf{W}_\alpha^{(1)} \mathbf{g} + \mathbf{b}_\alpha^{(1)} \right) + \mathbf{b}_\alpha^{(2)} \right) \in \mathbb{R}^3 \quad (15)$$

其中 $\mathbf{W}_\alpha^{(1)} \in \mathbb{R}^{d \times d}$ 、 $\mathbf{W}_\alpha^{(2)} \in \mathbb{R}^{3 \times d}$ 为可学习参数， $\varphi(\cdot)$ 仍为 GELU。由于门控输入为帧级全局上下文，

权重 α 不随时间位置变化, 可提供帧级稳定的尺度选择策略, 避免逐符号权重抖动引入判决噪声。融合后的逐符号 logits 为各分支的加权和:

$$\ell_{\text{final}} = \sum_{m=1}^3 \alpha_m \cdot \ell_m \quad (m = 1, 2, 3) \quad (16)$$

将式(16)经 softmax 归一化, 即得到当前符号在 $\mathcal{M}$ 上的后验概率分布:

$$P(s_k = m_j | \mathbf{y}; \boldsymbol{\theta}) = \frac{\exp(\ell_{\text{final}}[k, j])}{\sum_{j'=1}^{|\mathcal{M}|} \exp(\ell_{\text{final}}[k, j'])} \quad (17)$$

其中 $m_j \in \mathcal{M}$ 为第 j 个 QPSK 星座点。最终硬判决与式(4)一致, 取后验概率最大的星座点输出。

2.3.3 平衡正则化约束

若不对融合权重 α 加以约束, 自适应门控在训练中可能出现某一尺度的权重持续被放大, 其余分支因长期缺乏有效梯度回传而退化。而海洋信道在不同时段会切换主导尺度模式, 被压制的分支一旦需在新环境中激活, 其参数已无法提供有效响应。

为此, 本文在批样本层面约束各分支权重的离散程度。设批量大小为 B , 第 i 个样本的权重为 $\alpha^{(i)} \in \mathbb{R}^3$, 则批内各分支权重的均值与标准差为:

$$\mu_m = \frac{1}{B} \sum_{i=1}^B \alpha_m^{(i)}, \quad \sigma_m = \sqrt{\frac{1}{B} \sum_{i=1}^B (\alpha_m^{(i)} - \mu_m)^2}, \quad m = 1, 2, 3 \quad (18)$$

平衡正则项采用变异系数(Coefficient of Variation, CV)形式:

$$\mathcal{L}_{\text{bal}} = \frac{1}{3} \sum_{m=1}^3 \frac{\sigma_m}{\mu_m + \varepsilon} \quad (19)$$

其中 $\varepsilon = 10^{-8}$ 为防止除零的小常数。选用 CV 而非熵或 KL 散度的原因有二: 其一, CV 仅约束权重在样本间的相对波动, 不强制各分支权重均值趋于均匀, 保留了门控机制对不同信道的自适应灵活性, 与熵约束的等量化效果有本质区别; 其二, CV 对量级具有自归一化特性, 可避免少量极端样本主导损失, 在水声非高斯噪声环境下更为稳定。

2.3.4 多尺度自适应融合方法的误差有界性分析

为评估所提 MAF 机制在水声多径信道下的可靠性, 本文按“接收信号的 Lipschitz 平滑性、单尺度分支预测器的局部误差上界以及自适应加权融合的误差闭式上界”三级递进结构展开, 建立 MAF

输出误差的可控上界, 并据此阐释在线微调过程中的稳定性。

水声接收信号虽呈现复杂的多径叠加与时变衰落, 但在符号级时间尺度上仍受清晰的物理约束。本节首先针对发送符号、信道增益与噪声给出三条可由物理量直接验证的基本假设。

假设 1 (QPSK 恒模约束): 发送符号 $s(k) \in \mathcal{M}$ 在 QPSK 调制下满足恒模特性 $|s(k)| = A$ (取 $A = 1$), 故对任意时刻 a, b 有

$$|s(a) - s(b)| \leq 2A$$

假设 2 (信道总增益有界): 受声波在海水介质中能量守恒的物理约束, 等效信道抽头的模值之和有界, 即存在常数 $H_{\max} > 0$ 使

$$\sum_{l=0}^{L_h-1} |h_l(k)| \leq H_{\max}, \quad \forall k$$

假设 3 (噪声增量有界): 接收噪声经接收滤波后为带限过程, 其样本序列的相邻增量在有限观测帧内取值有界。据此, 本文以一个有效常数 $\kappa_n > 0$ 刻画噪声在符号率采样下的最大增量, 即

$$|w(a) - w(b)| \leq \kappa_n \cdot |a - b|, \quad \forall a \neq b$$

三条假设的核心参数 ($A, H_{\max}, \kappa_n$) 均可直接测得。 A 由调制方式给出; $H_{\max}$ 取信道冲激响应估计的最大模和; κ_n 取相邻噪声样本幅度的经验上界。三者的物理可测性为后续误差上界的可评估性奠定了基础。在上述假设下, 可建立接收信号 $y(k)$ 的 Lipschitz 平滑性引理。

引理 1 (接收信号的 Lipschitz 平滑性): 在假设 1-3 下, 接收信号 $y(k)$ 满足

$$|y(a) - y(b)| \leq \kappa \cdot |a - b|, \quad \kappa = 2AH_{\max} + \kappa_n \quad (20)$$

引理 1 中的常数 κ 由物理量直接构成, $2AH_{\max}$ 项反映恒模发送信号经多径叠加后的最大幅度跳变, 刻画多径效应对接收信号瞬时变化的贡献; κ_n 项刻画带限噪声的时序相关性。

第 m 分支由膨胀深度可分离卷积、BiLSTM 与 MLP 级联构成, 以 RoPE-Transformer 编码器的输出为输入。尽管编码器已在长度 K_w 的序列上建立全局上下文, 分支 m 的膨胀卷积仍以 R_m 个符号周期的感受野对编码特征进行局部精化, 使其输出主要敏感于以当前符号为中心、宽度为 R_m 的邻域; 信道的全局长时延依赖由编码器承载, 其贡献可并入下述分支灵敏度常数。据此给出关于整条复合预测

器的最小局部稳定性假设。

假设4（单尺度预测器局部稳定性）：第 m 尺度的复合预测器输出当前发送符号的软估计 $\hat{x}_m(k)$ 。设 R_m 为其在原始时间单位下的有效感受野长度，则存在尺度相关常数 $v_m > 0$ ，使预测误差受感受野内信号最大波动所控制，即

$$|\hat{x}_m(k) - s(k)| \leq v_m \cdot \sup_{|\tau - k| \leq R_m} |y_m(\tau) - y_m(k)| \quad (21)$$

其中 τ 为感受野内任意时间的位置变量，该闭区间内离散样本数有限且 y_m 取值有界，故式中 $\sup$ 即为区间内最大值。

假设4本质上仅要求预测器满足两条最基本的行为约束。其一，感受野内信号完全平稳，即 $\sup = 0$ 时，预测误差为零，对应预测器对常数输入应给出确定性输出；其二，预测误差随感受野内信号波动按比例放大，对应“输入波动越剧烈、预测越困难”的工程直觉。常数 v_m 称为第 m 尺度的灵敏度系数，它一并吸收了共享编码器对本分支输出的放大效应。因此编码器的全局建模不破坏本假设的局部尺度刻画，仅对 v_m 的取值进行重整。基于引理1与假设4，可得便于工程评估的闭式误差上界。

引理2（单尺度预测器误差的闭式上界）：在假设1-4下，第 m 分支的软估计 $\hat{x}_m(k)$ 满足

$$|\hat{x}_m(k) - s(k)| \leq v_m \cdot \kappa \cdot R_m \quad (22)$$

每个尺度的预测误差上界由信号平滑性、感受野长度与预测器灵敏度三因子的乘积控制。三者在物理来源上彼此独立， κ 由信道与噪声决定， R_m 由网络结构决定， v_m 由训练后预测器的内在特性决定。重要的是，三个分支共享同一接收信号，因而具有同一 κ ，各分支仅通过 (R_m, v_m) 相区分。这意味着融合阶段无需对任何特定尺度施加额外补偿系数即可实现公平加权， κ 可作为公共因子在后续融合上界中提出。各分支正是通过其 R_m 在“长时序覆盖”与“局部精度”间形成权衡，这也是自适应权重在式(14)、(15)中需要在线调节的核心物理量。

定理1（多尺度融合误差有界性）：在假设1-4、引理1、引理2成立的前提下，多尺度自适应融合后的软估计 $\hat{x}(k) = \sum_{m=1}^3 \alpha_m(k) \cdot \hat{x}_m(k)$ 满足闭式误差上界

$$|\hat{x}(k) - s(k)| \leq \kappa \cdot \sum_{m=1}^3 \alpha_m(k) v_m R_m \leq \kappa \cdot \bar{v} \cdot \bar{R}_\alpha \quad (23)$$

其中， $\bar{v} = \max v_m$ 为各分支灵敏度系数的上确界， $\bar{R}_\alpha = \sum_{m=1}^3 \alpha_m R_m$ 称为多尺度自适应加权有效感受野，刻画当前权重分布下网络对接收信号的等效时间感知范围。

上界式(23)的物理意义可从三个层面加以解读。

其一，误差上界与 κ 呈线性比例关系。由 $\kappa = 2AH_{\max} + \kappa_n$ 可知，信道越平稳、噪声相关性越弱，上界越紧。即融合机制无需调整结构即可直接受益于信道条件的改善。

其二， $\bar{R}_\alpha$ 始终落在区间 $\bar{R}_\alpha \in [R_1, R_3]$ 内且由权重分布决定。 α 集中于短尺度分支时 $\bar{R}_\alpha \rightarrow R_1$ ，对应直达径主导场景，上界最紧但长程建模能力受限；当 α 集中于长尺度分支时 $\bar{R}_\alpha \rightarrow R_3$ ，对应长时延扩展的远距离场景，长程建模能力充分但误差上界相应放宽。自适应门控正是依据当前帧的全局上下文在该区间内动态选择工作点，这与固定权重融合形成本质区别，也是MAF相较AMD原始结构在水声场景下的核心理论价值。

其三，由 $\bar{R}_\alpha \leq R_3$ ，可得 $\kappa \cdot \bar{v} \cdot \bar{R}_\alpha \leq \kappa \cdot \bar{v} \cdot R_3$ 。即无论权重如何分配，融合误差永不超过一个与权重无关的保守上界。又因硬判决 $\hat{s}(k)$ 由 $\hat{x}(k)$ 经 $\arg\max$ 取得，软估计误差的有界性同时为硬判决的稳健性提供了支撑，使MAF相对于任意单尺度预测器的最坏性能在假设成立范围内不致退化。这一结论与2.3.3节平衡正则化相呼应。前者从理论层面刻画融合输出在假设条件下的最坏误差上界，后者从训练过程中促使各分支获得稳定的梯度更新，二者共同为MAF实际部署提供稳定性支撑。

还需指出，假设3中的 κ_n 刻画的是噪声在有限观测帧内逐样本意义下的最大增量。真实海洋中还存在由海洋生物发声、瞬态事件等引起的非高斯脉冲噪声^[31-32]。在含有强冲激样本的观测帧内 κ_n 可能显著增大。但由引理1可知， κ_n 仅以加性方式并入平滑性常数 $\kappa = 2AH_{\max} + \kappa_n$ ，并经定理1以线性方式作用于融合误差上界 $\kappa \cdot \bar{v} \cdot \bar{R}_\alpha$ 。因此脉冲噪声的影响表现为上界沿 $\bar{v} \cdot \bar{R}_\alpha$ 方向的整体放宽，而尺度间相对结构、有效感受野的自适应择优机制保持不变。这表明本文以 κ 为枢纽的有界性结论对脉冲

噪声同样适用, 其仅在于改变平滑性常数 κ 的取值, 而不破坏多尺度判决结构的稳定性。

2.4 损失函数

以网络训练采用交叉熵损失与平衡正则项的加权和为总目标。设训练序列长度为 K_w , 需明确, 离线预训练与在线微调两阶段标签范围不同。离线预训练阶段为离线一次性训练, 以完整帧内全部符号的标签计算交叉熵损失, 充分学习信道结构的通用表征 (此时 K_w 为完整帧长度); 在线微调阶段则仅以每帧的前 N_p 个训练符号的标签更新参数 (此时 $K_w = N_p$), 待判决数据符号的标签全程不参与。批量大小为 B , 其中交叉熵项 $\mathcal{L}_{CE}$ 由逐符号后验分布与真实标签计算:

$$\mathcal{L}_{CE} = -\frac{1}{BK_w} \sum_{i=1}^B \sum_{k=1}^{K_w} \log P(s_k^{(i)} | \mathbf{y}^{(i)}; \boldsymbol{\theta}) \quad (24)$$

总损失定义为:

$$\mathcal{L}_{total} = \mathcal{L}_{CE} + \lambda \mathcal{L}_{bal} \quad (25)$$

平衡损失 $\mathcal{L}_{bal}$ 由式(19)给出。权重 λ 用于协调判决精度与分支均衡。 $\lambda = 0$ 时模型退化为无约束门控融合, 离线训练后期易出现单一尺度主导、其余分支退化, 致使在线微调阶段无法快速激活退化分支; λ 过大则强制各分支权重在样本间趋于一致, 削弱环境自适应灵活性。综合离线训练稳定性与在线微调可恢复性, 本文统一取 $\lambda = 10^{-2}$, 离线预训练与在线微调阶段保持一致。初步实验表明该取值能有效抑制分支崩塌, 且不显著影响门控对不同信道环境的判别能力。

2.5 网络训练及在线微调部署

针对实际海试系统对快速适配的需求, 本文构建“离线大规模预训练-在线微调”的两阶段部署框架。需说明, 在线微调特指部署信道上仅依赖已知训练符号的自适应更新, 以离线预训练参数为起点, 在线微调阶段对连续测试帧逐批次更新模型, 每帧的监督仅来自该帧前 $N_p = 50$ 个训练序列符号, 而待判决数据符号的真实标签全程不参与, 二者在标签层面严格隔离。离线预训练阶段在涵盖丰富信道的数据集上学习信道结构的通用表征, 赋予网络较强的初始泛化能力; 在线微调阶段则对预训练模型进行轻量更新, 使其快速适应当前部署环境的信道特性。两阶段在数据规模、参数更新策略与优化器配置上存在显著差异, 分述如下。

2.5.1 离线预训练流程

离线预训练以最大化网络在所有训练信道下的平均符号判决正确率为目标, 对全部参数进行端到端联合优化。采用带权重衰减的 Adam(Adam with Weight decay, AdamW)优化器, 初始学习率 $\eta_{pre} = 5 \times 10^{-4}$, 学习率调度采用 Warmup 与余弦退火相结合的两段式策略。前 $E_{warm} = 20$ 轮内, 学习率由 $0.01\eta_{pre}$ 线性升至 η_{pre} , 避免训练初期参数大幅震荡破坏 RoPE 与多尺度模块的初始结构; 随后 80 轮按余弦规律衰减至 $\eta_{min} = 5 \times 10^{-6}$, 使模型在末期细化判决边界。批量大小 $B_{pre} = 64$, 梯度裁剪阈值 1.0。完整离线预训练流程如算法 1 所示。

算法 1 网络离线预训练流程

输入: 训练集 $\mathcal{D}_{train} = \{(\mathbf{y}^{(i)}, \mathbf{s}^{(i)})\}_{i=1}^{N_{tr}}$; 初始学习率 η_{pre} ; 最低学习率 η_{min} ; Warmup 轮数 E_{warm} ; 总轮数 E_{pre} ; 批量大小 B_{pre} ; 平衡权重 λ

输出: 预训练模型参数 θ_0

- 1) 随机初始化网络参数 θ , 配置 AdamW 优化器与 Warmup-Cosine 学习率调度器
- 2) for $e=1$ to E_{pre} do
- 3) 将 $\mathcal{D}_{train}$ 随机划分为 (N_{tr}/B_{pre}) 个 mini-batch
- 4) for 每个含 B_{pre} 个样本的 mini-batch do
- 5) 依次经式 (5)~(9) 计算 RoPE-Transformer 编码器输出 $\mathbf{Z}$
- 6) 由式 (10)、(11) 得到三尺度分解特征 $\{\mathbf{Z}_1, \mathbf{Z}_2, \mathbf{Z}_3\}$
- 7) 由式 (12)、(13) 得到各分支 BiLSTM 输出与 logits $\{\ell_1, \ell_2, \ell_3\}$
- 8) 由式 (14)~(16) 计算自适应权重 α 与融合 logits ℓ_{final}
- 9) 由式 (18)、(19) 计算平衡损失 $\mathcal{L}_{bal}$
- 10) 由式 (24) 计算 $\mathcal{L}_{CE}$
- 11) 由式 (25) 计算总损失 $\mathcal{L}_{total} = \mathcal{L}_{CE} + \lambda \mathcal{L}_{bal}$
- 12) 反向传播, 按 $\max_norm=1.0$ 裁剪梯度, 更新参数 θ
- 13) end for
- 14) if $e \leq E_{warm}$ then 学习率按线性规律升温
- 15) else 学习率按余弦规律衰减
- 16) end if
- 17) 在验证集上评估 BER, 保存当前最优模型
- 18) end for
- 19) 返回最优模型参数 θ_0

2.5.2 在线微调流程

在线微调阶段在新部署环境下, 对新信道采集到的测试帧整体进行批量自适应, 以批量大小 B_{ft} 将连续测试帧组织成若干 mini-batch, 在其上执行 E_{ft} 个 epoch 的微调。考虑到各模块对信道结构变化的敏感程度不同, 特征嵌入层与 Transformer 编码器负责通用的时序与位置建模, 参数迁移性较强; 而多尺度分解、各尺度 BiLSTM、自适应权重门控与分类头则直接关联当前信道的多径结构与判决边界, 需要更强的更新能力。本文采用分层学习率策略: 特征嵌入层与全部 L_E 层编码器归入低学习率组 $\eta_{\text{low}} = 10^{-5}$; 多尺度分解模块、3 个尺度 BiLSTM、自适应权重模块与 3 个分类头归入高学习率组 $\eta_{\text{high}} = 10^{-4}$ 。两组学习率均按余弦规律同步衰减, 最小学习率比例为 10^{-2} 。微调批量大小 $B_{\text{ft}} = 16$, 轮数为 $E_{\text{ft}} = 100$, 并保持平衡正则项激活, 防止小样本对单一尺度过拟合。完整流程如算法 2 所示。

得益于预训练模型对水声信道结构性特征的有效抽取与分层学习率对参数迁移性的利用, 所提网络在线微调阶段每帧仅以约 50 个训练符号持续更新, 即可在多数信噪比下维持对当前信道的有效适配, 降低通信开销与重新训练模型所需的时间。

2.5.3 在线微调稳定性的含义

两阶段部署框架的可行性, 本质上取决于预

训练所学得的多尺度判决结构在线微调中的稳定性。因此, 需理清“离线大规模预训练-在线微调”与误差保证的关系。式(23)上界 $\kappa \cdot \bar{v} \cdot \bar{R}_\alpha$ 的成立性与紧致度由不同因素决定, 其成立性由 Lipschitz 性保证。由假设 1 - 3, 滑窗输入落在有界紧集内, 有限层网络在有界域上恒为 Lipschitz 映射, 故分支灵敏度 v_m 在初始化、预训练与在线微调的任一状态下均为有限值, 上界恒成立。而上界的紧致度则取决于 $\bar{v}$, 离线预训练在丰富信道集上将 $\bar{v}$ 压低、收紧上界。门控权重 α_m 同样由训练塑造, 但 $\bar{v}$ 与 α_m 在上界中地位不同, $\bar{v}$ 决定上界的绝对水平, 是紧致度的主控变量; 而 α_m 因 softmax 归一化使 $\bar{R}_\alpha$ 恒落于 $[R_1, R_3]$, 故仅在该有界区间内选择工作点、收紧幅度受区间宽度封顶。

在此框架下, 在线微调阶段高低学习率的设定随之清晰。它并非重新塑造 $\bar{v}$, 而是在保持预训练所得低 $\bar{v}$ 的前提下, 经门控调整 α_m , 使 $\bar{R}_\alpha$ 挪至贴

算法 2 在线微调流程

输入: 预训练模型参数 θ_0 ; 测试帧集 $\mathcal{D}_{\text{tgt}} = \{(\mathbf{y}^{(i)}, \mathbf{s}^{(i)})\}_{i=1}^{N_{\text{te}}}$; 其中 $\mathbf{y}^{(i)} = \{y_k\}_{k=1}^N$ 为第 i 帧完整接收序列, $\mathbf{s}^{(i)} = \{s_k\}_{k=1}^N$ 为其对应的完整符号真值序列; 批量大小 B_{ft} ; 分层学习率 $(\eta_{\text{low}}, \eta_{\text{high}})$; 微调轮数 E_{ft} ; 平衡权重 λ

输出: 部署信道全部测试帧的判决符号序列

- 1) 加载预训练模型参数 $\theta \leftarrow \theta_0$
- 2) 按模块对 θ 进行分组:

$$\theta_{\text{low}} = \{ \text{特征嵌入, RoPE - Transformer} \}$$

$$\theta_{\text{high}} = \{ \text{多尺度分解, BiLSTM, 自适应权重, 分类头} \}$$
- 3) 配置 AdamW 优化器, 分别对 $\theta_{\text{low}}, \theta_{\text{high}}$ 赋予初始学习率 $\eta_{\text{low}}, \eta_{\text{high}}$
- 4) for $e=1$ to E_{ft} do
- 5) 将 $\mathcal{D}_{\text{tgt}}$ 随机划分为 $(N_{\text{te}}/B_{\text{ft}})$ 个 mini-batch
- 6) for 每个含 B_{ft} 帧的 mini-batch do
- 7) 取批内各帧前 N_p 个训练符号对 $(\mathbf{y}_{1:N_p}^{(i)}, \mathbf{s}_{1:N_p}^{(i)})$
- 8) 经式 (5)~(16) 前向计算融合 logits ℓ_{final}
- 9) 经式 (18)、(19) 在批样本层面计算平衡损失 $\mathcal{L}_{\text{bal}}$
- 10) 由式 (24) 计算 $\mathcal{L}_{\text{CE}}$
- 11) 由式 (25) 计算总损失 $\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{CE}} + \lambda \mathcal{L}_{\text{bal}}$
- 12) 反向传播, 按 $\text{max_norm} = 1.0$ 裁剪梯度
- 13) 执行 AdamW 更新, θ_{low} 与 θ_{high} 分别按各自学习率优化
- 14) end for
- 15) 按余弦退火规则同步更新两组学习率
- 16) end for
- 17) 加载微调后参数, 对全部测试帧逐 batch 前向推理
- 18) 由式 (17) 取后验最大者, 输出判决 $\{\hat{\mathbf{s}}^{(i)}\}_{i=1}^{N_{\text{te}}}$

合目标信道主导时延尺度的工作点。由假设 4, v_m 已吸收编码器的放大效应、编码器训练后为固定 Lipschitz 映射, 若在 50 符号样本下对编码器施加过强更新, 极易破坏其映射结构。本文的分层学习率正是这一分工的实现: 以低学习率温和更新编码器, 以高学习率更新门控与任务模块, 其跨场景有效性由表 5-6 交叉实验验证。

定理 1 的闭式上界为这一稳定性提供了定量刻画。记离线预训练所用信道环境的物理参数为 $(H_{\text{max}}^{\text{pre}}, \kappa_n^{\text{pre}})$, 对应 Lipschitz 常数 $\kappa^{\text{pre}} = 2AH_{\text{max}}^{\text{pre}} + \kappa_n^{\text{pre}}$; 在线部署目标信道的参数为 $(H_{\text{max}}^{\text{tgt}}, \kappa_n^{\text{tgt}})$, 对应 $\kappa^{\text{tgt}} = 2AH_{\text{max}}^{\text{tgt}} + \kappa_n^{\text{tgt}}$ 。由定理 1, 迁移前后融合软估计的误差上界之差满足:

$$|\kappa^{\text{tgt}} \bar{v} \bar{R}_\alpha - \kappa^{\text{pre}} \bar{v} \bar{R}_\alpha| \leq \bar{v} R_{\max} \cdot (2\Delta H_{\max} + \Delta \kappa_n) \quad (26)$$

其中 $\Delta H_{\max}$ 与 $\Delta \kappa_n$ 分别为目标与预训练信道在总增益与噪声变化率上的差异, $R_{\max} = \max R_m$ 为各分支感受野长度的上确界。需要说明的是, 式(26)刻画的是在自适应权重 α 保持不变时, 迁移误差上界仅由信道物理参数变化 ($\Delta H_{\max}, \Delta \kappa_n$) 所引起的漂移; 在线微调阶段对 α 的进一步调整属于该上界之内的细化, 不改变此处的结构性刻画。

式(26)表明, 在假设 1-4 成立的前提下, 当目标信道与预训练信道的物理参数差异有界时, 误差上界的变化也按线性比例受控, 各尺度分支的误差上界不致被异常放大。需强调, 该式刻画的是误差上界在信道迁移下的结构稳定性, 而非微调所需训练符号数的样本复杂度结论。其意义在于, 预训练所学到的多尺度判决结构在迁移过程中保持有效, 分层学习率下的微调原则上只需补偿与 ($\Delta H_{\max}, \Delta \kappa_n$) 同量级的判决边界漂移, 而无需重建多尺度时序表征。这一结构可迁移性与“以少量训练符号完成在线适配”的设计目标一致, 并为第 3 节实验中观察到的小样本快速适配现象提供了定性解释; 对于所提的 50 个训练符号是否充分, 仍由实验予以验证。

3 仿真与海试实验

为系统评估所提算法在水声多径信道下的均衡性能与泛化能力, 本章分别基于公开标准数据集 WATERMARK 与南海实测海试数据开展验证。仿真部分用于在公开信道环境下对比不同方法的稳态性能并量化各模块贡献, 海试部分则进一步检验所提网络在真实部署条件下的鲁棒性与小样本在线微调能力。所有实验在 NVIDIA RTX 4090 GPU 上完成, 软件框架为 PyTorch 2.8.0。

3.1 WATERMARK 数据集仿真验证

3.1.1 仿真信道与实验配置

本节采用 WATERMARK 公开水声信道数据集对所提方法开展性能仿真^[33]。该数据集包含多组实测时变信道冲激响应, 涵盖近岸浅海、峡湾与大陆架等典型传播环境。

本文选取其中两组具有代表性的信道场景开展验证, 实验示意如图 3 所示, 测量条件见表 1。

需说明, 本文针对每类传播环境分别进行离线预训练与在线微调, 而非以混合多种环境的数据训




图 3 基于 WATERMARK 的仿真信道实验及示意图

(a)NOF1 实验态势图, (b)NOF1 动态水声信道冲激响应 (c)NCS1 实验态势图, (d)NCS1 动态水声信道冲激响应

表 1 仿真所选信道测量条件

名称	NOF1	NCS1
测量环境	挪威峡湾	挪威大陆架
测量月份	6月	6月
收发距离(m)	750	540
水深(m)	10	80
发射机部署方式	坐底	坐底
接收机部署方式	坐底	坐底
时延扩展(ms)	128	32
仿真信道训练数	1000	1000
仿真信道部署数	100 (额外留取)	100 (额外留取)

练统一模型。NOF1 与 NCS1 各自在本环境的信道集合上独立完成离线预训练, 并在同一环境新采集、未参与训练的信道上在线微调。此处“同一环境”指同类传播条件而非固定信道, 所选信道为该环境下实测的时变冲激响应, 其衰落与时延本身随时间漂移, 且部署所用信道 (表 1 中额外留取的 100 组) 与训练信道实现互不重叠。

通信系统仿真采用无信道编码的 QPSK 单载波体制, 符号速率 $R_s = 500\text{baud}$, 符号宽度 $T_s = 2\text{ms}$, 采样速率 $f_s = 16\text{kHz}$ 。发射端采用滚降因子 $\beta = 1$ 、跨度 8 个符号的根升余弦滤波器。发射帧结构如

图 4 所示。单个通信帧首尾各置一段持续 50ms 的线性调频 (Linear Frequency Modulation, LFM) 信号用于同步、粗多普勒估计与补偿, 并辅以保护间隔 (Guard Interval, GI)。单帧数据块由 50 个训练符号与 950 个数据符号构成。系统通信速率计算为:

$$R = \frac{N_b}{T_1} = \frac{(N_t - N_p) \log_2 M}{T_1} \approx 864\text{bit/s} \quad (26)$$

其中, N_b 为一帧发射信号中的有效传输比特数, N_t 和 N_p 为单帧传输 QPSK 符号和训练序列符号, T_1 为一帧中 LFM、GI、数据符号以及训练序列持续的总时间。具体仿真参数见表 2。

表 2 仿真参数设置

参数	取值
调制方式	QPSK
编码方式	无编码
调制阶数 M	4
采样速率(Hz)	16000
符号宽度(ms)	2
脉冲成形滤波器	根升余弦
滚降因子	1
滤波器跨度	8 个符号
输入序列长度 K_w	1000
单帧传输总符号数 N_t	1000
单帧传输训练序列符号数 N_p	50
单帧有效比特数 N_b	1900

当在线微调使用的训练符号数 N_p 由 50 增至 100、200 时, 帧结构与单帧总时长不变, 有效数据符号数由 950 减至 900、800, 对应有有效传输速率由 864 bit/s 降至 818、727 bit/s。

3.1.2 仿真信道性能对比分析

为系统验证所提方法(RoMAFNet)的性能优势, 本节选取覆盖水声深度学习均衡演进各阶段的五种代表性方法对比。所有方法均采用相同的训练数据划分、训练轮数与“离线大规模预训练-在线微调”两阶段实验协议, 以保证对比公平。

1) SCABNet[17]: 基于残差学习与跳跃连接的水声通信接收机, 通过浅深层特征重用缓解梯度消失, 代表早期卷积架构的深度学习均衡器。

2) 1DCNN+LSTM[19]: 耦合一维 CNN 与 LSTM 的混合架构, 在频域提取特征并以 LSTM 完成时序建模, 代表经典 CNN-LSTM 类时序均衡方法。

3) UDNet[24]: 基于深度展开的水声信道均衡器, 将经典最小均方误差均衡器逐层展开为前馈网络, 代表模型驱动的深度展开方法。

4) DenseNet[25]: 基于密集连接卷积网络的均衡器, 通过层间密集直连实现深度特征复用, 代表

大规模卷积架构方法。

5) TimeMixer[29]: 通用领域的可分解多尺度混合时序预测框架, 本文将其适配至水声单变量复值场景, 代表通用多尺度建模方法。

离线预训练阶段, 在 NOF1 与 NCS1 信道下, 分别选 1000 组信道冲激响应作为训练信道集, 每组信道生成 200 个发射帧, 共构建 2×10^5 帧训练样本。各模型按算法 1 进行端到端优化。在线微调阶段, 另取 100 组信道作为新部署环境下的测试信道集, 每组信道生成 200 个测试帧。对部署信道的全部连续测试帧以 $B_{ft} = 16$ 组织成多个 mini-batch, 各帧仅利用其帧内前 $N_p = 50$ 个训练序列符号执行算法 2 的在线自适应流程, 随后对该帧剩余 950 个数据符号进行判决并统计通信误码率(Bit Error Rate, BER); 数据符号的真实标签不参与该过程, 且帧间参数以预训练模型为起点持续更新、不重置。本文方法与对比方案在两种信道环境下的误码率曲线对比如图 5 所示。

图 5 的 (a)、(b) 分别给出各方法在 NOF1 和 NCS1 信道下信噪比(Signal-to-Noise Ratio, SNR)取 -10dB 至 15dB (步长 5dB) 的 BER 性能曲线, 纵轴采用对数刻度, 插图为 -8dB 至 -2dB 区间的局部放大视图。

NOF1 信道虽然时延扩展较长 (约 128ms), 但由图 3 的信道冲激响应可见其多径结构相对稳定, 能量集中于直达径与若干离散反射径上, 衰落平缓。图 5(a)显示, RoMAFNet 在全 SNR 范围内显著优于所有对比方法, 当 SNR ≥ 0 dB 时 BER 即压低至 10^{-3} 量级以下; SNR=15dB 时降至 2.4×10^{-5} , 相比次优的 TimeMixer 仍有相当优势, 相较于 SCABNet 性能提升超过一个数量级。由插图可见, 低信噪比区

间 RoMAFNet 仍保持领先, 表明所提 MAF 机制在噪声主导阶段仍能有效区分多径分量。

NCS1 信道的时延扩展较短 (约 32ms), 但多径密集、衰落剧烈, 时变情况显著高于 NOF1, 对均衡器的快速跟踪能力要求更高。图 5(b)显示, 受信道复杂度影响, 各方法 BER 整体上升约一个数量级, 但 RoMAFNet 仍稳定最优。SNR=15dB 时 BER 约为 3×10^{-3} , 较 TimeMixer 有约 5dB 增益, 较 DenseNet 与 SCABNet 提升超一个数量级。值得注意的是, UDNet 与 1DCNN+LSTM 在两信道




图4 仿真连续发射数据组合帧结构


下的相对排序发生互换,反映出固定结构的均衡器在不同时变特性下难以保持稳定排名,而所提网络借助自适应尺度门控可动态调整分支贡献,在两种差异显著信道下均维持稳健。

综合两信道结果可观察到, RoMAFNet 相对次优方法的性能优势在 NOF1 长时延稳态信道下更为显著,而在 NCS1 短时延强时变信道下相对收窄。这与第 2.3.4 节定理 1 所揭示的趋势相符。即当信道更平稳、信号平滑性参数 κ 越小时,加权融合输出的误差上界 $\kappa \cdot \bar{v} \cdot \bar{R}_a$ 越紧,所提方法越能逼近其最优工作点。当信道时变剧烈使 κ 增大时,该上界随之放宽。


从对比方法的整体表现亦可看出水声深度学习均衡的演进脉络。缺乏显式时序建模的 SCABNet 与 DenseNet 在高 SNR 区出现明显误码平台; 1DCNN+LSTM 与基于深度展开的 UDNet 性能有所改善,但仍受限于单一时间建模; TimeMixer 验证了多尺度建模在水声场景的有效性,但其面向平稳数据的固定混合策略难以适应快时变特性。RoMAFNet 则一方面以 RoPE 注入相对位置感知强化长时延 ISI 建模,另一方面以自适应门控与平衡正则实现对不同信道环境的动态适配,因而在两种信道下均取得最优。

需特别指出,上述全部性能均在仅 $N_p = 50$ 个训练符号、 $E_{\text{tr}} = 100$ 轮在线微调的条件下取得,相比离线预训练每帧 1000 个符号,部署时训练序列开销仅 5%。从实验层面印证了第 2.5.3 节给出的在线微调稳定性结论。得益于离线预训练对多尺度判决结构的有效抽取以及分层学习率策略对低层通用表征的保护,所提网络以较小的训练符号即可适配新信道,为低开销部署提供了一种可行方案。

为定量解析各核心模块的边际贡献,本节在 NOF1 与 NCS1 信道下以完整模型 M7 为基准构造 M1 - M6 六组消融变体,通过仅相差单一模块的受控对比逐一考察 RoPE、MAF 与 BiLSTM 的作



(a) NOF1 信道环境



(b) NCS1 信道环境

图5 不同信道环境下 RoMAFNet 均衡性能

用。各变体的网络宽度、层数与训练超参数同 2.5 节,并执行相同的两阶段流程。表 3-表 4 分别给出两信道下各变体在不同信噪比下的 BER,加粗为最优、下划线为次优。为便于参考,表中列出了各变体的参数量(Param/M)与计算量(FLOPs/G);需强调,本组消融旨在验证模块各自及其组合的正向增益,BER 性能仍是首要关注指标,参数量与计算量仅作为辅助性参考信息。

首先考察 RoPE 模块。RoPE 为对查询/键向量的无参数旋转,替换正弦绝对编码不引入任何可学

习参数与计算量。表3-表4中M1与M3、以及含相同SE与BiLSTM的M2与M6，即为两组参数量与计算量完全相同、仅位置编码不同的对照。在M1与M3对比中，NOF1信道SNR=15dB时BER由 1.23×10^{-3} 降至 2.63×10^{-4} ，NCS1信道同信噪比下由0.190降至0.025，下降近一个数量级。M2与M6在NCS1同条件下由 3.29×10^{-2} 降至 9.06×10^{-3} 。在严格等参数量、计算量下BER仍跨信道一致改善，说明该增益纯由结构而非容量带来。其根源在于RoPE以乘性方式将相对时延嵌入注意力计算，契合水声ISI由相对时延主导的物理本质，且在离线（1000符号）与在线（50符号）序列长度差异显著时仍保持鲁棒，可作为即插即用模块嵌入现有Transformer类均衡网络。

其次考察MAF。从M3与M4对比中可看出，在RoPE编码器输出端引入MAF，可在不依赖BiLSTM的情形下进一步降低BER，NOF1信道SNR=15dB时由 2.63×10^{-4} ，降至 2.01×10^{-4} ，NCS1信道由0.025降至0.013。印证了RoPE与MAF组合的有效性。为排除“提升仅来自参数增多”，将其与以BiLSTM替代MAF的M5对照，M4(2.085 M、8.106 GFLOPs)的参数量与计算量均小于M5(2.475 M、9.013 GFLOPs)，但在时变更剧烈的NCS1信道上BER反而更低。

即在更具挑战性的信道上，MAF以更小的容量取得了更优的结果，表明M3到M4的增益源于

MAF依多径传播规律所做的物理结构分解，而非单纯扩大模型规模；BiLSTM仅在多径结构稳定的NOF1信道上凭借额外容量略占优（M5优于M4）。此外，M3与M5实验对比中通过单独引入BiLSTM虽在NOF1信道的高信噪比区降至 6.8×10^{-5} ，但低信噪比区略有回落，反映单一时间尺度的BiLSTM在噪声主导阶段对噪声样本较为敏感，从反面印证了多尺度分支的必要性。

最后对比仅以压缩激励(Squeeze-and-Excitation, SE)注意力加权的M6与完整模型M7。二者均含RoPE与BiLSTM，区别在于以MAF的多尺度分解替换M6的SE通道重加权；M7在NOF1信道SNR=15 dB时BER由 5.4×10^{-5} 降至 2.4×10^{-5} ，NCS1信道由 9.06×10^{-3} 降至 3.14×10^{-3} 。这表明通道维度的注意力无法刻画多径沿时延尺度的能量分布差异，而MAF以膨胀率递增的并行分支在感受野层面显式分离各时延分量、再以帧级自适应门控加权聚合，实现了“结构分解+机制融合”的双重适配。M7参数量(4.655 M)虽在各变体中最大，主要来自三个尺度各自独立的BiLSTM分支；但前述等容量的M2/M6对照与M4/M5对照，已分别将RoPE、MAF的结构增益同模型参数量增加区分开来，故M7取得最优并非容量最大的简单结果。且MAF在时变剧烈的NCS1下相对增益高于NOF1，与定理1一致。当信号平滑性参数增大、感受野方法的误差上界放宽时，MAF通过自适应权重在区

表3 NOF1信道环境网络消融性能对比

指标 编号	模型变体	位置 编码	MAF	Param (M)	FLOPs (G)	NOF1信道不同信噪比环境BER（50个训练符号）					
						-10dB	-5dB	0dB	5dB	10dB	15dB
M1	Transformer (Baseline)	绝对 编码	×	1.618	7.309	0.090247	0.027221	0.008781	0.004831	0.002639	0.001232
M2	Baseline+SE+BiLSTM	绝对 编码	SE通道 注意力	2.491	9.013	0.100654	0.015319	0.001420	0.000289	0.000158	0.000140
M3	RoPE	旋转 编码	×	1.618	7.309	0.088367	0.011986	0.001478	0.000468	0.000297	0.000263
M4	RoPE+MAF	旋转 编码	√	2.085	8.106	<u>0.086030</u>	<u>0.011751</u>	0.001395	0.000401	0.000248	0.000201
M5	RoPE+BiLSTM	旋转 编码	×	2.475	9.013	0.093559	0.013103	0.001143	0.000183	0.000101	0.000068
M6	RoPE+SE+BiLSTM	旋转 编码	SE通道 注意力	2.491	9.013	0.091902	0.012934	<u>0.000947</u>	<u>0.000155</u>	<u>0.000057</u>	<u>0.000054</u>
M7	RoMAFNet（本文方法）	旋转 编码	√	4.655	13.217	0.080317	0.011584	0.000595	0.000091	0.000028	0.000024

表 4 NCS1 信道环境网络消融性能对比

指标 编号	模型变体	位置 编码	MAF	Param (M)	FLOPs (G)	NCS1 信道不同信噪比 BER（50 个训练符号）					
						-10dB	-5dB	0dB	5dB	10dB	15dB
M1	Transformer (Baseline)	绝对 编码	×	1.618	7.309	0.381072	0.364607	0.309316	0.217796	0.208558	0.189584
M2	Baseline+SE+BiLSTM	绝对 编码	SE 通道 注意力	2.491	9.013	0.275550	0.165095	0.071512	0.049122	0.040568	0.032862
M3	RoPE	旋转 编码	×	1.618	7.309	0.203114	0.095429	0.050676	0.035564	0.030652	0.025104
M4	RoPE+MAF	旋转 编码	√	2.085	8.106	<u>0.188886</u>	<u>0.083666</u>	0.036435	0.020196	0.015256	0.013431
M5	RoPE+BiLSTM	旋转 编码	×	2.475	9.013	0.244860	0.108720	0.044027	0.028137	0.025599	0.021578
M6	RoPE+SE+BiLSTM	旋转 编码	SE 通道 注意力	2.491	9.013	0.220861	0.088354	<u>0.025548</u>	<u>0.013134</u>	<u>0.009413</u>	<u>0.009064</u>
M7	RoMAFNet（本文方法）	旋转 编码	√	4.655	13.217	0.169342	0.076448	0.024444	0.007755	0.003922	0.003139

表 5 分层学习率策略在 NOF1 信道的交叉对照

在线微调策略	NOF1 信道不同信噪比 BER（50 个训练符号）					
	-10dB	-5dB	0dB	5dB	10dB	15dB
编码器高学习率	<u>0.081113</u>	<u>0.011595</u>	<u>0.000597</u>	0.000087	<u>0.000029</u>	0.000024
冻结编码器	0.081343	0.012450	0.000659	0.000096	0.000038	0.000027
分层学习率（本文方法）	0.080317	0.011584	0.000595	<u>0.000091</u>	0.000028	0.000024

表 6 分层学习率策略在 NCS1 信道的交叉对照

在线微调策略	NCS1 信道不同信噪比 BER（50 个训练符号）					
	-10dB	-5dB	0dB	5dB	10dB	15dB
编码器高学习率	<u>0.201133</u>	<u>0.085073</u>	<u>0.027932</u>	0.010887	<u>0.006039</u>	<u>0.005934</u>
冻结编码器	0.229448	0.107177	0.041790	<u>0.010566</u>	0.009601	0.006114
分层学习率（本文方法）	0.169342	0.076448	0.024444	0.007755	0.003922	0.003139

间内动态选择有效感受野，部分补偿了上界的扩张。NCS1 信道上参数更少的 M3(1.618 M)优于参数更多的 M2(2.491 M)，且各变体在 NOF1 与 NCS1 上的相对排序随信道发生交换（如 M4 与 M5 的优劣在两信道间互换），这种随信道而变的排序归因于不同结构对不同信道时延扩展与时变特性的适配差异，而非参数规模。考虑到本文面向时变水声信道且在线仅以 50 个训练符号微调，盲目扩大容量不仅增加部署开销，更易在小样本微调中过拟合、损害向新信道的迁移能力。因此本文各模块均依物理先验设计，以结构而非参数量获取增益，这正是 RoMAFNet 在差异显著信道下保持稳健的关键。

综合来看，M7 在两种信道全部六个 SNR 取值上均取得最优，次优位置则在低信噪比区由 M4、在中高信噪比区由 M6 交替占据而无单一变体稳居次席，说明任一单独模块均难以替代三者协同。还需指出，各变体的 BER 并不随参数量单调下降，为验证在线微调中分层学习率对不同信道场景的适应性，本文在 NOF1 与 NCS1 仿真信道上，将三种微调方式（全参数高学习率、冻结编码器、本文分层学习率）在相同预训练模型与微调轮数下对照，结果如表 5-表 6 所示；三者更新范围一致，仅编码器学习率分别对应“过强、为零与折中”。该对照与南海海试范式消融（表 11）中对应三组共同构

成跨三类信道的学习率交叉验证。

由表 5 可见, 结构稳定的 NOF1 上三种方式 BER 极为接近, 表明信道平稳、平滑性参数 κ 较小时式(23)上界本就较紧, 编码器更新强度影响甚微, 本文方法与最优近似持平; 而在强时变的 NCS1 上(表 6)差异显著拉开, 本文分层学习率在全部六个 SNR 取值上均最优。因此 NCS1 时变剧烈使 κ 增大、上界放宽, 全参数高学习率在小样本下过度扰动编码器、抬高 v_m , 冻结编码器又限制适配, 而本文以低学习率守住 v_m 、高学习率适配任务模块, 兼顾稳定与适配。可见所提分层学习率在稳定信道上不劣于其他策略, 在强时变信道上显著占优并规避其高 SNR 退化, 验证了对不同场景的适应性。

3.2 南海海试实验验证

3.2.1 海试场景与实验配置

为进一步验证所提网络在真实海洋环境下的

均衡性能与泛化能力, 研究团队于 2025 年 12 月在南海近海海域开展海试实验。试验区域属典型浅海近岸环境, 试验期间为 3 级海况。试验采用双船协同配置, 发射船与接收船分别搭载发射、接收换能器并稳定停泊于各自指定位置, 收发距离设定为

2250m, 发射与接收换能器布放深度均约为水下 8m, 试验态势示意及信道环境如图 6 所示。

由图 6 所示实测时变冲激响应可见, 相较于 WATERMARK 数据集的两种仿真环境, 南海近海实测信道呈现出更为复杂的多径传播特征, 对均衡算法的多尺度建模与快速跟踪能力均提出了更高要求。

海试发射信号体制、帧结构、训练与部署均与 3.1 节仿真保持一致, 仅采样速率由 16kHz 调整为 14kHz, 发射数据帧的数据块由 200 调整为 250 个。

其余参数取值参见表 2。网络训练采用海试过程所采集的 600 组信道数据, 另取 50 组未参与训练的新信道作为部署测试集。对比方法仍选取与 3.1.2 节相同的 SCABNet、1DCNN+LSTM、UDNet、DenseNet 与 TimeMixer 五种代表性方法, 所有方法的预训练参数、网络规模与微调超参数均保持一致, 以保证对比的公平性与可重复性。

3.2.2 海试信道性能对比分析

本节延续 3.1 节的评估框架开展两组实验。首先, 与五种代表性方法进行海试环境下的均衡性能对比, 系统验证每帧训练符号长度 N_p 取 50、100、200 时的持续在线自适应性能; 其次, 在 $N_p = 50$ 下开展消融分析, 考察各核心模块在真实海洋环境中的边际贡献。

针对均衡性能对比, 表 7 给出各方法在三种 N_p 取值, SNR 由 -10dB 至 15dB 的 BER 性能对比。当 N_p 增至 100、200 时并非改变图 4 帧结构或增设额外训练段, 而是在同一通信帧的数据块内, 将用作微调的训练序列由 50 扩展至 100、200, 扩展部分取自数据符号, 连同其已知标签参与微调, 且这些额外训练符号不计入 BER 统计。因此, 训练符号增大本质上是以有效速率(864、818、727bit/s)的下降换取适配性能的提升。

需客观指出, SCABNet、DenseNet、1DCNN+LSTM 与 UDNet 的参数量更小, 但其在多数信噪比下 BER 明显更高、且在中高 SNR 区出现误码平台, 即以均衡精度换取了更小体量。需明确, 各方法的部署推理耗时由前向计算量(FLOPs)决定, 与离线训练时长无关, 在线阶段仅对预训练模型施加少量训练符号微调, 故训练收敛快慢不会显著放大部署耗时差异。从训练序列长度的影响看, BER 随训练符号数增加的下降速率, 即反映模型对每个额外训练符号的利用效率。以 SNR=15dB 为例, 训练符号




图 6 (a)南海实验态势图, (b)南海实测动态水声信道冲激响应图

长度由 50 增至 100 时, RoMAFNet 的 BER 由 1.74×10^{-2} 降至 2.85×10^{-3} , 降幅约 84%。而 TimeMixer 的同等条件下降幅仅为 36%; 由 100 进一步增至 200 时, RoMAFNet 的 BER 再降至 9.08×10^{-4} , 降幅约 68%, TimeMixer 仅为 18%。这表明 RoMAFNet 能更充分地利用额外的训练符号对预训练表征进行精细化更新, 从工程层面验证了第 2.5.3 节在线微调稳定性结论的合理性。整体来看, 相较于 WATER-MARK 仿真信道, 实测信道下所有方法的 BER 均不同程度上升, 与图 6 所示多径密集、衰落剧烈以及快变特性相吻合。但除 $N_p = 50$ 且 SNR=-10dB 这一极端低信噪比与极小训练符号开销组合下 BER 略高于 TimeMixer 和 SCABNet 外, RoMAFNet 在其余所有组合下均最优。

前文已指出, 仅 $N_p = 50$ 且 SNR=-10dB 这一组合下 RoMAFNet 在线微调增益出现退化, 进一步分析成因, 可归结为两点。一是在线微调以测试帧前

50 个训练符号为标签, 这些符号同样经历低信噪比信道, 自身可靠性下降、小样本微调过程中难以平均掉噪声, 致使梯度更新失效; 二是离线预训练为充分学习信道结构, 在较高信噪比 (15dB) 下进行, 部署至极低信噪比时存在训练与部署的分布偏移, 二者叠加使微调增益收窄。然而, 该边界可随训练符号长度外推, 当 N_p 由 50 增至 100、200 时 BER 由 0.220 依次降至 0.170、0.146, 相对于次优方法均能实现性能提升。故“约 50 符号快速适配”主要适用于中高信噪比区间, 极低信噪比场景宜采用适度增大训练符号长度、纳入更宽训练信噪比范围或辅以外部可靠性增强手段。

考虑到图 4 的帧结构同样适用于传统单载波接收机, 本节在深度学习方法对比之外进一步引入传统均衡基线, 在完全相同的帧结构与前 $N_p = 50$ 个训练符号条件下与所提方法对比, 结果见表 8。所选基线包括: 以 50 个训练符号做 LS 信道估计并据

表 7 南海海试信道环境性能对比

模型指标		RoMAFNet (本文方法)	TimeMixer	UDNet	1DCNN+ LSTM	DenseNet	SCABNet
Param(M)		4.655	16.410	1.125	1.074	0.335	0.064
FLOPs(G)		13.217	17.027	2.237	2.136	0.645	0.123
信噪比/符号数		三种训练序列长度在南海信道不同信噪比 BER (50、100、200 个训练符号)					
-10dB	50	0.220198	0.205501	0.240456	0.267590	0.229237	<u>0.208743</u>
	100	0.169630	<u>0.178290</u>	0.206036	0.213905	0.186167	0.200056
	200	0.145912	0.177644	0.194824	0.197053	<u>0.168284</u>	0.185124
-5dB	50	0.105888	<u>0.108090</u>	0.140772	0.151848	0.137487	0.129285
	100	0.070620	<u>0.090302</u>	0.117542	0.123061	0.100364	0.113411
	200	0.053166	0.087643	0.103836	0.106858	<u>0.087570</u>	0.108057
0dB	50	0.050768	<u>0.058661</u>	0.076565	0.077576	0.095767	0.085651
	100	0.020430	<u>0.040098</u>	0.050106	0.049766	0.057387	0.072541
	200	0.011190	0.035168	<u>0.033680</u>	0.034170	0.046944	0.068197
5dB	50	0.026944	<u>0.028255</u>	0.044732	0.038032	0.080130	0.064106
	100	0.006768	0.020921	0.022219	<u>0.015396</u>	0.042826	0.056942
	200	0.002448	0.017945	0.011348	<u>0.008104</u>	0.032649	0.049732
10dB	50	0.019325	<u>0.020273</u>	0.032907	0.020538	0.074680	0.056449
	100	0.003675	0.015121	0.014018	<u>0.006904</u>	0.037678	0.047895
	200	0.001162	0.012344	0.006164	<u>0.003333</u>	0.028231	0.042178
15dB	50	0.017410	0.018034	0.030399	<u>0.017522</u>	0.069289	0.052525
	100	0.002851	0.011605	0.011489	<u>0.004830</u>	0.036175	0.043596
	200	0.000908	0.009464	0.004434	<u>0.001620</u>	0.026449	0.038121

表8 南海海试信道传统均衡方法及理想上界的性能对比

模型	均衡器系数获取方式	南海信道不同信噪比BER (50个训练符号)					
		-10dB	-5dB	0dB	5dB	10dB	15dB
RoMAFNet (本文方法)	离线预训练+在线微调	0.220198	0.105888	0.050768	0.026944	0.019325	0.017410
LS+MMSE-DFE	块训练+逐符号判决反馈	<u>0.347924</u>	<u>0.235160</u>	<u>0.131262</u>	<u>0.066801</u>	<u>0.044614</u>	<u>0.037325</u>
RLS-DFE	逐符号自适应	0.489783	0.391056	0.204980	0.102957	0.072547	0.067823
MMSE with perfect CSI	已知完整CSI	0.125064	0.041475	0.007889	0.001588	0.000642	0.000452

此设置抽头的LS+MMSE-DFE、以训练符号初始化后逐符号自适应的RLS-DFE,以及假设已知真实信道的MMSE均衡器(MMSE with perfect CSI)作为性能上界参考。文献[34]对有限长MMSE-DFE的系统分析表明,当滤波器长度增至覆盖信道时延扩展对应的抽头跨度后,性能即快速饱和^[34]。据此,本文将MMSE with perfect CSI及其余传统方法的滤波器长度统一设为充分覆盖信道最大时延扩展,确保各方法在结构容量上充分且彼此可比。

如表8所示,在全信噪比范围内RoMAFNet的BER均显著低于可实现的LS+MMSE-DFE与RLS-DFE。MMSE with perfect CSI为已知真实信道的理想上界,仅作参考,不参与最优/次优标记。在三种可实现方法中,RoMAFNet最接近该上界,表明其最充分地逼近了理想MMSE性能,从传统均衡算法对比角度进一步验证了所提方法的有效性。

就计算复杂度而言,设DFE前馈与反馈抽头总数为 N ,则RLS-DFE的每符号复杂度为 $O(N^2)$,LS+MMSE-DFE为每训练块以 $O(N^3)$ 求解最优抽头、再以 $O(N)$ 逐符号判决反馈,而所提网络每符号复杂度由自注意力与前馈网络主导,量级为 $O(L_E \cdot K_w \cdot d + L_E \cdot d^2)$ (K_w 为滑窗长度、 d 为嵌入维度、 L_E 为编码器层数)。客观指出,所提方法的单符号运算量高于上述传统DFE,但其运算高度并行。

如表9所示经NVIDIA RTX 4090 GPU加速后单帧平均推理时间仅2.505 ms,处于工程可行区间。此外,

表9给出了所提网络在线微调的超参数设置与时间开销统计,在线微调以批量大小16、每帧50个训练符号执行100个epoch,每个epoch含781次迭代。其中反向传播与AdamW参数更新占5.947 ms/batch,单帧每epoch的平均微调时间为0.59 ms,涵盖前50个训练符号的前向、反向与参数

更新。

表9 在线微调超参数与时间开销统计

统计值	取值
在线微调 epoch 数 E_{ft}	100
单 epoch 迭代数	781
单 epoch 微调总时间(ms)	7400.3
反向传播+参数更新(ms/batch)	5.947
单帧每 epoch 平均微调时间(ms)	0.59
单帧每 epoch 平均推理时间(ms)	2.505

表10给出50训练符号条件下南海海试消融结果,并列出各变体的参数量与计算量。RoPE、MAF与BiLSTM依次叠加在真实海试信道带来稳定增益,M7在全部SNR取值上均取得最优。值得注意的是,等参数、等计算量的M2与M6(均2.491 M、9.013 GFLOPs)在SNR=15 dB由RoPE带来明显改善(0.0607、0.0332),参数更少的M4(2.085 M, 0.0471)在SNR=15dB环境下优于参数更多的M5(2.475 M,0.0519),再次表明MAF的结构分解较单纯增大模型参数量更高效。具体地,仅含RoPE编码器的变体M3在高信噪比区呈现明显的误码平台,当SNR由5dB增至15dB时,BER仅由0.144微降至0.138,几乎不再随信噪比改善。其原因在于,M3仅依靠自注意力编码器进行全局上下文建模,缺乏BiLSTM的显式时序状态跟踪与多尺度分支对不同时延分量的分离,面对真实海洋信道密集且快变的多径结构时,残余码间干扰无法被充分消除,在高信噪比区取代噪声成为主导误差来源。M4和M5分别引入MAF和BiLSTM模块后,该平台被显著打破,印证了在真实复杂信道下时序建模与多尺度分解并非冗余,而是消除残余多径干扰所必需。M7以MAF替换M6的SE通道注意力后,BER进一步由0.033降至0.017,与定理1揭示

的MAF加权有效感受野在 $[R_1, R_3]$ 内动态择优相一致,印证了多尺度结构分解与自适应门控在真实海洋信道下的协同价值。

为验证并理清在线阶段高低学习率参数更新策略的影响,本节在 $N_p = 50$ 的南海海试信道下构造A1-A7七组对照,如表11所示。结果表明单一阶段均难以胜任部署:未经离线预训练、仅以50个符号从随机初始化训练的A1因样本不足而欠拟合,其BER在0dB之后不再随信噪比改善而下降、于高SNR区甚至回升,表明缺乏先验时模型难以从极少样本学到信道逆映射、残余码间干扰在高信噪比区取代噪声成为主导误差;而仅作离线预训练、在线完全不更新的A2无法适配部署信道与预训练信道间的分布差异,BER在全SNR区反而劣于A1,说明离线先验与在线适配缺一不可。就更新范围而言,仅更新分类头(A3)或门控与分类头(A4)的浅层适配收效有限,15dB时BER仍达0.28与0.27;当更新拓展至多尺度分支等承载多径结构的模块后(A5、A6、A7),BER出现数量级下降。值得注意的是,冻结Transformer、仅更新多尺度分支与分类头的A6(15dB时0.0236)反优于全参数等学习率微调的A5(0.0381),表明在50符号小样本下对预训练编码器施加过强更新易扰动其通用时序与位置表征而引发过拟合。本文所提分层学习率方案(A7)以低学习率温和更新编码器、以高学习率快速适配任务相关模块,在保护通用表征的同时保留

对新信道的微调能力,于全部SNR取值上均取得最优,印证了2.5.2节分层微调设计的合理性。

4 结束语

本文面向水声单载波通信提出信道均衡网络RoMAFNet。该网络以RoPE-Transformer编码器捕获多径时延主导的相对位置依赖,以多尺度自适应多径均衡模块对直达径与不同延迟分量分尺度解耦建模,兼顾全局上下文与局部多径特征;在此基础上构建“离线预训练-在线微调”两阶段部署框架,并在Lipschitz平滑性等假设下推导融合机制的误差闭式上界与在线微调稳定性分析。仿真与海试表明,所提网络在部署信道上每帧仅以约50个训练序列符号持续更新,即可在多数信噪比下维持对新信道的有效适配,为低开销下的稳健符号恢复提供了一种可行途径。

附录引理1的证明:由式(2),在信道相干时间内可近似认为信道抽头时不变,记 $h_l(a) \approx h_l(b) \triangleq h_l$ 。将 $y(a) - y(b)$ 发送符号项与噪声项展开并应用三角不等式,可得

$$|y(a) - y(b)| \leq \sum_{l=0}^{L_h-1} |h_l| \cdot |s(a-l) - s(b-l)| + |w(a) - w(b)|$$

由假设1,恒模约束给出 $|s(a-l) - s(b-l)| \leq 2A$;由

假设2,信道总增益有界给出 $\sum_{l=0}^{L_h-1} |h_l| \leq H_{\max}$;

由假设3,噪声平滑性给出 $|w(a) - w(b)| \leq \kappa_n \cdot |a - b|$ 。代入上式得

表 10

南海海试信道环境网络消融性能对比

指标 编号	模型变体	位置 编码	MAF	Param (M)	FLOPs (G)	南海信道不同信噪比BER (50个训练符号)					
						-10dB	-5dB	0dB	5dB	10dB	15dB
M1	Transformer (Baseline)	绝对 编码	×	1.618	7.309	0.430489	0.387741	0.320924	0.240626	0.201097	0.189715
M2	Baseline+SE+BiLSTM	绝对 编码	SE通道 注意力	2.491	9.013	0.283531	0.201211	0.130784	0.083527	0.065774	0.060700
M3	RoPE	旋转 编码	×	1.618	7.309	0.328952	0.217586	0.161741	0.144152	0.138628	0.138481
M4	RoPE+MAF	旋转 编码	√	2.085	8.106	<u>0.241087</u>	<u>0.133883</u>	<u>0.079782</u>	0.058163	0.049578	0.047058
M5	RoPE+BiLSTM	旋转 编码	×	2.475	9.013	0.301165	0.187212	0.098005	0.074111	0.057669	0.051866
M6	RoPE+SE+BiLSTM	旋转 编码	SE通道 注意力	2.491	9.013	0.299499	0.191217	0.094741	<u>0.049928</u>	<u>0.037193</u>	<u>0.033171</u>
M7	RoMAFNet (本文方法)	旋转 编码	√	4.655	13.217	0.220198	0.105888	0.050768	0.026944	0.019325	0.017410

表 11

离线预训练-在线微调范式消融实验性能对比

指标 编号	模型变体	离线 预训 练	在线阶段更新模 块	南海信道不同信噪比BER (50个训练符号)					
				-10dB	-5dB	0dB	5dB	10dB	15dB
A1	无离线预训练, 仅用 50 个训练符号从随机初始化模型训练	×	全参数随机初始化训练	0.264230	0.152763	0.111408	0.132436	0.111915	0.163417
A2	仅离线预训练, 在线不微调	√	不更新	0.497018	0.372185	0.315265	0.303302	0.299193	0.297707
A3	离线预训练 + 只更新分类头	√	分类头	0.412197	0.336827	0.300364	0.288148	0.282475	0.281212
A4	离线预训练 + 只更新门控和分类头	√	门控模块、分类头	0.405722	0.332401	0.291999	0.276979	0.269920	0.267263
A5	离线预训练 + 全参数微调	√	全参数等学习率微调	0.227980	<u>0.105920</u>	0.058126	0.052477	0.044953	0.038095
A6	冻结 Transformer, 仅更新多尺度分支与分类头	√	多尺度分支、分类头	<u>0.221839</u>	0.110235	<u>0.051557</u>	<u>0.031555</u>	<u>0.025931</u>	<u>0.023649</u>
A7	分层学习率 (本文方法)	√	全参数分层学习率微调	0.220198	0.105888	0.050768	0.026944	0.019325	0.017410

$$|y(a) - y(b)| \leq 2AH_{\max} + \kappa_n \cdot |a - b|$$

注意到符号率采样下任意不同时刻满足 $|a - b| \geq 1$, 因此 $2AH_{\max} \leq 2AH_{\max} \cdot |a - b|$, 从而有

$$|y(a) - y(b)| \leq (2AH_{\max} + \kappa_n) \cdot |a - b| = \kappa \cdot |a - b|$$

证毕。

引理 2 的证明: 由假设 4, 对所有满足 $|\tau - k| \leq R_m$ 的 τ 有

$$|y_m(\tau) - y_m(k)| \leq \kappa \cdot |\tau - k| \leq \kappa \cdot R_m$$

从而 $\sup_{|\tau - k| \leq R_m} |y_m(\tau) - y_m(k)| \leq \kappa \cdot R_m$ 。代入式(21)即得

(22)。证毕。

定理 1 的证明: 由式(15)中 softmax 的归一化性质

$\sum_{m=1}^3 \alpha_m(k) = 1$ 与 $\alpha_m(k) \geq 0$, 可将 $\hat{x}(k) - s(k)$ 改写为各分支误差的加权和:

$$\begin{aligned} \hat{x}(k) - s(k) &= \sum_{m=1}^3 \alpha_m(k) \hat{x}_m(k) - s(k) = \\ &\sum_{m=1}^3 \alpha_m(k) [\hat{x}_m(k) - s(k)] \end{aligned}$$

两端取绝对值, 由三角不等式与权重非负性

$$|\hat{x}(k) - s(k)| \leq \sum_{m=1}^3 \alpha_m(k) \cdot |\hat{x}_m(k) - s(k)|$$

对右端每一项应用引理 2, 可得

$$\begin{aligned} |\hat{x}(k) - s(k)| &\leq \sum_{m=1}^3 \alpha_m(k) \cdot v_m \kappa R_m = \kappa \cdot \\ &\sum_{m=1}^3 \alpha_m(k) v_m R_m \end{aligned}$$

即得式(23)的第一个不等号。进一步注意到对每个 m 有 $v_m \leq \bar{v}$, 将其代入上式右端并将 $\bar{v}$ 从求和号中提出, 可得

$$\kappa \cdot \sum_{m=1}^3 \alpha_m v_m R_m \leq \kappa \cdot \bar{v} \cdot \sum_{m=1}^3 \alpha_m R_m = \kappa \cdot \bar{v} \cdot \bar{R}_\alpha$$

即得式(23)的第二个不等号。

综合上述两步, 定理得证。

参考文献:

- [1] Stojanovic M, Preisig J. Underwater acoustic communication channels: propagation models and statistical characterization[J]. IEEE Communications Magazine, 2009, 47(1): 84-89.
- [2] 段瑞洋, 王景璟, 杜军, 等. 面向“三全”信息覆盖的新型海洋信息网络[J]. 通信学报, 2019, 40(4): 10-20.
- [3] 杨健敏, 王佳惠, 乔钢, 等. 水声通信及网络技术综述[J]. 电子与信息学报, 2024, 46(1): 1-21.
- [4] 伍飞云, 杨坤德, 童峰. 部分范数约束的稀疏恢复算法及其在单载波水声数据遥测中的应用[J]. 通信学报, 2018, 39(6): 127-132.
- [5] 王海斌, 汪俊, 台玉朋, 等. 水声通信技术研究进展与技术水平现状[J]. 信号处理, 2019, 35(9): 1441-1449.
- [6] 张友文, 黄福朋, 兰华林, 等. 水声单载波调制技术综述[J]. 哈尔滨工程大学学报, 2019, 40(11): 1809-1815.
- [7] Stojanovic M, Catipovic J, Proakis J G. Adaptive multichannel combining and equalization for underwater acoustic communications[J]. The Journal of the Acoustical Society of America, 1993, 94(3): 1621-1631.
- [8] Stojanovic M. Recent advances in high-speed underwater acoustic communications[J]. IEEE Journal of Oceanic Engineering, 1996, 21(2): 125-136.
- [9] Bianco M J, Gerstoft P, Traer J, et al. Machine learning in acoustics: theory and applications[J]. The Journal of the Acoustical Society of America, 2019, 146(5): 3590-3628.
- [10] Liu J, Zhao H, Ma D, et al. Theoretical analysis of deep neural networks in physical layer communication[J]. IEEE Transactions on Communications, 2022, 70(10): 6589-6603.
- [11] 张永霖, 王海斌, 李超, 等. 水声通信中的信道估计与机器学习交叉研究进展[J]. 声学技术, 2022, 41(3): 334-345.

- [12] 赵昊, 季飞, 李杰, 等. 水声通信物理层技术综述: 从模型驱动到数据驱动[J]. 电信科学, 2025, 41(10): 13-28.
- [13] 陈友淦, 许肖梅. 人工智能技术在水声通信中的研究进展[J]. 哈尔滨工程大学学报, 2020, 41(10): 1536-1544.
- [14] Zhang Y, Li J, Zakharov Y V, et al. Deep learning based single carrier communications over time-varying underwater acoustic channel[J]. IEEE Access, 2019, 7: 38420-38430.
- [15] Jiang R, Wang X, Cao S, et al. Deep neural networks for channel estimation in underwater acoustic OFDM systems[J]. IEEE Access, 2019, 7: 23579-23594.
- [16] Zhang Y, Wang H, Li C, et al. On the performance of deep neural network aided channel estimation for underwater acoustic OFDM communications[J]. Ocean Engineering, 2022, 259: 111518.
- [17] Zhang Y, Chang J, Liu Y, et al. Deep learning and expert knowledge based underwater acoustic OFDM receiver[J]. Physical Communication, 2023, 58: 102041.
- [18] Zhang Y, Li C, Wang H, et al. Deep learning aided OFDM receiver for underwater acoustic communications[J]. Applied Acoustics, 2022, 187: 108515.
- [19] Liu L, Cai L, Ma L, et al. Channel state information prediction for adaptive underwater acoustic downlink OFDMA system: deep neural networks based approach[J]. IEEE Transactions on Vehicular Technology, 2021, 70(9): 9063-9076.
- [20] Qiao G, Liu Y, Zhou F, et al. Deep learning-based M-ary spread spectrum communication system in shallow water acoustic channel[J]. Applied Acoustics, 2022, 192: 108742.
- [21] Liu S, Zuberi H H, Arfeen Z, et al. Spectral efficient neural network-based M-ary chirp spread spectrum receivers for underwater acoustic communication[J]. Arabian Journal for Science and Engineering, 2024, 49(12): 16593-16609.
- [22] Feng X, Zhou M, Wang J, et al. Model-driven deep learning-based estimation for underwater acoustic channels with uncertain sparsity[J]. IEEE Transactions on Wireless Communications, 2024, 23(6): 5710-5725.
- [23] Khan M A, Liu S, Bilal M, et al. Low probability of detection constrained covert underwater acoustic communication receiver using autoencoders[J]. IEEE Transactions on Communications, 2026, 74: 1350-1361.
- [24] Zhao H, Yang C, Xu Y, et al. Model-driven based deep unfolding equalizer for underwater acoustic OFDM communications[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 6056-6067.
- [25] Liu S, Adil M, Ma L, et al. DenseNet-based robust channel estimation in OFDM for improving underwater acoustic communication[J]. IEEE Journal of Oceanic Engineering, 2025, 50(2): 1518-1537.
- [26] Jing L, Zhou X, Shi W, et al. Delay-doppler domain underwater acoustic channel prediction using multi-scale convolutional LSTM[J]. IEEE Internet of Things Journal, 2026, 13(4): 7030-7039.
- [27] Xu M, Liu L. TFLM: a time-frequency domain learning model for underwater acoustic signal reconstruction[J]. Signal Processing, 2025, 233: 109936.
- [28] Liu L, Ma C, Duan Y, et al. Kernel adaptive filter-based channel prediction for adaptive underwater acoustic OFDMA system[J]. Applied Ocean Research, 2025, 158: 104586.
- [29] Wang S, Wu H, Shi X, et al. TimeMixer: decomposable multiscale mixing for time series forecasting[C]//International Conference on Learning Representations (ICLR). 2024.
- [30] Hu Y, Liu P, Zhu P, et al. Adaptive multi-scale decomposition framework for time series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2025, 39(16): 17359-17367.
- [31] Chitre M A, Potter J R, Ong S H. Optimal and near-optimal signal detection in snapping shrimp dominated ambient noise[J]. IEEE Journal of Oceanic Engineering, 2006, 31(2): 497-503.
- [32] Mahmood A, Chitre M, Armand M A. On single-carrier communication in additive white symmetric alpha-stable noise[J]. IEEE Transactions on Communications, 2014, 62(10): 3584-3599.
- [33] van Walree P A, Socheleau F X, Otnes R, et al. The watermark benchmark for underwater acoustic modulation schemes[J]. IEEE Journal of Oceanic Engineering, 2017, 42(4): 1007-1018.
- [34] Al-Dhahir N, Cioffi J M. MMSE decision-feedback equalizers: finite-length results[J]. IEEE Transactions on Information Theory, 1995, 41(4): 961-975.