

基于响应生成网络的水声信道估计方法

徐明, 张琦

(上海海事大学信息工程学院, 上海 201306)

摘 要: 为了解决水声通信环境下信道估计精度低的问题, 提出了一种基于响应生成网络的水声信道估计方法。首先, 基于 MIMO-OTFS 水声信道特性建立水声冲激响应模型。在此基础上, 提出了一种采用时滞补偿的局部化分析算法对水声信号进行三维重建, 降低水声信道动态变化带来的特征误差。然后, 考虑到 OTFS 时延-多普勒矩阵容易受噪声污染而导致矩阵的扩展和失真问题, 提出了一种信号自迭代更新网络, 并根据 L1-正则化最小二乘法对网络权重与偏置进行更新, 从而对生成网络的输入信号进行更新。最后, 针对传统水声信号深度学习模型训练稳定性不佳的问题, 提出了一种基于 Bures-Wasserstein 目标函数的分解优化算法, 将响应生成网络的训练分解为多个子问题进行优化求解, 提高了模型收敛速度并降低了误差。实验结果表明, 所提方法在信噪比为 5 dB 时, 信道估计的归一化均方误差低至 0.04。此外, 与其他方法相比, 所提方法估计的时延-多普勒响应热力图中信号峰的模糊程度更低, 信号失真更小。

关键词: 响应生成网络; 时滞补偿; 时延-多普勒; 归一化均方误差

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025071

Underwater acoustic channel estimation method based on response generative network

XU Ming, ZHANG Qi

College of Information Engineering, Shanghai Maritime University, Shanghai 201306, China

Abstract: To address the issue of low channel estimation accuracy in underwater acoustic communication environments, an underwater acoustic channel estimation method based on the response generative network (RGNet) was proposed. First, an underwater acoustic impulse response model based on MIMO-OTFS channel characteristics was established. On this basis, a time-delay-compensated localized analysis algorithm was proposed for 3D reconstruction of underwater signals to reduce feature errors caused by the dynamic changes of the channels. Considering OTFS time-delay-Doppler matrix's susceptibility to noise pollution, which leads to matrix expansion and distortion, a self-iterative signal updating network was proposed. The input signal of the generative network was updated by a weight and bias update algorithm based on L1-regularized least squares. Finally, to address the instability of traditional deep learning models for underwater acoustic signals, a decomposed optimization algorithm based on Bures-Wasserstein objective function was proposed. The convergence process of the objective function was decomposed into several sub-problems to improve the model's convergence speed and reduce errors. Experimental results show that the proposed method achieves a normalized mean square error of 0.04 for channel estimation at a signal-to-noise ratio of 5 dB. Moreover, compared with other methods, the proposed method achieves lower signal peak blur and less signal distortion in the time-delay and Doppler response heat maps.

Keywords: response generative network, time-delay compensation, delay-Doppler, normalized mean squared error

收稿日期: 2025-02-10; 修回日期: 2025-04-07

通信作者: 徐明, mingxu@shmtu.edu.cn

基金项目: 国家自然科学基金资助项目(No.62172269)

Foundation Item: The National Natural Science Foundation of China (No.62172269)

0 引言

海洋通信与传统无线通信领域类似,支持多种需求和应用场景。但是在潜艇通信、水下探测器、水下运输以及海洋观测和监测等水下场景中,海洋通信面临独特挑战。水声信号在传播过程中经历多次反射,形成多条传播路径,进而引发路径之间异质的多普勒频移与时延,使水声信道表现出显著的时变特性。同时,由于水中声速远低于电磁波在空气中的传播速度,因此相同速度的相对运动会产生更显著的多普勒频移。水声信道的快速时变、高多普勒扩展等特性会破坏传统正交频分复用(OFDM, orthogonal frequency division multiplexing)子载波之间的正交性,导致子载波间产生干扰,从而使信号的信噪比(SNR, signal-to-noise ratio)显著降低,并引发严重的误码效应^[1]。因此,传统OFDM在高噪声和高多普勒环境下难以满足水声通信需求。正交时频空(OTFS, orthogonal time frequency space)调制技术^[2-3]能够精确建模信道中的时延与多普勒效应,适应水声信道的快速时变与多径特性。通过将信号映射至时延-多普勒(DD, delay-Doppler)二维域,可以抑制多普勒扩展带来的性能退化,增强系统在高动态环境下的抗干扰能力。OTFS调制技术同时具备良好的多径分辨能力,有助于提升信道估计与信号恢复精度,增强数据传输速率。在多输入多输出(MIMO, multi-input multi-output)系统中,OTFS随阵列阶数提升可进一步提高频谱效率,有效缓解多径衰落的影响。目前,主流的OTFS信道参数估计算法,如稀疏贝叶斯学习算法^[4]和3D结构正交匹配追踪(OMP, orthogonal matching pursuit)算法^[5],分别通过稀疏贝叶斯学习框架和正交匹配追踪算法,将信道估计问题转化为稀疏信号恢复问题。然而,水声信道的强时变特性导致时延、多普勒和角度的稀疏性结构变化^[6],使基于稀疏信号恢复的信道估计算法的性能显著下降^[7],因此不适用于水下时变信道的参数估计。

为实现水下时变信道的参数估计,文献[8]结合路径时延和多普勒扩展信息,将OMP算法与最大后验(MAP, maximum a posteriori)概率估计相结合,通过先验知识与观测数据抑制噪声,提高信道估计精度。但该方法难以实时跟踪水声信道稀疏度的动态变化,导致参数估计滞后并引发误差积累,影响信号解调性能。文献[9]提出了一种基于

时延-多普勒对齐调制的自适应信号正交匹配追踪(ASOMP-SR, adaptive signal and OMP for spatial reuse)算法进行环境感知和信道估计,但是水声信道的快速时变特性和非稀疏成分会导致路径不变时间较短,从而影响信道估计性能。文献[10]提出了期望最大化算法联合估计信道冲激响应(CIR, channel impulse response)、残余噪声和信道协方差矩阵,但其将MIMO信道协方差矩阵建模为块对角结构,在复杂水声环境下易陷入不收敛问题。基于自适应滤波的信道估计方法^[11-13]通过动态调整估计权重,实现对时变信道的实时跟踪,但是包含噪声的伪信号会影响滤波器输出与期望输出之间的残差^[14-15],导致权重估计偏离真实值。文献[16]提出了一种基于序列导频的匹配滤波信道估计方法,利用互相关匹配滤波估计小数倍多普勒抽头和信道增益,从而获取信道状态信息。然而,在水声环境下,小数倍多普勒效应可能会导致误差积累^[17],从而影响估计精度。

近年来,深度学习技术在复杂环境条件下的建模中展现出了独特优势^[18]。在信道估计方面,深度神经网络能够通过学习复杂的非线性关系来减轻信道噪声和载波间干扰的影响^[19],从而提高信道估计精度。文献[20]提出了基于低密度近似消息传递(LDAMP, low-density approximate message passing)网络学习信道结构并进行信道估计,但该方法依赖大量训练数据,难以适应动态变化且数据受限的水下多径信道,且鲁棒性不足。文献[21]提出的空间频率ECAUNet++(SF-ECAUNet++)方法结合子载波的空间与频率相关性进行信道压缩与重构,提升估计精度与鲁棒性,但该方法同样依赖大规模训练数据以确保泛化能力。文献[22]提出了一种两步正交匹配追踪信道状态信息估计方法,使用带有Noise2Void(N2V)学习策略的压缩激励残差网络进行去噪与信道估计,可在低采样率下恢复细粒度信道信息。文献[23]提出了一种混合编码器-解码器结构(称为HA02),利用Transformer编码器提取输入信号的稀疏特征,结合残差网络解码器获得较好的均方误差性能。但是Transformer编码器结构可能难以精准分离路径特征,在有限数据条件下易出现过拟合现象。文献[24]提出了一种基于信道状态信息网络(CSINet, channel state information-based network)的感知与恢复机制,实现对信

道状态信息的高效压缩和重建。然而,相比于无线信道,水声信道具有快速时变性、复杂多径效应、高多普勒扩展等特性,并且通常采用低采样率传输信号,导致现有的深度学习信道估计方法无法捕捉时延、多普勒等动态特征,缺乏复杂信道环境中的自适应能力,并且训练过程的稳定性较差。相比之下,生成式模型能够更好地建模信道先验分布,并在数据受限或信道复杂多变的情况下提供更稳健的信道估计。文献[25]提出了基于去噪扩散概率模型(DDPM, denoising diffusion probabilistic model)和去噪扩散隐式模型(DDIM, denoising diffusion implicit model)的信道估计方法,通过学习信道数据分布的得分函数,并结合信道观测信息对信道响应进行估计。文献[26]进一步提出了基于布朗桥(BB, Brownian bridge)优化的扩散信道去噪方法,通过构建最小二乘估计域和真实信道域之间的图像到图像的映射,提升去噪性能。但这2种基于扩散模型的方法依赖多步采样与优化,限制了其在水声信道中的应用。本文的主要贡献如下。

1) 提出了一种基于响应生成网络(RGNet, response generation network)的水声信道估计方法,在RGNet方法中提出了一种基于时滞补偿的信号局部化分析算法,通过重叠加窗技术,在时延-多普勒域内分析窗口内信号的多径时延效应和多普勒频移大小,并利用时间轴切片进行时间维度扩展,选择最大互相关的时滞参数对水声信号进行三维重建,强化信号的时延和多普勒特征,并将重建结果作为响应生成网络的输入。

2) 提出了一种信号自迭代更新网络,通过基于L1-正则化最小二乘法进行网络权重与偏置更新,并对生成网络的输入信号进行迭代更新和补充。在网络训练过程中,根据目标函数的反馈优化网络参数,提升系统在复杂信道环境中的自适应能力,有效减少模拟信道响应与真实信道响应之间的误差。

3) 提出了一种基于Bures-Wasserstein目标函数的分解优化算法,通过将目标函数的收敛过程分解为多个简化的子问题进行优化求解,从而通过更新Bures-Wasserstein距离模型的参数来加速整体收敛,有效减小了梯度消失和梯度爆炸等问题发生的概率,提高了训练过程的稳定性和效率。

1 系统模型

本文假设一个水下MIMO-OTFS通信系统,发射端配备了 q 个发射换能器,接收端配备了 p 个水听器,MIMO-OTFS通信模型如图1所示,其中各天线独立传输OTFS调制信号。

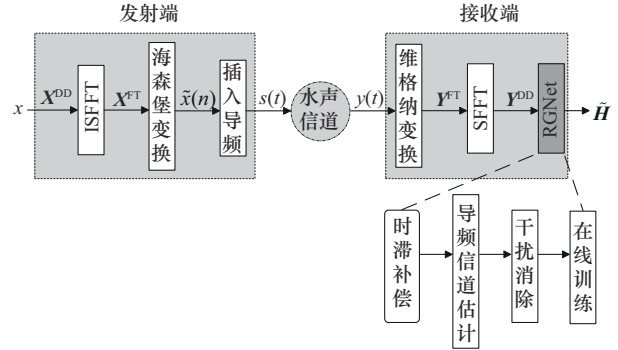


图1 MIMO-OTFS通信模型

首先在发射端,考虑长度为 $M \times N$ 的正交相移键控(QPSK, quadrature phase shift keying)信号集合 $\mathcal{A} = \{a_1, \dots, a_Q\}$ 的二维数据块 $\{x[m, n], m = 0, 1, \dots, M-1, n = 0, 1, \dots, N-1\}$ 。将OTFS调制信号 $x[m, n]$ 映射到时延-多普勒域矩阵 $\mathbf{X}^{\text{DD}} \in \mathbb{C}^{M \times N}$,其中 M 和 N 分别表示沿时延维度和多普勒维度的资源单元数。 \mathbf{X}^{DD} 经过离散辛傅里叶逆变换(ISFFT, inverse discrete symplectic Fourier transform)映射到频域域的二维块 $\mathbf{X}^{\text{FT}} \in \mathbb{C}^{M \times N}$ 。然后通过OFDM调制器,在二维块 \mathbf{X}^{FT} 的每一列上应用 M 点离散傅里叶逆变换(IDFT, inverse discrete Fourier transform)来获取二维发射信号 $\mathbf{S} \in \mathbb{C}^{M \times N}$,即

$$\mathbf{S} = \mathbf{F}_M^H \mathbf{X}^{\text{FT}} \quad (1)$$

其中, $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_N]$, \mathbf{S} 中每个列向量 $\mathbf{s}_i \in \mathbb{C}^{M \times 1}$ 看作一个OFDM符号, $\mathbf{F}_M \in \mathbb{C}^{M \times M}$ 为离散傅里叶变换(DFT, discrete Fourier transform)矩阵。若按列读取二维发射信号 $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_N]$,则一维发射信号 $\mathbf{s} \in \mathbb{C}^{(M+N_{\text{CP}}) \times N}$ 为

$$\mathbf{s} = \text{vec} \{ \mathbf{A}_{\text{CP}} \mathbf{F}_M^H \mathbf{X}^{\text{FT}} \} \quad (2)$$

其中, N_{CP} 表示循环前缀长度, $\mathbf{A}_{\text{CP}} \in \mathbb{C}^{(M+N_{\text{CP}}) \times M}$ 表示CP加法矩阵。在接收端,记 $h_{qp}(\tau, \nu)$ 为第 q 个发射换能器与第 p 个水听器之间信道的时延-多普勒响应矩阵的参数对。假设第 q 个发射换能器和第 p 个水听器对应的信道共有 P 个抽头,则信道响应 $h_{qp}(\tau, \nu)$ 为

$$h_{qp}(\tau, \nu) = \sum_{i=1}^P h_{qp_i} \delta(\tau - \tau_i) \delta(\nu - \nu_i) \quad (3)$$

其中, τ_i 、 ν_i 和 h_{qp_i} 分别表示第 i 条路径的时延、多普勒频移和信道增益, $\delta(\cdot)$ 表示狄拉克函数, $q = 1, 2, \dots, N_q$, $p = 1, 2, \dots, N_p$ 。将接收信号序列 $\mathbf{r} \in \mathbb{C}^{(M+N_{cp}) \times N}$ 的第 K 个元素表示为

$$\mathbf{r}_K = \sum_{i=1}^P h_{qp_i} s_{K-i} e^{j2\pi\nu_i(K-i)} + w_K \quad (4)$$

其中, w_K 表示接收端的加性白噪声, i 表示第 i 条传播路径, τ_i 、 ν_i 和 h_{qp_i} 分别表示第 i 条路径的时延、多普勒频移和信道增益。将解调得到的接收二维信号块 \mathbf{Y}^{FT} 在时延-多普勒域中转换成二维数据块 $\mathbf{Y}^{\text{DD}} \in \mathbb{C}^{M \times N}$ 。

设 OTFS 信号帧持续时间为 $T_o = NT$, 带宽为 $B = \frac{M}{2T_o}$ 。令 \mathbf{H}_{qp} 表示第 q 个发射天线和第 p 个接收天线对应的等效信道矩阵, 且第 i 条路径的时延抽头和多普勒抽头分别表示为

$$\tau_i = \frac{l_{\tau_i}}{M\Delta f}, \nu_i = \frac{k_{\nu_i}}{NT} \quad (5)$$

其中, l_{τ_i} 和 k_{ν_i} 分别为时延和多普勒的整数倍抽头, M 和 N 为二维符号索引, Δf 为频率采样间隔。将输出 $Y^{\text{DD}}[l, k]$ 与输入 $X^{\text{DD}}[l, k]$ 在时延-多普勒域的向量关系表示为

$$Y^{\text{DD}}[l, k] = \frac{1}{MN} \sum_{l'=0}^{M-1} \sum_{k'=-\frac{N}{2}}^{\frac{N}{2}-1} X^{\text{DD}}[l', k'] \sum_{i=1}^P H^{\text{DD}}[l+1+M(i-1), (l-l')_M] e^{-j2\pi(i-1)\frac{k-k'}{P}} + w^{\text{DD}}[l, k] \quad (6)$$

其中,

$$H^{\text{DD}}[l, k] = \iint h_{qp_i}(\tau, \nu) \mathbf{A}_{\text{grx, gtx}}((l-l')T - \tau, (k-k')\Delta f - \nu) e^{j2\pi(v+k'\Delta f)((l-l')T - \tau)} e^{j2\pi\nu l' T} d\tau d\nu \quad (7)$$

其中, $\mathbf{w}^{\text{DD}} = [w_1, w_2, \dots, w_N] \mathbf{F}_N$, \mathbf{F}_N 为 DFT 矩阵。在本文中, $Y^{\text{DD}}[l, k]$ 和 $X^{\text{DD}}[l, k]$ 分别表示 \mathbf{Y}^{DD} 和 \mathbf{X}^{DD} 中第 $(l+1, k+1 + \frac{N}{2})$ 个元素, 其中参数 l 和 k 满足 $l = 0, 1, \dots, M-1$ 且 $k = -\frac{N}{2}, \dots, 0, \dots, \frac{N}{2}-1$ 。将时延-多普勒信道冲激响应 $\mathbf{H}_{l,k}^{\text{DD}}$ 矩阵中的元素表示为

$$H^{\text{DD}}[l, k] \triangleq \sum_{i=1}^P h_{q_{(i-1)(M+N+1)P_i}}(\tau, \nu) e^{-j2\pi(i-1)\frac{k}{N}} \quad (8)$$

本文的目标是通过 $H^{\text{DD}}[l, k]$ 估计出时延-多普勒域的信道响应参数对 $h_{qp_i}(\tau, \nu)$ 。

2 算法设计

2.1 信道粗估计及干扰消除

在 OTFS 数据帧中插入复高斯序列为训练导频, 以第 $[l, k]$ 块二维时延多普勒数据块 $Y^{\text{DD}}[l, k]$ 为例, 将第 $[l, k]$ 块对应的接收信号记为 $y_{l,k}$, 其对应的原二维数据块为 $x_{l,k}$, 对应的导频符号块为 $\zeta_{l,k}$, 因此接收信号的一个元素可以表示为

$$y_{l,k} = h(\tau, \nu) * s[l, k] + w[l, k] = \sum_{n=1}^N \sum_{i=1}^P \zeta_{n+1-i, l} e^{j2\pi\nu_i \frac{f_{n+1-i, l}}{N(n+1-i+N_{cp})}} * (\zeta_{n+1-i, l} + x_{n+1-i, l}) + w_{n+1-i, l} \quad (9)$$

其中, $*$ 表示卷积运算, w_n 表示均值为 0 的加性白高斯噪声, $e^{j2\pi\nu_i \frac{f_{n+1-i, l}}{N(n+1-i+N_{cp})}}$ 表示第 $n+1-i$ 个接收信号块相应的多普勒频移补偿, $f_{i, l}$ 表示第 l 个信道响应冲激响应的第 i 个频率分量, $\zeta_{n+1-i, l}$ 对应 $e^{j2\pi\nu_i \frac{f_{n+1-i, l}}{N(n+1-i+N_{cp})}}$ 的非零系数, $\zeta_{i, l}$ 表示第 $[i, l]$ 段二维导频块, x_{n+1-i} 表示第 $[i, l]$ 段二维数据块。假设原始符号序列的均值 $\mu_{l,k} = 0$, 且 $T \geq N$ 可得

$$E(y_{l,k}) = \sum_{n=1}^N \sum_{i=1}^P \zeta_{(n+1-i)} e^{j2\pi\nu_i \frac{f_{n+1-i, l}}{N(n+1-i+N_{cp})}} h_{qp_i}(\tau, \nu) \quad (10)$$

根据预设导频周期 T 将 $E(y_{l,k})$ 分成 $n \times 1$ 的向量段 $\mathbf{E}(y_{l,k})$, 可得

$$\mathbf{E}(y_{l,k}) = \mathbf{E} \begin{Bmatrix} y_{1T} \\ y_{2T} \\ \vdots \\ y_{qT} \end{Bmatrix} \quad (11)$$

$$\mathbf{E}[y_{iT}] = \frac{1}{\sqrt{1+n^2}} \begin{pmatrix} \zeta_{iT+1} & \zeta_{iT} & \cdots & \zeta_{iT-N+2} \\ \zeta_{iT+2} & \zeta_{iT+1} & \cdots & \zeta_{iT-N+3} \\ \vdots & \vdots & & \vdots \\ \zeta_{iT+T} & \zeta_{iT+1+T} & \cdots & \zeta_{iT-N+T+1} \end{pmatrix} \times$$

$$\begin{pmatrix} e^{j2\pi v_i \frac{f_{1+1-iT,l}}{N(1+1-iT+N_{CP})}} \\ e^{j2\pi v_i \frac{f_{2+1-iT,l}}{N(2+1-iT+N_{CP})}} \\ \vdots \\ e^{j2\pi v_i \frac{f_{n+1-i,l}}{N(n+1-i+N_{CP})}} \end{pmatrix}^T \begin{pmatrix} h_{qp_1}(\tau, v) \\ h_{qp_2}(\tau, v) \\ \vdots \\ h_{qp_N}(\tau, v) \end{pmatrix} \quad (12)$$

其中, $i = 1, 2, \dots, N$, NT 表示导频符号块长度, $\mathbf{E}(y_{l,k})$ 表示接收信号序列的均值, $\mathbf{E}[y_{iT}]$ 表示第 i 或第 iT 个周期导频块对应的接收信号块均值, 所以可得到上述维度为 $(N+1) \times T$ 的托普利茨矩阵 \mathbf{A} 为

$$\mathbf{A} = \frac{1}{\sqrt{1+n^2}} \begin{pmatrix} \zeta_{iT+1} & \zeta_{iT} & \cdots & \zeta_{iT-N+2} \\ \zeta_{iT+2} & \zeta_{iT+1} & \cdots & \zeta_{iT-N+3} \\ \vdots & \vdots & \ddots & \vdots \\ \zeta_{iT+T} & \zeta_{iT+1+T} & \cdots & \zeta_{iT-N+T+1} \end{pmatrix} \times \begin{pmatrix} e^{j2\pi v_i \frac{f_{1+1-iT,l}}{N(1+1-iT+N_{CP})}} \\ e^{j2\pi v_i \frac{f_{2+1-iT,l}}{N(2+1-iT+N_{CP})}} \\ \vdots \\ e^{j2\pi v_i \frac{f_{n+1-i,l}}{N(n+1-i+N_{CP})}} \end{pmatrix}^T \quad (13)$$

分别对均值 $\mathbf{E}[y_{iT}]$ 进行累加和计算可得到

$$\frac{1}{N} \sum_{i=1}^N \mathbf{E}[y_{iT}] = \frac{1}{N} \sum_{i=1}^N [y_{iT,IT}] \triangleq \mathbf{A} \mathbf{h}_{N \times 1} \quad (14)$$

根据最小二乘信道估计算法, 可得训练导频对应的信道响应参数矩阵为

$$\mathbf{H}_{l,k}^{DD} = \left[(\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \left(\frac{1}{N} \sum_{i=1}^N y_{iT,l} \right) \right]_{N \times 1} \quad (15)$$

其中, \mathbf{A}^H 表示 \mathbf{A} 的共轭矩阵, N 表示训练导频的周期数, 同时对上述信道响应参数矩阵进行补0, 以实现将离散信道响应值拓展至连续域, 其中长度拓展到 \mathbf{S}_n , 即 $\mathbf{H}_n = [\mathbf{H}_n, \mathbf{0}]_{M \times N}$, 其中 $M \times N$ 表示信息数据符号长度。将该表达式对应的 \mathbf{H}_n 矩阵作为信道响应判别网络的输入之一。

2.2 基于响应生成网络的水声信道估计方法

本文提出的基于RGNet的信道估计方法由3个部分组成: 基于时滞补偿的局部化分析和信号三维重建算法; 用于生成模拟信道响应的生成网络; 对输入的信道响应样本进行鉴别的判别网络, 如图2所示。

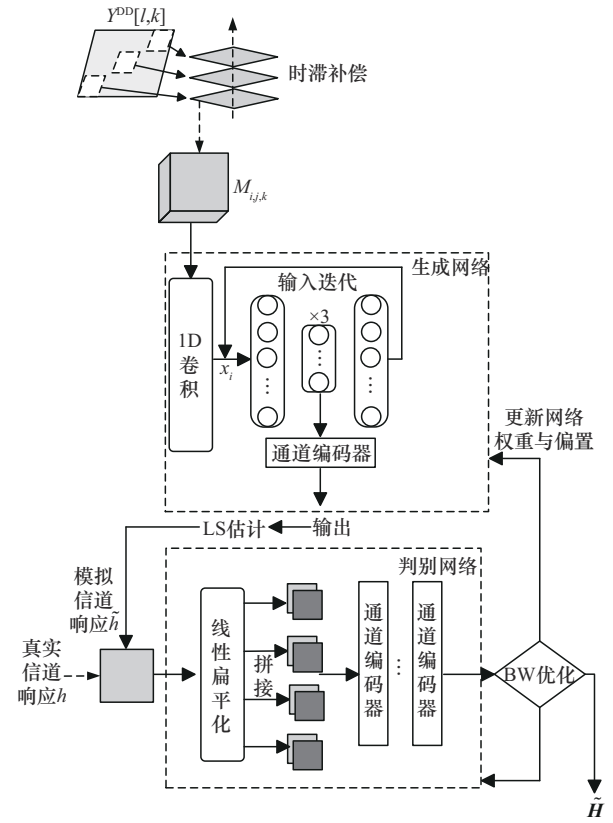


图2 RGNet信道估计方法

2.2.1 时滞补偿

在水声通信环境中, 信道可能会在短时间内剧烈波动, 多普勒和时延效应会导致信号失真和误码率 (BER, bit error rate) 增加, 进行基于时滞补偿的三维重建, 可以有效改善信号的抗干扰能力和质量, 从而提高信道估计精度。

记参数 Δt 、 $\Delta \tau$ 和 Δv 分别为观测时间、时延和多普勒频移的采样间隔。离散化的观测时间表示为 $t_n = n\Delta t, n = 1, 2, \dots, N$, 离散化的时延表示为 $\tau_m = \tau_0 + (m-1)\Delta t, m = 1, 2, \dots, M$, 其中, τ_0 为参考时延, M 为最大的时延采样维度, 即水声信道路径阶数。将时域接收信号 $y(t)$ 表示为

$$y(t) = \int_{-\infty}^{+\infty} \int_0^{+\infty} h_{qp}(\tau, v) S(t-\tau) e^{j2\pi v(t-\tau)} d\tau dv + w(t) \quad (16)$$

根据式(16), 定义二维互相关函数 $R_{ys}(\tau, v)$ 为

$$R_{ys}(\tau, v) = \int_{-\infty}^{+\infty} y(t) S(t-\tau_m) e^{-j2\pi vt} dt \quad (17)$$

其中, τ_m 为时滞延迟, 取值为 $\tau_m = m\Delta t$, m 为整数, 将该函数峰值位置对应的时延大小和多普勒频

移大小分别定义为时滞参数，如式(18)和式(19)所示。

$$d_\tau = \arg \max_\tau (\max_\nu |R_{ys}(\tau, \nu)|) \quad (18)$$

$$d_\nu = \arg \max_\nu (\max_\tau |R_{ys}(\tau, \nu)|) \quad (19)$$

将时延的时滞范围定义为 $[\tau_{\min}, \tau_{\max}] = [\tau_m - d_\tau, \tau_m + d_\tau]$ ，同时将多普勒频移的时滞范围定义为 $[\nu_{\min}, \nu_{\max}] = [\nu_m - d_\nu, \nu_m + d_\nu]$ 。对接收信号 $y(t)$ 在时延-多普勒域上进行布莱克曼加窗，本文中选定窗函数的系数为 0.42、0.5 和 0.08 来平衡主瓣宽度和进行旁瓣抑制，构建接收信号时间轴切片，表示为

$$y(t)|_{t_{n-1} \leq t \leq t_n} = [s(t - \tau_m)e^{-j2\pi ft}] \times \left[0.42 - 0.5\cos\left(\frac{2\pi t}{N-1}\right) + 0.08\left(\frac{4\pi t}{N-1}\right) \right] dt \quad (20)$$

其中， N 表示窗函数的总宽度，根据时滞参数 d_τ 和 d_ν 的变化，动态调整平滑窗口的大小，并通过将时间窗口重叠叠加进行维度扩展，如图 3 所示。




图 3 时滞补偿过程

构建三维离散网格，每个网格点 (i, j, k) 对应一个三维坐标为 $(d_{i,j,k}, \nu_{i,j,k}, \tau_{i,j,k})$ 。定义三维网格的大小为 $N_x \times N_y \times N_z$ ，其中 N_x 、 N_y 和 N_z 分别为网格在 x -、 y - 和 z - 方向的分辨率。构建一个三维矩阵 M 来表示该三维离散网格，即

$$M[i][j][k] = (\tau[i][j][k], \nu[i][j][k], d[i][j][k]) \quad (21)$$

其中， $\tau[i][j][k] = \frac{\alpha_{i,j,k}}{c}$ 表示每个网格点的时延值， $\alpha_{i,j,k}$ 表示从发射信号源点到接收网格点 (i, j, k) 之间的距离， c 表示水下声音的传播速度， $\nu[i][j][k] = f_0 \left(\frac{v_{qp}}{c} \right)$ 表示每个网格点的频移值，其中 f_0 为初始信号频率， v_{qp} 为发射换能器和水听

器之间的相对速度， $d[i][j][k]$ 表示每个网格点的时滞值， $d = \frac{1}{2} \left(d_\tau \frac{\tau_{\max}}{\tau_{\min}} + d_\nu \frac{\nu_{\max}}{\nu_{\min}} \right) \psi_N^*(\alpha)$ ， $\psi_N^*(\alpha)$

$$\text{定义为 } \psi_N^*(\alpha) \triangleq \sum_{i=1}^N e^{j2\pi \frac{\alpha}{N} (i-1)}.$$

2.2.2 基于信号自迭代更新的生成网络

在生成网络中，定义变量 w_{ij}^c 为信号自迭代更新网络的权重，变量 $b_n^m(k)$ 为偏置，其中， i 表示连接该权重的上层网络的第 i 个元素， j 表示连接该权重的下层网络中的第 j 个元素， $c = 1$ 是从输入层到隐藏层的权重， $c = 2$ 是从隐藏层到输出层的权重。变量 b_n^m 为偏置，其中 $m = 1$ 是隐藏层的偏置， $m = 2$ 是输出层的偏置， n 表示该偏置是该层第 n 个元素的偏置，从而 w_{ij}^1 表示输入层第 i 个元素连接隐藏层第 j 个元素的权重， w_{ij}^2 表示隐藏层第 i 个元素连接输出层第 j 个元素的权重， b_1^1 表示隐藏层第 1 个元素的偏置， b_2^2 表示输出层第 2 个元素的偏置， z_n^1 表示隐藏层第 n 个元素的输出， \hat{x}_N 表示输出层第 N 个输出元素。当生成网络前向传播时，表达式为

$$z_n = \sigma \left(w_{1n}^1 x_1 + \dots + w_{Nn}^1 x_N + b_n^1 + \frac{1}{2N} \sum_{i=1}^N (x_i - y_i) \right) \quad (22)$$

$$\hat{x}_N = \sigma \left(w_{1N}^2 z_1 + \dots + w_{nN}^2 z_n + b_N^2 + \frac{1}{2n} \sum_{i=1}^n (x_i - y_i) \right) \quad (23)$$

其中， $\sigma(\cdot)$ 表示激活函数 Sigmoid， $z_n = \sigma(\cdot)$ 表示输入层到隐藏层的过程， $\hat{x}_N = \sigma(\cdot)$ 表示隐藏层到输出层的过程。为控制网络复杂度，构建正则化最小二乘目标函数为 $L = \frac{1}{2N} \sum_{i=1}^N \|x_i - \hat{x}_i\|_2^2 + \lambda \sum_{ij} |w_{ij}|$ ，根据式(24)和式(25)更新网络权重和偏置。

$$w_{ij}^c \leftarrow w_{ij}^c - \eta \left(\frac{\partial L_{\text{mse}}}{\partial w_{ij}^c} + \frac{\partial L_{\text{reg}}}{\partial w_{ij}^c} \right) \quad (24)$$

$$b_i^m \leftarrow b_i^m - \eta \frac{\partial L_{\text{mse}}}{\partial b_i^m} \quad (25)$$

其中， $L_{\text{mse}} = \frac{1}{2N} \sum_{i=1}^N \|x_i - \hat{x}_i\|_2^2$ ， $L_{\text{reg}} = \lambda \sum_{ij} |w_{ij}|$ ， η 为学习率， λ 为正则化参数。

将信号自迭代更新网络隐藏层输出 z_n 传入 M

层通道编码器块中,利用通道注意力机制进行特征权重计算和信道特征提取,并经过批归一化层和激活函数层处理后得到信号输出,最终通过最小二乘法得到模拟信道响应矩阵 \hat{H}_n 。

2.2.3 基于层级通道编码器的判别网络

在判别网络中,采用层级通道编码器的方式进行多尺度判别,将信道响应矩阵 \hat{H}_n 等效为信道响应特征图 H_n^y ,并对其进行线性扁平化处理。该网络通过选择不同尺度的特征图 H_n^y 进行拼接和线性加权,将其作为各层级通道编码器的输入,从而实现多尺度的特征提取与真假判别。

在通道编码器中,首先将输入的特征图 $DE \times DL \times T \times CE$ 分别采用基于 T 和 CE 的全局最大池化(MaxPool, max pooling)和全局平均池化(AvgPool, average pooling),也就是基于通道维度和时间维度进行池化,提取得到2组尺寸为 $1 \times 1 \times DE \times DL$ 的信道特征图。然后,将这2组信道特征图输入一个共享权值的多层感知机(MLP, multi-layer perceptron)中进行通道间依赖关系学习,并通过压缩比 r 实现降维。最后,MLP的输出特征经逐元素加和,并通过Sigmoid激活函数归一化,得到最终的通道加权矩阵。

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c) + W_1(W_0(F_{\text{max}}^c)))) \quad (26)$$

不同层级的通道编码器生成具有不同维度的信道响应特征图,用以对输入的信道响应矩阵进行多尺度特征提取和融合。同时,通过平均池化层对每一层通道编码器的输出进行重塑和拼接,整合不同尺度的信息。最终,经过全连接层处理后,层级通道编码器的输出用于更新和优化损失函数。通过Sigmoid激活函数,输出结果的范围能够得到限制,并用于度量真实信道响应分布与模拟信道响应分布之间的Bures-Wasserstein误差。

2.2.4 网络训练

在RGNet训练过程中,判别网络在迭代过程中调用算法1更新生成网络的权重和偏置,对生成网络的输入信号进行迭代更新和补充,并随着迭代次数的增加,逐步减小学习率。

算法1 基于L1-正则化最小二乘法的权重与偏置迭代更新

定义输入层 N 个元素,隐藏层 n 个元素,输出

层 N 个元素;给定权重参数 $w_{ij}^c(k)$ 和偏置参数 $b_n^m(k)$;初始化 $w_{ij}^1(0)$ 、 $w_{ij}^2(0)$ 、 $b_n^1(0)$ 、 $b_n^2(0)$ 和 $z_m^1(0)$;初始化迭代次数为 k ,迭代精度为 π_1 ,特征基为 A

- 1) 循环
- 2) 定义 $k = 0$,初始化输入 x_N
- 3) 循环
- 4) for $k=1:1:K$
- 5) 根据式(24)和式(25)更新权重参数 $w_{ij}^c(k)$ 和偏置参数 $b_n^m(k)$
- 6) end for
- 7) $i=i+1; j=j+1; m=m+1$
- 8) until $J_k(w,b) = \frac{1}{N^2} \sum_{j=1}^N \sum_{i=1}^N \left\| A w_{ij}^c + b_i^m - x_i^k \right\|_2^2 + \lambda \sum_{ij} \left\| w_{ij}^c \right\|_1$ 收敛
- 9) $k=k+1$

在RGNet训练过程中,根据反馈信息优化网络参数,可以提升系统在复杂信道环境中的自适应能力,有效减少模拟信道响应与真实信道响应之间的误差。

2.3 基于Bures-Wasserstein目标函数的分解优化算法

将上述响应生成网络的目标函数表示为

$$\min_{G,D} L(G,D) = \min \mathcal{B}^2(p_h, p_{\tilde{h}}) = \min_{E_{(x,y)} \sim \pi} \inf_{\pi} \left\{ \int \int \|x - y\|^2 d\pi_{N \times N}(x,y) + \int \|y\|^2 dp_{\tilde{h}_{N \times N}}(y) \right\} \quad (27)$$

其中, $\mathcal{B}^2(p_h, p_{\tilde{h}})$ 为真实信道响应分布和模拟信道响应分布之间的距离,即真实信道响应分布和模拟信道响应分布之间的误差。 $\mathcal{B}^2(p_h, p_{\tilde{h}})$ 的误差最小值证明见附录1。 $E_{(x,y)} \sim \pi$ 为目标函数中进行最小化的 X 和 Y 之间距离的期望值,且保证在训练过程中 $(x,y) \sim \pi$ 取值服从 π 的联合分布,其中联合分布 π 满足式(28)所示约束条件。

$$E_{(x,y)} \sim \pi \text{ s.t. } \begin{cases} x \sim N(0, \Sigma_{p_{h_{l,k}}}^T \Sigma_{p_{\tilde{h}_{l,k}}}) \\ y \sim N(0, \Sigma_{p_{h_{l,k}}}^T \Sigma_{p_{\tilde{h}_{l,k}}}) \end{cases} \quad (28)$$

其中, $\Sigma_{p_{h_{l,k}}}$ 和 $\Sigma_{p_{\tilde{h}_{l,k}}}$ 分别代表 $h_{l,k}$ 和 $\tilde{h}_{l,k}$ 在各自概率分布下计算得到的协方差矩阵。根据在线交替方向乘

子法 (ADMM, alternating direction method of multiplier) 设置, 对 t 时刻信道估计任务的目标优化进行改写。

1) 对信道响应矩阵 \mathbf{H} 和 $\tilde{\mathbf{H}}$ 的每个元素 $h_{l,k}$ 和 $\tilde{h}_{l,k}$ 进行标准化, 每个元素都是独立的高斯随机变量。计算其均值 $\mu_{l,k} = \frac{1}{N} \sum_{k=1}^N h_{l,k}^{(k)}$ 和标准差 $\sigma_{l,k}^2 = \frac{1}{N-1} \cdot \sum_{k=1}^N (h_{l,k}^{(k)} - \mu_{l,k})^2$, 再对每个元素 $h_{l,k}$ 和 $\tilde{h}_{l,k}$ 执行标准化得到 $h'_{l,k} = \frac{h_{l,k} - \mu_{l,k}}{\sigma_{l,k}} \left(\tilde{h}'_{l,k} = \frac{\tilde{h}_{l,k} - \tilde{\mu}_{l,k}}{\tilde{\sigma}_{l,k}} \right)$ 。假设信道响应参数是一个独立的复高斯随机变量, 每个信道元素 $h_{l,k}$ 都服从复高斯分布, 即 $h_{l,k} \sim \text{CN}(0, \sigma_{l,k}^2)$, 则根据上述参数构建 $h_{l,k}$ 概率密度函数表达式为

$$p(h_{l,k}) = \frac{1}{\pi \sigma_{l,k}^2} \exp\left(-\frac{|h_{l,k}|^2}{\sigma_{l,k}^2}\right) \quad (29)$$

2) 对响应生成网络的目标函数进行改写, 如式(30)所示。

$$\begin{aligned} L(G, D) = \min L(\Sigma_{\mathbf{H}}^{p_h}, \Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}, Z_{l,k}^{(k)}, u_{l,k}^{(k)}) = \\ \min \mathcal{B}^2(\Sigma_{\mathbf{H}}^{p_h}, \Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}) = \\ \min_{h, \tilde{h}, p_h, p_{\tilde{h}}, \Sigma} \sum_{i=1}^M \sum_{j=1}^N \left\{ \frac{\lambda_1}{2} \left\{ \int \|h_{l,k} - \tilde{h}_{l,k}\|_2^2 d\pi_{N \times N}(p_h, p_{\tilde{h}}) \right\} + \right. \\ \left. \frac{\lambda_2}{2} \left\{ \int \|p_h - p_{\tilde{h}}\|_2^2 dN_{\perp}(p_{\tilde{h}}) \right\} + \frac{\lambda_3}{2} \text{tr}(\Sigma_{\mathbf{H}}^{p_h}, \Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}) + \right. \\ \left. \frac{\rho}{2} \sum_{k=1}^K \left\| \Sigma_{\mathbf{H}}^{(k)} - Z_{l,k}^{(k)} + u_{l,k}^{(k)} \right\|_F^2 \right\} \quad (30) \end{aligned}$$

其中, $\Sigma_{\mathbf{H}}^{p_h}$ 和 $\Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}$ 分别为真实信道响应分布和模拟信道响应分布的协方差矩阵, $Z_{l,k}^{(k)}$ 为当前迭代训练的辅助变量, $Z_{l,k}^{(k)} \in \mathbb{R}^d$, $u_{l,k}^{(k)}$ 为拉格朗日乘子, 上标 k 为多普勒维度的抽头因子, ρ 为 ADMM 的步长参数。

3) 在每次训练迭代过程中, 分别对 $\Sigma_{\mathbf{H}}^{p_h}, \Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}, Z_{l,k}^{(k)}, u_{l,k}^{(k)}$ 进行更新, 并在更新过程中最小化 $\|h_{l,k} - \tilde{h}_{l,k}\|_2^2$ 和 $\|p_h - p_{\tilde{h}}\|_2^2$ 的值。为了简化表示, 将 $\Sigma_{\mathbf{H}}^{p_h}$ 表示为 Σ_1 , $\Sigma_{\tilde{\mathbf{H}}}^{p_{\tilde{h}}}$ 表示为 Σ_2 。

首先更新 Σ_1 , 表示为

$$\begin{aligned} \Sigma_1^{(k+1)} = \arg \min_{\Sigma_1} L(\Sigma_2^{(k)}, Z^{(k)}, u_1^{(k)}) = \\ \arg \min_{\Sigma_1} \left[d_{\mathcal{B}^2}(\Sigma_1, \Sigma_2^{(k)}) + \frac{\rho}{2} \left\| \Sigma_1^{(k)} - Z^{(k)} + u_1^{(k)} \right\|_F^2 \right] \quad (31) \end{aligned}$$

其中, $d_{\mathcal{B}^2}(\Sigma_1, \Sigma_2^{(k)})$ 为 Σ_1 与 $\Sigma_2^{(k)}$ 之间的 Bures-Wasserstein 距离。然后对 Σ_2 进行更新, 表示为

$$\begin{aligned} \Sigma_2^{(k+1)} = \arg \min_{\Sigma_2} L(\Sigma_1^{(k)}, Z^{(k)}, u_2^{(k)}) = \\ \arg \min_{\Sigma_2} \left[d_{\mathcal{B}^2}(\Sigma_1^{(k+1)}, \Sigma_2) + \frac{\rho}{2} \left\| \Sigma_2 - Z^{(k)} + u_2^{(k)} \right\|_F^2 \right] \quad (32) \end{aligned}$$

再对辅助变量 $Z^{(k)}$ 进行更新, 约束形式为

$$Z^{(k+1)} = \frac{1}{2} (\Sigma_1^{(k+1)} + \Sigma_2^{(k+1)}) \quad (33)$$

最后更新拉格朗日乘子, 表示为

$$\begin{aligned} u_1^{(k+1)} = \arg \min_{u_1^{(k)}} L(\Sigma_1^{(k)}, \Sigma_2^{(k)}, Z^{(k)}, u_1^{(k)}) = \\ \arg \min_{u_1^{(k)}} \left(Z^{(k)} (\Sigma_1^{(k+1)} - u_1^{(k)} - \Sigma_2^{(k+1)}) + \right. \\ \left. \frac{\rho}{2} \left\| \Sigma_1^{(k)} - u_1^{(k)} - \Sigma_2^{(k+1)} \right\|_2^2 \right) \quad (34) \end{aligned}$$

$$\begin{aligned} u_2^{(k+1)} = \arg \min_{u_2^{(k)}} L(\Sigma_1^{(k)}, \Sigma_2^{(k)}, Z^{(k)}, u_2^{(k)}) = \\ \arg \min_{u_2^{(k)}} \left(Z^{(k)} (\Sigma_1^{(k+1)} - u_2^{(k)} - \Sigma_2^{(k+1)}) + \right. \\ \left. \frac{\rho}{2} \left\| \Sigma_1^{(k)} - u_2^{(k)} - \Sigma_2^{(k+1)} \right\|_2^2 \right) \quad (35) \end{aligned}$$

4) 每次迭代更新结束时, 检查目标函数是否小于预设阈值 $\varepsilon = 10^{-3}$ 。

RGNet 方法首先通过基于时滞补偿的局部分析算法, 结合重叠加窗技术进行时间维度扩展, 在时延-多普勒域中实现了多径时延与多普勒频移特征的高精度提取。随后, 构建信号自适应更新网络以增强信号输入, 并基于 L1-正则化最小二乘法实现对网络参数的自适应动态调整, 有效降低了信道响应估计误差。最后, 构建 Bures-Wasserstein 分解优化算法, 提升了收敛效率并确保训练稳定性。得益于上述设计, RGNet 方法能够有效适应复杂多径传播与强噪声干扰并存的水下移动通信环境, 兼顾了估计精度、计算效率与系统鲁棒性, 为动态时变水声通信环境提供了有效解决方案。

3 性能分析

本节将对 RGNet 方法、HA02^[23]方法和 OMP-MAP 方法^[8]的计算复杂度进行比较与分析。

RGNet 方法的计算复杂度由时滞补偿 $O(N_d N_w)$ 、

导频信道估计 $O(N_t^3)$ 和 RGNNet 神经网络训练 $O\left(\sum_{l=1}^L \frac{1}{N^2} (N_\omega N_b k_l^2 + N_w)\right)$ 构成, 其中 N_d 和 N_w 分别为时滞参数数量和每个时滞值下的窗口大小, N_t 为 MIMO 阵元数量, N 为输入块大小, L 为层数, k_l 为第 l 层的核大小, N_ω 和 N_b 分别表示 $\sigma(N_\omega, N_b)$ 迭代网络中权重和偏置的迭代次数, 因此总的计算复杂度为 $O\left(N_d N_w + N_t^3 + \sum_{l=1}^L \frac{1}{N^2} (N_\omega N_b k_l^2 + N_w)\right)$ 。

HA02 方法的计算复杂度为 $O(N_p N_f N_s)$, 其中 N_p 为导频符号数量, N_f 为多普勒频移, N_s 为时间单元数量。由于 $K \gg L$, OMP-MAP 方法的计算复杂度为 $O\left(K + P \frac{N_\tau N_b}{K}\right)$, 其中 P 为子载波数量, K 为信道延迟扩展, N_τ 为符号时间序列长度, N_b 为传输比特数。

4 仿真分析

本节通过对仿真结果的分析来验证本文所提基于 RGNNet 的水声信道估计方法对 MIMO-OTFS 系统信道估计的有效性。本文对归一化均方误差 (NMSE, normalized mean square error) 和 SNR 的定义分别为

$$\text{NMSE} = E \left(\frac{\|\tilde{\mathbf{H}} - \mathbf{H}\|_{\text{F}}^2}{\|\mathbf{H}\|_{\text{F}}^2} \right) \quad (36)$$

$$\text{SNR} = 10 \lg \left(\frac{\sigma_s^2}{\sigma_v^2} \right) \quad (37)$$

其中, σ_s^2 为发射功率, σ_v^2 为噪声功率。

本文利用 Bellhop 平台对 MIMO-OTFS 水声信道进行建模, 环境数据采用了 2016 年 8 月 22 日下午 1 点在墨西哥湾北部地区^[27]的海试数据。其中, 风向从东南方向吹来, 风速约为 8.3 m/s, 阵风达 10.6 m/s, 风力较稳定, 水体温度约为 30.1°C, 水体盐度约为 35 ppt, 海浪平均波高 1.5 m, 海面较平静, 波浪方向从东向北传播, 气压约为 1 012.2 hPa。自主式水下机器人 (AUV, autonomous underwater vehicle) 部署在现场水深 20 m 处, 发送深度为 19.5 m。接收方配备了一个由 16 个阵元组成的 MIMO 水听器阵列, 阵列深度位于 17.2~19.2 m, 阵元间距为 1.75 m。发送方和接收方位于相同的深度范围内, 通信双方水平距离为 20 m, 通过缩短水平通信距离, 能够增强多径效应的表现, 使不同路径信号的

干扰更加显著, 从而为多径传播特性的研究提供更清晰的展示。环境噪声功率为 -20 dB, 吸收损耗参数为 4, 传播损耗参数为 10。OTFS 帧参数设置为 $(M, N) = (128, 32)$ 。在发射信号前对初始数据流进行 QPSK 调制, 经过水声信道传输后将信号通过 ISFFT 映射到 DD 域作为 RGNNet 方法的输入。其他仿真参数如表 1 所示。

参数	数值
中心频率 f_c /kHz	12
带宽 B /kHz	5.812
数据块长度 N /个	256
导频数 m /个	256
循环前缀 CP/个采样点	16
数据块时长 T /ms	104.86
采样频率/kHz	96
发射阵元数 q /个	16
最大移动速度 v_m /(m·s ⁻¹)	2
最大时延扩展 τ_m /ms	5
衰落径数 P /条	8


表 2 给出了不同信道估计方法的运行时间, HA02 方法的 N_p 为 100, N_f 为 194 Hz, N_s 为 5 000, 故 HA02 方法的运行时间为 13.241 s。OMP-MAP 方法的 P 为 64, K 为 512, N_τ 、 N_b 最大为 40, 故 OMP-MAP 方法的运行时间为 12.070 s。MMSE 方法的运行时间为 17.059 s, 而 RGNNet 方法的运行时间为 7.582 s, 远低于 HA02、OMP-MAP 和 MMSE 方法。

方法	运行时间/s
RGNNet	7.582
HA02	13.241
OMP-MAP	12.070
MMSE	17.059


图 4 给出了克拉美-罗下界 (CRLB, Cramer-Rao lower bound) 及不同信道估计方法的 NMSE 与 BER 性能比较。由于水下噪声较大, 本文实验中 SNR 范围设定为 [-5, 20] dB。如图 4(a) 所示, MMSE 方法的估计性能最差, 这是因为水下噪声环境的不

理想性影响了噪声协方差矩阵的估计,进而导致信道估计出现较大的偏差。OMP-MAP方法依赖于信道特性(如时延和多普勒频移)的稀疏假设进行信道估计,但水下环境中的多普勒效应呈现非线性变化导致估计误差的积累。ASOMP-SR方法通过引入路径不变时间,并假设在该时间段内路径状态信息近似稳定,从而能够更准确地估计信道特性,减少由动态环境变化引起的误差,但是水声信道的快速时变特性可能导致路径不变时间较短,从而影响信道估计性能。RGNet方法在SNR=20 dB时,NMSE为0.003 4左右,较OMP-MAP方法提升49.9%,较ASOMP-SR方法也提升了约24.1%,表明了RGNet方法的有效性。RGNet方法性能提升的本质原因在于:1)通过时滞补偿有效捕捉和强化了信号的时延与多普勒特性,增强了模型在复杂动态水声环境下的鲁棒性;2)响应生成网络与响应判别网络通过对抗训练生成高逼真度的模拟信道响应,弥补了传统信道估计方法在复杂信道环境中的局限性;3)基于Bures-Wasserstein的分解优化算法通过将训练目标分解为多个子问题进行优化求解,加速模型收敛并提高模型稳定性。如图4(b)所示,与MMSE、OMP-MAP和ASOMP-SR方法相比,基于RGNet的水声信道估计方法的BER在SNR=5 dB的情况下,分别下降了90.3%、67.8%和33.8%;当处于较高SNR条件下时,RGNet方法性能优势没有那么明显,与ASOMP-SR方法的BER相近。

在基于深度学习的信道估计方法中,将本文提出的RGNet方法与基于Transformer和残差神经网络(称为HA02)、CGAN^[28]、CSINet^[24]以及WGAN^[29]信道估计方法的NMSE性能进行对比,结果如图5所示。CGAN依赖于条件输入生成目标信号,但水声信道中存在大量未被充分利用的条件信息,其性能表现较差。HA02中的Transformer在建模长距离依赖关系方面具有优势,但无法有效捕捉水声信道中的局部依赖,且需要大量标注数据进行训练,在处理有限的水声信号时表现受限。WGAN和CSINet方法性能接近,但均弱于RGNet。WGAN采用Wasserstein距离作为生成器和判别器之间的损失函数,训练过程相对稳定,但依赖于梯度惩罚来保持网络稳定性。CSINet在重建信道矩阵时,水声信道的快速时变特性和多径效应会使信道矩阵中的稀疏结构更加不稳定,降低其重建质量。



(a) NMSE与SNR之间的关系



(b) BER与SNR之间的关系

图4 RGNet信道估计方法与其他信道估计方法性能对比




图5 基于深度学习的信道估计方法性能对比

图6展示了在网络迭代过程中,选择不同损失函数进行训练的过程中NMSE的变化趋势。RGNet方法中ADMM优化器设置 $\lambda_1 = 0.5$ 、 $\lambda_2 = 0.9$ 和 $\lambda_3 = 0.3$ 。随机梯度下降优化器中动量设为0.9,学习率衰减设为0.001,权重衰减为0.000 1。采用统一的初始学习率 $\alpha = 0.000 5$ 进行训练,并且利用学习率预热技术将学习率由一个极小的初始值慢慢加到初始学习率,最小学习率设置为0.000 001,批量大

小设置为256。由图6可知,当采用 Wasserstein 距离作为RGNet方法的目标函数时, NMSE 变化剧烈, 导致训练不稳定, 甚至出现明显的突变现象。这种不稳定会影响模型的收敛性能并增加训练失败的风险; 采用 Bures-Wasserstein 距离作为目标函数能够明显提高训练稳定性, NMSE 变化曲线更加平滑, 波动较小。因此 Bures-Wasserstein 距离作为目标函数, 相比传统的 Wasserstein 距离, 具有更优越的收敛特性和更平稳的优化动态。

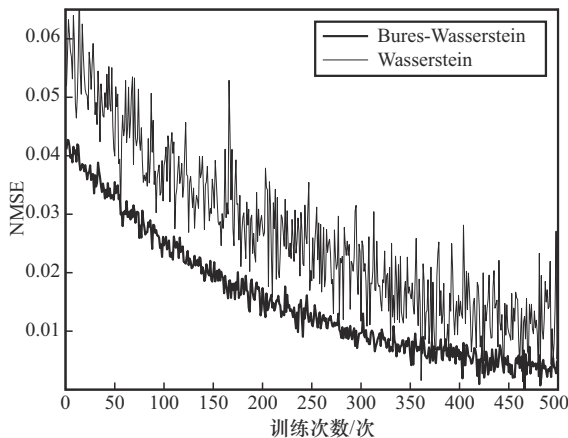


图6 不同损失函数训练结果对比

水声信号在传播过程中会穿越海面及水体中的不同层次, 导致不同路径的传播距离和速度各异, 从而产生多径信号的时延差异。为了验证不同信道估计方法在不同最大时延扩展下的性能和鲁棒性, 实验仿真设置在 SNR=5 dB 的低信噪比条件下, 最大时延扩展范围为 $\tau_m = [5, 25]$ ms, 不同方法在不同最大时延扩展下的 NMSE 性能对比如图7所示。结果表明, RGNet 方法在不同最大时延扩展下有较好的效果, 尤其是当 $\tau_m = 25$ ms 时, RGNet 方法性能效果依然高于 HA02 方法 63.8%, 高于 ASOMP-SR 方法 57.8%, 这是因为 RGNet 方法能利用时滞补偿来捕捉时延特征的动态变化, 增强模型对于信号细节特征的学习, 验证了本文方法在水声复杂多变信道中的良好泛化能力。

在复杂水下移动场景中, 衰落路径数的变化可能导致估计性能下降。本文通过生成不同衰落路径数的信道样本, 并在衰落路径数 $P = 8$ 的数据集上进行训练, 然后用训练好的模型分别在数据集 $P = 3, 4, 6, 10$ 上进行测试。由于测试 $P = 8$ 时使用的数据集与训练阶段一致, 因此将其作为基线。在不同衰

落路径数下 RGNet 方法的 NMSE 性能对比如图8所示。从图8可以看出, 当 $P = 3$ 时, 模型效果优于基线, 这是因为此时信道结构较简单, 更有利于生成网络在较少的计算复杂度下学习到有效的映射关系; 当 $P = 4, 6$ 时, 信道性能相较于基线略有下降, 但仍维持了较好的 NMSE 性能; 当 $P = 10$ 时, 信道性能较基线有了明显的下降。这表明当 $P = 3, 4, 6, 10$ 时, 训练的 RGNet 模型依然具有良好的鲁棒性。

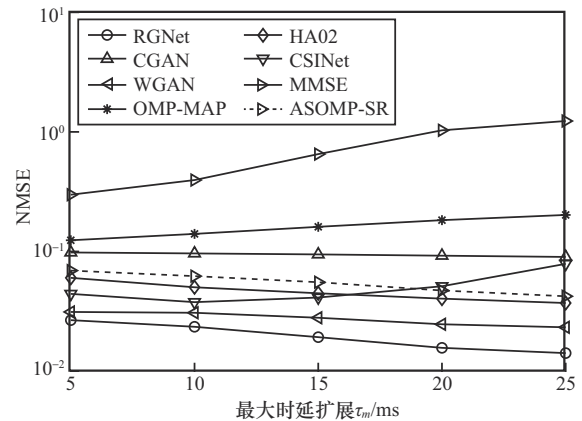


图7 不同方法在不同最大时延扩展下的 NMSE 性能对比




图8 在不同衰落路径数下 RGNet 方法的 NMSE 性能对比

图9验证了MIMO系统中不同发射阵元数对算法 BER 性能的影响。由图9可知, 当发射阵元数相同时, RGNet 方法的 BER 明显低于 CSINet, 这是因为 RGNet 方法在网络训练过程中能够根据目标函数的反馈自适应地调整网络参数, 优化了对信号细节特征的学习。

在水下通信环境中, 声速受水温、盐度和深度等因素的影响, 这些因素共同影响了水声信道的特性。图10(a)给出了墨西哥湾北部地区3个典型季节在水深0~200 m 的声速剖面对比, 结果表明, 声速随着深度的增加和水温的下降而逐渐减小。为评估不同水温和

声速环境对RGNet方法性能的影响,选择深度40 m处的数据生成3个典型季节的信道样本,并在暖水(夏季,水温20~30 °C,盐度35.5~36.5 ppt)数据集上进行训练,然后用训练好的模型分别在温水(春季)、暖水(夏季)和冷水(冬季)数据集上进行测试,结果如图10(b)所示。当水温降低时,RGNet方法由于信号自迭代更新网络对复杂信道环境中自适应能力的有效提升,性能至多只有0.028 dB的变化。


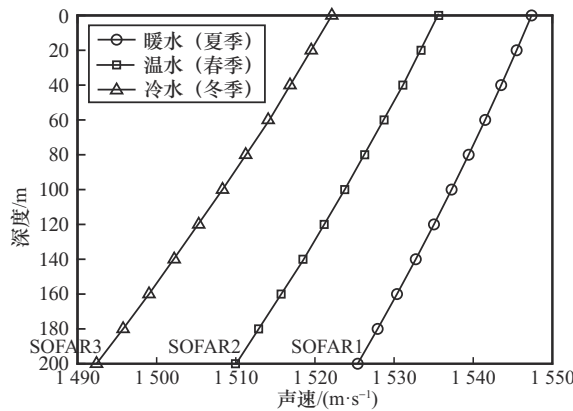



图9 在不同发射阵元数下RGNet方法的BER性能对比




(a) 墨西哥湾典型声速剖面对比




(b) NMSE与不同季节之间的关系

图10 在不同海洋环境下RGNet方法的NMSE性能对比


图11展示了RGNet方法估计得到的信道时延-多普勒信道响应热力图,并与HA02和OMP-MAP方法进行比较。RGNet方法的热力图显示出最清晰集中且高度聚焦的光斑,表明其在时滞补偿后能有效提高信道估计的精度和鲁棒性,适应复杂多变信道环境。HA02方法的热力图光斑边界模糊且分布广泛,因为其在实际移动水声场景下分辨率较低,受噪声影响较为显著。OMP-MAP方法的热力图出现光斑拉伸现象,因为该方法通过逐步选择字典元素来逼近信号的稀疏表示,但由于其贪心策略,会在信号恢复过程中对信号的细节特征估计精度不高,在高分辨率场景下的信道估计性能有限,对复杂信道环境的适应能力不足。



(a) HA02方法



(b) OMP-MAP方法



(c) RGNet方法

图11 不同估计方法的时延-多普勒信道响应热力图对比

5 结束语

为了解决水声通信环境下信道估计精度较低的问题,本文提出了一种基于RGNet的水声信道估计方法。针对水声信道动态变化带来的特征误差问题,提出了一种采用时滞补偿的局部化分析和三维重建算法;针对OTFS时延-多普勒矩阵容易受到噪声污染导致矩阵的扩展和失真的问题,提出了一种信号自迭代更新网络,并根据基于L1-正则化最小二乘法对网络权重与偏置进行更新;针对传统的水声信号深度学习模型训练稳定性不佳的问题,提出了一种基于Bures-Wasserstein目标函数的分解优化算法,将响应生成网络的训练分解为多个子问题分别进行优化求解,提高了模型收敛速度并降低了误差。与现有方法相比,本文方法具有更高的估计精度和鲁棒性。

附录1 Bures-Wasserstein距离最小值证明

将生成网络输出的信号经最小二乘法处理所获得的信道响应定义为 $\tilde{h} \in \mathcal{P}_2(\mathbb{R}^n)$,假设 $p_h, p_{\tilde{h}} \in N(\mathbb{C})$ 则存在

$$\mathcal{B}^2(p_h, p_{\tilde{h}}) = \inf \left\{ \mathcal{W}_2^2(\Sigma_{p_h}, \Sigma_{p_{\tilde{h}}}) \right\} \quad (38)$$

证明 对于给定的二维子空间 $\mathbb{C} \subseteq \mathbb{R}^n$, $\mathcal{B}^2(p_h, p_{\tilde{h}})$ 的最小值分布为 \tilde{h} 在 \mathbb{C} 上的正交投影,即

$$\mathcal{B}^2(p_h, p_{\tilde{h}}) = p_{\mathbb{C}_\#} \tilde{h} = \tilde{h}_{\mathbb{C}} \quad (39)$$

其中, $p_{\mathbb{C}_\#} \tilde{h}$ 表示将 \tilde{h} 投影到 \mathbb{C} 上的推前分布,用 $\tilde{h}_{\mathbb{C}}$ 表示 \tilde{h} 在子空间 \mathbb{C} 上的表示。将给定大小的 \mathbb{C} 的概率空间边界值集合表示为

$$\Gamma_{(x,y) \sim \pi} = \left\{ \mu_{\mathbb{R}}^n \in \mathcal{P}_2(\mathbb{R}^n \times \mathbb{R}^n) \mid \mu_1 = p_h, \mu_n = p_{\tilde{h}} \right\} \quad (40)$$

其中, $\mu_{\mathbb{R}}^n \in \mathcal{P}_2(\mathbb{R}^n \times \mathbb{R}^n)$, μ_1, μ_n 为 $\mu_{\mathbb{R}}^n \in \mathcal{P}_2(\mathbb{R}^n \times \mathbb{R}^n)$ 的边缘分布, $\mu_{\mathbb{R}}^n$ 在 \mathbb{C} 上的正交投影表示为 $\mu_{\mathbb{C}} = p_{\mathbb{C}_\#} \mu_{\mathbb{R}}^n$ 。

同时,定义二阶概率测度 δ 满足 $\delta \in \mathcal{P}_2(\mathbb{R}^n \times \mathbb{R}^n)$, δ 在 $\mathbb{C} \times \mathbb{C}$ 上表示为 $\delta_{\mathbb{C} \times \mathbb{C}} := p_{(\mathbb{C} \times \mathbb{C})_\#} \delta_{\mathbb{C} \times \mathbb{C}}$ 。在 $(p_h, p_{\tilde{h}})$ 这个可测的概率分布空间中,定义过程 $T: p_h \rightarrow p_{\tilde{h}}$ 为 $\mu_{\mathbb{R}}^n \in \mathcal{P}_2(p_h, p_{\tilde{h}})$ 的前推,并表示为 $T_{\#} \mu_{\mathbb{R}}^n \in \mathcal{P}_2(p_h, p_{\tilde{h}})$ 。对于任意模拟信道响应集 S 与过程 T 的转换表示为 $T_{\#} \mu_{\mathbb{R}}^n(S) = \mu_{\mathbb{R}}^n(T^{-1}(S)) \delta$ 。

如果 $\sup \left[\mathcal{B}^2(p_h, p_{\tilde{h}}) \right] = \sup \left(\Gamma_{(x,y) \sim \pi} \right)$, 则有

$$\begin{aligned} \inf_{(x,y) \in S_+} \mathcal{B}^2(p_h, p_{\tilde{h}}) &= \inf_{(x,y) \in S_+} \mathcal{W}_2^2(x,y) = \\ &= \inf_{(x,y) \sim \pi} \left\{ \int \int \|x - y\|^2 d\pi_{\mathbb{C} \times \mathbb{C}}(x,y) \right\} + \int \|y\|^2 dp_{\tilde{h}_{\mathbb{C}}}(y) \quad (41) \end{aligned}$$

其中,最小化是在模拟信道响应集 S 的可行域上进行近似的,且 $S_+ \in \mathbf{H}_+(n) \times \tilde{\mathbf{H}}_+(n)$,使 $\inf_{(x,y) \in S_+} \mathcal{B}^2(p_h, p_{\tilde{h}}) = \inf_{(x,y) \in S_+} \mathcal{W}_2^2(x,y)$ 成立。

因此,对于给定的 $\mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N)$,则有

$$\begin{aligned} \inf \left\{ \mathcal{W}_2^2(x,y) \mid p_h \in N(\mathbb{C}) \right\} &= \\ \inf \left\{ \inf \left\{ \int \|x - y\|^2 d\pi_{\mathbb{C} \times \mathbb{C}}(x,y) \mid x \in N(\mathbb{C}) \right\} \right\} &= \\ \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \left\{ \int \|y\|^2 dp_{\mathbb{C}_\#} \tilde{h}(y) \right\} & \quad (42) \end{aligned}$$

式(42)等价于

$$\begin{aligned} \inf \left\{ \inf \left\{ \int \|x - y\|^2 d\pi_{\mathbb{C} \times \mathbb{C}}(x,y) \mid x \in N(\mathbb{C}) \right\} \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \right\} &= \\ \inf \left\{ \mathcal{W}_2^2(\Sigma_{p_h}, \Sigma_{p_{\tilde{h}}}) \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \right\} & \quad (43) \end{aligned}$$

由于 $p_{\tilde{h}_{\mathbb{C}}} \in N(\mathbb{C})$,当 $p_{\tilde{h}}^* = p_{\mathbb{C}_\#} \tilde{h}$ 时,式(44)成立。

$$\begin{aligned} \inf_{(x,y) \in S_+} \mathcal{B}^2(A,B) &= \\ \inf \left\{ \inf \left\{ \mathcal{W}_2^2(\Sigma_{p_h}, \Sigma_{p_{\tilde{h}}}) \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \right\} \right\} &= \\ \Leftrightarrow \inf \left\{ \int \|y\|^2 dp_{\mathbb{C}_\#} \tilde{h}(y) \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \right\} &= \\ \Leftrightarrow \sup \left\{ \int \|y\|^2 dp_{\mathbb{C}_\#} \tilde{h}(y) \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) \right\} & \quad (44) \end{aligned}$$

因此可得

$$\begin{aligned} \inf_{(x,y) \in S_+} \mathcal{B}^2(A,B) &\leq \\ \sum_{i=1}^M \sum_{j=1}^N \int \|y\|^2 dp_{\mathbb{C}_\#} \tilde{h}(y) \mid \mathbb{C} \in \mathfrak{S}(\mathbb{R}^n, M \times N) &\leq \\ p_{\tilde{h}}^* = p_{\mathbb{C}_\#} \tilde{h} & \quad (45) \end{aligned}$$


证毕。

参考文献:


- [1] 林静怡, 孙宗鑫, 刘宇飞. OTFS水声通信技术研究现状与展望[J]. 数字海洋与水下攻防, 2022, 5(6): 502-509.
LIN J Y, SUN Z X, LIU Y F. Research status and prospect of OTFS underwater acoustic communication technology[J]. Digital Ocean & Underwater Warfare, 2022, 5(6): 502-509.
- [2] HADANI R, RAKIB S, TSATSANIS M, et al. Orthogonal time frequency space modulation[C]//Proceedings of the 2017 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2017: 1-6.
- [3] MOHAMMED S K, HADANI R, CHOCKALINGAM A, et al. OTFS: a mathematical foundation for communication and radar sensing in the delay-Doppler domain[J]. IEEE BITS the Information Theory Magazine, 2022, 2(2): 36-55.
- [4] ZHAO L, GAO W J, GUO W B. Sparse Bayesian learning of delay-Doppler channel for OTFS system[J]. IEEE Communications Letters, 2020, 24(12): 2766-2769.
- [5] SHEN W Q, DAI L L, AN J P, et al. Channel estimation for orthogonal

- time frequency space (OTFS) massive MIMO[J]. IEEE Transactions on Signal Processing, 2019, 67(16): 4204-4217.
- [6] LIU L, TAO C, QIU J H, et al. Position-based modeling for wireless channel on high-speed railway under a viaduct at 2.35 GHz[J]. IEEE Journal on Selected Areas in Communications, 2012, 30(4): 834-845.
- [7] WAN L, DENG S M, CHEN Y G, et al. Sparse channel estimation for underwater acoustic OFDM systems with super-nested pilot design[J]. Signal Processing, 2025, 227: 109709.
- [8] PANAYIRCI E, ALTABBAA M T, UYSAL M, et al. Sparse channel estimation for OFDM-based underwater acoustic systems in Rician fading with a new OMP-MAP algorithm[J]. IEEE Transactions on Signal Processing, 2019, 67(6): 1550-1565.
- [9] XIAO Z Q, ZENG Y, WEN F X, et al. Integrated sensing and channel estimation by exploiting dual timescales for delay-Doppler alignment modulation[J]. IEEE Transactions on Wireless Communications, 2025, 24(1): 415-429.
- [10] QIN X Z, QU F Z, ZHENG Y R. Bayesian iterative channel estimation and turbo equalization for multiple-input-multiple-output underwater acoustic communications[J]. IEEE Journal of Oceanic Engineering, 2021, 46(1): 326-337.
- [11] 梁永明, 罗汉文, 黄建国. MIMO-OFDM 系统中一种基于自适应滤波的信道估计方法[J]. 电子与信息学报, 2007, 29(2): 310-313.
LIANG Y M, LUO H W, HUANG J G. A method of channel estimation based on adaptive filtering in MIMO-OFDM systems[J]. Journal of Electronics & Information Technology, 2007, 29(2): 310-313.
- [12] SHEN L, ZAKHAROV Y, HENSON B, et al. Adaptive filtering for full-duplex UWA systems with time-varying self-interference channel[J]. IEEE Access, 2020, 8: 187590-187604.
- [13] LIU Y, RANGANATHAN R, HUNTER M T, et al. Complex adaptive LMS algorithm employing the conjugate gradient principle for channel estimation and equalization[J]. Circuits, Systems, and Signal Processing, 2012, 31(3): 1067-1087.
- [14] ZHANG A H, HAO W M, ZHOU Q Y, et al. A square-root variable step size with a l_p -norm penalty LMS algorithm for sparse channel estimation[J]. International Journal of Performability Engineering, 2020, 16(9): 1374-1382.
- [15] ZHANG A H, LIU P C, NING B, et al. Reweighted l_p constraint LMS-based adaptive sparse channel estimation for cooperative communication system[J]. IET Communications, 2020, 14(9): 1384-1391.
- [16] 夏麒麟, 王华华, 李峰. 一种基于小数倍多普勒信道的 OTFS 信道估计方法[J]. 计算机应用研究, 2024, 41(3): 900-904.
XIA Q Y, WANG H H, LI F. OTFS channel estimation method based on fractional Doppler channel[J]. Application Research of Computers, 2024, 41(3): 900-904.
- [17] LANGOWSKI A. Time and frequency synchronisation in 4G OFDM systems[J]. EURASIP Journal on Wireless Communications and Networking, 2009, 2009(1): 641292.
- [18] 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.
ZHANG Y L, WANG H B, LI C, et al. Advances in the intersection of channel estimation and machine learning in underwater acoustic communications[J]. Technical Acoustics, 2022, 41(3): 334-345.
- [19] CUI X R, ZHANG C, LI J, et al. Channel estimation based on dual frequency domain Transformer in time-frequency doubly-selective fading underwater acoustic channels[J]. Physical Communication, 2025, 68: 102585.
- [20] HE H T, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. IEEE Wireless Communications Letters, 2018, 7(5): 852-855.
- [21] LIU H J, LONG K. A deep learning channel estimator for millimeter-wave hybrid massive MIMO systems[J]. IEEE Wireless Communications Letters, 2023, 12(12): 2103-2107.
- [22] TONG W Q, XU W J, WANG F Y, et al. Deep learning compressed sensing-based beamspace channel estimation in mmWave massive MIMO systems[J]. IEEE Wireless Communications Letters, 2022, 11(9): 1935-1939.
- [23] LUAN D X, THOMPSON J. Attention based neural networks for wireless channel estimation[C]//Proceedings of the 2022 IEEE 95th Vehicular Technology Conference: (VTC2022-Spring). Piscataway: IEEE Press, 2022: 1-5.
- [24] WEN C K, SHIH W T, JIN S. Deep learning for massive MIMO CSI feedback[J]. IEEE Wireless Communications Letters, 2018, 7(5): 748-751.
- [25] MA X C, XIN Y, REN Y, et al. Diffusion model based channel estimation[C]//Proceedings of the 2024 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2024: 1159-1164.
- [26] XU S, ZHANG J X, XU Y F, et al. Brownian bridge-based diffusion channel denoising for ISAC massive MIMO systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 11(2): 764-776.
- [27] ZHOU Y H, SONG A J, TONG F, et al. Distributed compressed sensing based channel estimation for underwater acoustic multiband transmissions[J]. The Journal of the Acoustical Society of America, 2018, 143(6): 3985.
- [28] YE H, LIANG L, LI G Y, et al. Deep learning-based end-to-end wireless communication systems with conditional GANs as unknown channels[J]. IEEE Transactions on Wireless Communications, 2020, 19(5): 3133-3143.
- [29] ZHOU M Z, WANG J F, SUN H X. Wasserstein GAN based underwater acoustic channel simulator[C]//Proceedings of the 2023 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). Piscataway: IEEE Press, 2023: 1-6.

[作者简介]



徐明 (1977-), 男, 安徽马鞍山人, 博士, 上海海事大学教授, 主要研究方向为水声传感器网络、水声通信、深度学习、网络与信息安全等。



张琦 (1999-), 女, 安徽池州人, 上海海事大学硕士生, 主要研究方向为水声通信网络、深度学习、信道估计。