

基于基扩展模型和双向 LSTM 网络的 OTFS 信道估计算法

黄子懿¹, 李国权¹, 林金朝¹, 庞宇¹, 武瑞恒²

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 伦敦布鲁内尔大学电子与电气工程系, 英国伦敦 UB8 3PH)

摘要: 高精度的信道估计是正交时频空间 (OTFS) 系统在 6G 高速移动场景中可靠应用的关键。为进一步提升 OTFS 系统的信道估计精度, 提出了一种基于融合基扩展模型 (BEM) 和双向长短期记忆 (LSTM) 网络的 OTFS 信道估计算法。首先利用 BEM 将延时-多普勒 (DD) 域的信道估计问题转换为基系数估计问题, 然后引入双向 LSTM 网络对基系数进行离线训练与在线预测, 并结合自注意力 (SA) 机制增强对时序特征的全局感知能力, 实现基系数的高精度估计与动态跟踪。在此基础上, 进一步设计了一种低复杂度两级均衡器, 基于估计得到的基系数重构信道信息, 通过单抽头均衡器消除多径效应, 并在 DD 域采用基于对数似然比的迭代干扰消除 (LLR-IIC) 算法抑制多普勒扩展引起的残余干扰。仿真结果表明, 所提算法在信道估计精度、泛化能力和复杂度方面均具有明显优势; 结合所提均衡器后, 可在保持较低复杂度情况下, 实现更优的误比特率 (BER) 性能。

关键词: 信道估计; 正交时频空间; 高速移动场景; 基扩展模型; 双向长短期记忆; 两级均衡器

中图分类号: TN92

文献标志码: A

Channel estimation algorithm for OTFS based on basis expansion model with bidirectional LSTM network

Huang Ziyi¹, Li Guoquan¹, Lin Jinzhao¹, Pang Yu¹, Wu Ruiheng²

1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

2. Department of Electronic and Electrical Engineering, Brunel University London, London UB8 3PH, UK

Abstract: Accurate channel estimation is critical for the reliable deployment of orthogonal time frequency space (OTFS) systems in 6G high-mobility scenarios. To further improve the channel estimation accuracy in OTFS systems, this paper proposes a channel estimation algorithm integrating the basis expansion model (BEM) and a bidirectional long short-term memory (LSTM) network. The proposed algorithm first uses BEM to reformulate the channel estimation problem in the delay-Doppler (DD) domain into a basis coefficient estimation problem. A bidirectional LSTM network is then introduced for offline training and online prediction of the basis coefficients, and a self-attention (SA) mechanism is incorporated to strengthen global perception of temporal features, enabling high-accuracy estimation and dynamic tracking of the basis coefficients. Building on this, a low-complexity two-stage equalizer is further designed. Channel information is reconstructed from the estimated basis coefficients, multipath effects are mitigated via a single-tap equalizer, and a log likelihood ratio based iterative interference cancellation (LLR-IIC) algorithm is employed in the DD domain to suppress residual interference induced by Doppler spread. Simulation results demonstrate that the proposed algorithm offers significant advantages in channel estimation accuracy, generalization capability, and complexity. When combined with the proposed equalizer, superior bit error rate (BER) performance is achieved while maintaining low complexity.

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 李国权, ligq@cqupt.edu.cn

基金项目: 国家自然科学基金资助项目(No.U21A20447, No.12411530119); 重庆自然科学基金资助项目(No.CSTB2022NSCQ-LZX0069); 成都市科技项目(No.2025-YF11-00077-HZ)

Foundation Items: The National Natural Science Foundation of China (No.U21A20447, No.12411530119), The Chongqing Natural Science Foundation (No.CSTB2022NSCQ-LZX0069), The Chengdu Science and Technology Program (No.2025-YF11-00077-HZ)

Key words: channel estimation, OTFS, high-mobility scenarios, BEM, bidirectional LSTM, two-stage equalizer

0 引言

当前, 移动通信技术正在向 6G 演进, 实现“空天地海一体化^[1]、全场景深度覆盖^[2]、高速移动通信^[3]”已成为其核心目标。4G 与 5G 所采用的正交频分复用 (orthogonal frequency division multiplexing, OFDM) 技术, 在静态或低速场景下表现优异^[4-5], 但面对低轨卫星^[6]、超高速列车^[7]及高空长航时无人机^[8]等典型 6G 高速移动场景时, 由于无线信道表现出强烈的双选衰落特性, OFDM 子载波正交性难以维持, 通信性能受到显著影响^[9-11]。

正交时频空间 (orthogonal time frequency space, OTFS) 调制通过将时变信道转换至延时-多普勒 (delay-Doppler, DD) 域进行处理, 将原本快变、弥散的时间-频率 (time-frequency, TF) 域信道响应转换为具有缓变、稀疏特性的信道表征, 具备优异的时变信道适应性与子载波间干扰 (inter-carrier interference, ICI) 抑制能力, 从本质上克服了高速场景下信道时变与多普勒扩展带来的负面影响, 为高速移动通信挑战提供了有效的解决路径^[12-14]。然而, 高速移动带来的信道快速时变与多普勒扩展, 使得准确获取其信道响应面临诸多挑战。

针对 OTFS 系统的信道估计, 现有研究主要沿着三条技术路线展开。第一条路线为传统相关或阈值类算法。文献[15]提出相关信道估计 (correlation channel estimation, CCE) 算法, 假设信道在一个符号周期内保持恒定, 通过估计 DD 域中元素的互相关函数实现信道估计。然而在高速移动场景下, 相干时间远小于符号持续时间, 该假设不再成立, 导致估计精度快速下降。文献[16]针对整数与分数多普勒频移的多径信道分别设计了 OTFS 符号排列结构, 采用基于阈值的信道估计 (threshold channel estimation, TCE) 算法获取信道状态信息 (channel state information, CSI), 并通过 DD 域最小均方误差 (minimum mean square error, MMSE) 均衡器实现均衡, 获得了较高的频谱效率, 但均衡器复杂度较高。第二条路线是基于基扩展模型 (basis expansion model, BEM) 的信道估计算法。文献[17]采用广义复指数 BEM (generalized complex exponential-BEM, GCE-BEM) 将时域信道冲激响应

(channel impulse response, CIR) 的估计问题转换为基系数估计问题, 利用导频处的线性最小均方差 (linear MMSE, LMMSE) 基系数估计值与拉格朗日插值算法估计数据处的基系数。该算法结构简单, 但在高速场景下插值结果难以准确跟踪信道的快时变特性, 估计误差显著增大。文献[18]证明了 BEM 中的基系数具有稀疏性, 因此可以将信道估计转换为稀疏信号重构问题, 提出基于 BEM 的改进正则化正交匹配追踪 (improved regularized orthogonal matching pursuit, iROMP) 迭代稀疏信道估计算法, 通过迭代反馈提升估计精度。然而这种算法依赖预定义的稀疏度参数, 对噪声和模型失配较为敏感。第三条路线是深度学习算法。利用深度神经网络 (deep neural networks, DNNs)^[19]、长短期记忆 (long short-term memory, LSTM)^[20-21] 网络及门控循环单元 (gated recurrent unit, GRU)^[22] 等模型对时序特征的强大学习能力, 能够有效捕捉信道在不同域中的结构化特征, 从而抵抗多普勒扩展与多径效应。文献[20]和文献[21]将 LSTM 应用于 OTFS 信道估计, 但其采用的单向 LSTM 结构仅能利用过去时刻的导频信息, 无法引入未来时刻的导频信息, 导致在预测数据符号位置的 CSI 时缺失了后续导频所包含的时间相关性, 为此需要配置较密集的导频才能保证估计精度。此外, 在均衡器方面, 文献[23]分析得出 OTFS 系统在 TF 域和 DD 域中采用 MMSE 均衡器均涉及高维矩阵求逆运算而复杂度过高, 难以在实际系统中实现。相比之下, TF 域中单抽头均衡器虽复杂度较低, 但在高速移动场景下性能损失严重。因此, 在完成信道估计之后, 设计一种低复杂度的均衡器同样是提升系统性能的关键。

综上, 传统相关或阈值类算法在高速场景下估计精度低, 基于 BEM 的插值算法难以跟踪信道的快速变化, 基于 BEM 的稀疏重构算法对噪声较为敏感。在深度学习算法中, 单向 LSTM 无法利用后向信息, 不能建模全局时间相关性, 导频开销较大。

针对上述问题, 本文提出了一种基于 BEM 和双向 LSTM 网络的 OTFS 信道估计算法, 首先将 DD 域信道估计问题转换为基于 BEM 的低维基系数

估计, 减少待估计参数数量, 然后提出基于双向 LSTM 网络的基系数估计算法进行精确估计, 进而重构信道信息。在此基础上, 提出了一种低复杂度两级均衡器, 采用单抽头均衡器消除多径效应并完成初步 ICI 抑制, 然后利用基于对数似然比的迭代干扰消除 (log likelihood ratio based iterative interference cancellation, LLR-IIC) 算法进一步消除残余干扰, 在低复杂度情况下实现了良好的性能。本文的主要工作如下。

1) 建立 OTFS 系统传输模型, 将 DD 域中的信道估计问题等效地转换为时域信道估计问题, 接着采用 GCE-BEM 将时域信道估计问题转换为基系数估计问题, 减少了需要估计的参数数量。在此基础上, 进一步提出了一种基于双向 LSTM 网络的基系数估计算法, 利用双向 LSTM 的时序建模能力捕捉基系数的前后依赖关系, 并引入自注意力 (self-attention, SA) 机制增强对全局特征的感知, 实现对基系数的高精度估计与动态跟踪。

2) 提出了一种低复杂度两级均衡器, 基于基系数估计值重构得到的信道信息, 在 TF 域中采用单抽头均衡器消除多径效应并完成初步 ICI 抑制, 然后在 DD 域中采用 LLR-IIC 算法, 通过引入阻尼因子保障迭代收敛, 在避免高维矩阵求逆的同时有效消除多普勒扩展引起的残余干扰。

3) 针对提出的算法进行了仿真对比分析, 结果表明, 所提信道估计算法的归一化均方误差 (normalized mean square error, NMSE) 较对比算法

明显更优, 且在不同移动速度条件下表现出较强的泛化能力; 所提两级均衡器在复杂度远低于现有方案的情况下具有良好的误比特率 (bit error rate, BER) 性能, 且能够快速收敛。整体而言, 所提算法在估计精度、系统性能与复杂度之间取得了良好平衡。

1 OTFS 系统模型

本文研究的 OTFS 系统的传输模型如图 1 所示。在发射端, 长度为 MN_d 的正交幅度调制 (quadrature amplitude modulated, QAM) 数据符号序列被重新排列为一个二维符号块, 在 DD 域中记为 $\mathbf{X}^{\text{DD}} \in \mathbb{C}^{M \times N_d}$, 其中 M 和 N_d 分别表示延时维度和多普勒维度上的数据符号数量。经过辛有限傅里叶逆变换 (inverse symplectic finite Fourier transform, ISFFT) 将 \mathbf{X}^{DD} 转换为 TF 域发射数据符号矩阵 $\mathbf{X}^{\text{TF}} \in \mathbb{C}^{M \times N_d}$ 表示为

$$\mathbf{X}^{\text{TF}} = \mathbf{F}_M \mathbf{X}^{\text{DD}} \mathbf{F}_{N_d}^{\text{H}} \quad (1)$$

其中, $\mathbf{F}_M \in \mathbb{C}^{M \times M}$ 和 $\mathbf{F}_{N_d} \in \mathbb{C}^{N_d \times N_d}$ 为离散傅里叶变换 (discrete Fourier transform, DFT) 矩阵, $(\cdot)^{\text{H}}$ 表示共轭转置操作。

TF 域发射符号矩阵 $\mathbf{S}^{\text{TF}} \in \mathbb{C}^{M \times N}$ 由已知的前导序列和数据字段组成, 其结构如图 1 所示。前导序列预留用于同步功能, 同时可以作为导频符号使用, 数据字段用于传输数据符号与导频符号。 \mathbf{S}^{TF} 共包含 $N = N_d + N_p + 1$ 列, 其中第 1 列为前导序列

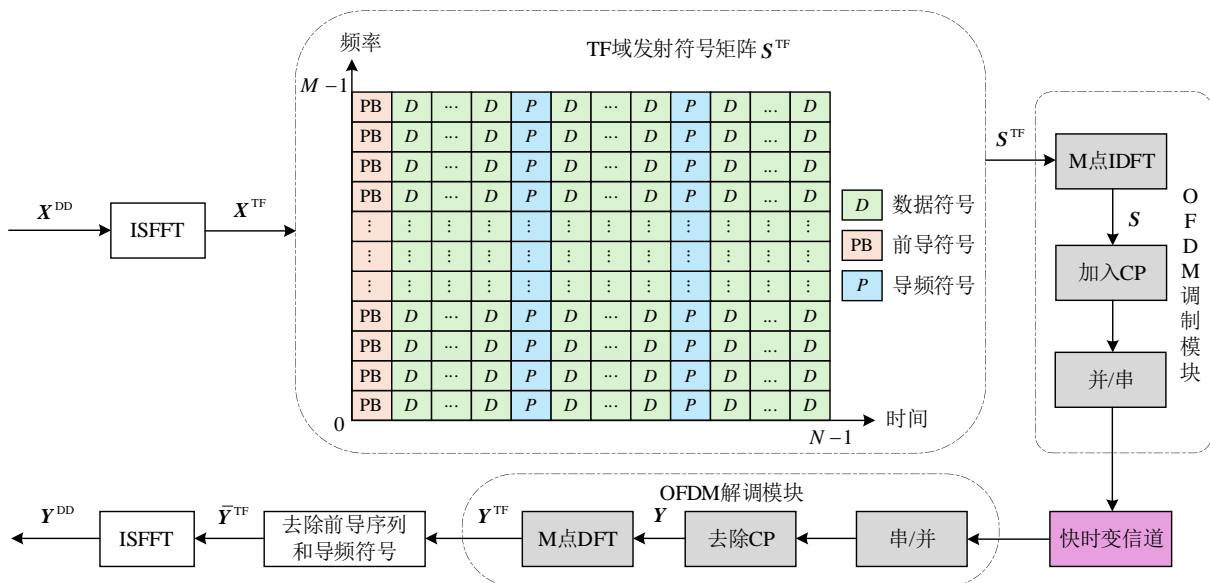


图 1 OTFS 系统的传输模型

$\mathbf{x}^{\text{pb}} \in \mathbb{C}^{M \times 1}$, N_d 列为数据符号 \mathbf{X}^{TF} , N_p 列为预先生成的导频符号 $\mathbf{X}^p \in \mathbb{C}^{M \times N_p}$, 导频符号沿着时间维度上等间隔插入。所有符号时间集合表示为 $U_{\text{up}} = U_p \cup U_d \cup U_{\text{pb}}$, 其中 U_p 为导频符号时间集合, U_d 为数据符号时间集合, U_{pb} 为前导序列符号时间集合。对 \mathbf{S}^{TF} 中的每一列应用 M 点离散傅里叶逆变换 (inverse discrete Fourier transform, IDFT) 得到时域发射符号矩阵 $\mathbf{S} \in \mathbb{C}^{M \times N}$ 表示为

$$\mathbf{S} = \mathbf{F}_M^H \mathbf{S}^{\text{TF}} \quad (2)$$

其中, $\mathbf{S} = [\mathbf{s}_0, \mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_{N-1}]$, \mathbf{S} 中每个列向量 $\mathbf{s}_n = [s_n(0), s_n(1), \dots, s_n(M-1)]^T \in \mathbb{C}^{M \times 1}$ 表示一个时域 OFDM 发射符号向量, $s_n(m)$ 表示第 n 个时域 OFDM 发射符号向量中第 m 个子载波上的符号, $m = 0, 1, \dots, M-1$, $n = 0, 1, \dots, N-1$, $(\cdot)^T$ 表示转置操作, $\mathbf{F}_M^H \in \mathbb{C}^{M \times M}$ 为 IDFT 矩阵。

为了避免符号间干扰 (inter-symbol interference, ISI) 的影响, 在每个符号时间的开始处插入长度为 M_{cp} 的循环前缀 (cyclic prefix, CP)。在接收

$$\mathbf{H}_n = \begin{bmatrix} h_n(0,0) & 0 & \dots & h_n(0,L-1) & \dots & h_n(0,1) \\ h_n(1,1) & h_n(1,0) & 0 & \dots & \dots & h_n(1,2) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & 0 & h_n(M-1,L-1) & \dots & h_n(M-1,0) \end{bmatrix} \quad (4)$$

令 $\mathbf{Y} = [\mathbf{y}_0, \mathbf{y}_1, \dots, \mathbf{y}_{N-1}] \in \mathbb{C}^{M \times N}$ 表示时域 OFDM 接收符号矩阵, 通过对 \mathbf{Y} 中的每一列应用 M 点 DFT 得到 TF 域接收符号矩阵 $\mathbf{Y}^{\text{TF}} \in \mathbb{C}^{M \times N}$ 表示为

$$\mathbf{Y}^{\text{TF}} = \mathbf{F}_M \mathbf{Y} \quad (5)$$

其中, $\mathbf{Y}^{\text{TF}} = [\mathbf{y}_0^{\text{TF}}, \mathbf{y}_1^{\text{TF}}, \dots, \mathbf{y}_{N-1}^{\text{TF}}]$, \mathbf{Y}^{TF} 中每个列向量 $\mathbf{y}_n^{\text{TF}} \in \mathbb{C}^{M \times 1}$ 为 TF 域接收符号向量。去除 \mathbf{Y}^{TF} 中前导序列和导频符号位置的列向量后得到 TF 域接收数据符号矩阵 $\bar{\mathbf{Y}}^{\text{TF}} = [\bar{\mathbf{y}}_0, \bar{\mathbf{y}}_1, \dots, \bar{\mathbf{y}}_{N_d-1}] \in \mathbb{C}^{M \times N_d}$, $\bar{\mathbf{Y}}^{\text{TF}}$ 中每个列向量 $\bar{\mathbf{y}}_{n_d} \in \mathbb{C}^{M \times 1}$ 为 TF 域接收数据符号向量, $n_d = 0, 1, \dots, N_d-1$ 。经过辛有限傅里叶变换 (symplectic finite Fourier transform, SFFT) 将 $\bar{\mathbf{Y}}^{\text{TF}}$ 转换为 DD 域接收数据符号矩阵 $\mathbf{Y}^{\text{DD}} \in \mathbb{C}^{M \times N_d}$ 表示为

$$\mathbf{Y}^{\text{DD}} = \mathbf{F}_M^H \bar{\mathbf{Y}}^{\text{TF}} \mathbf{F}_{N_d} \quad (6)$$

综上, 可以得到 OTFS 系统中 DD 域的输入输出关系为

端, 去除 CP 后时域 OFDM 接收符号向量 $\mathbf{y}_n \in \mathbb{C}^{M \times 1}$ 为

$$\mathbf{y}_n = \sum_{l=0}^{L-1} \mathbf{g}_l \mathbf{h}_{n,l} + \mathbf{e}_n = \mathbf{H}_n \mathbf{s}_n + \mathbf{e}_n \quad (3)$$

其中, $\mathbf{g}_l = \text{diag}(\mathbf{s}_{n,l}) \in \mathbb{C}^{M \times M}$, $\text{diag}(\cdot)$ 为提取矩阵对角线元素构成列向量或使用向量构造对角矩阵, $\mathbf{s}_{n,l} = [s_n(-l), s_n(-l+1), \dots, s_n(M-l-1)]^T \in \mathbb{C}^{M \times 1}$ 为第 n 个 OFDM 符号时间内第 l 条路径中的发射信号。 $\mathbf{h}_{n,l} \in \mathbb{C}^{M \times 1}$ 为第 n 个 OFDM 符号在第 l 条路径中的时域 CIR 向量, 由元素 $h_n(m,l)$ 构成, $h_n(m,l)$ 为第 n 个 OFDM 符号时间内第 l 条路径中第 m 个采样点的时域 CIR。 $l = 0, 1, \dots, L-1$, L 表示多径信道数量并且满足 $L \leq M_{\text{cp}}$ 。 $\mathbf{e}_n \in \mathbb{C}^{M \times 1}$ 表示均值为 0, 协方差矩阵为 $\sigma_e^2 \mathbf{I}_M$ 复加性高斯白噪声 (additive white gaussian noise, AWGN) 向量, \mathbf{I}_M 表示维度为 $M \times M$ 的单位矩阵。 $\mathbf{H}_n \in \mathbb{C}^{M \times M}$ 为第 n 个 OFDM 符号的时域 CIR 矩阵, 如下式所示

$$\begin{aligned} \mathbf{y}^{\text{DD}} &= (\mathbf{F}_{N_d} \otimes \mathbf{I}_M) \bar{\mathbf{E}}^T \bar{\mathbf{H}} \bar{\mathbf{E}} (\mathbf{F}_{N_d}^H \otimes \mathbf{I}_M) \mathbf{x}^{\text{DD}} + \mathbf{e}^{\text{DD}} \\ &= \mathbf{H}^{\text{DD}} \mathbf{x}^{\text{DD}} + \mathbf{e}^{\text{DD}} \end{aligned} \quad (7)$$

其中, $\mathbf{y}^{\text{DD}} = \text{vec}(\mathbf{Y}^{\text{DD}}) \in \mathbb{C}^{MN_d \times 1}$ 表示 DD 域接收数据符号向量, $\mathbf{x}^{\text{DD}} = \text{vec}[(\mathbf{X}^{\text{DD}})^T] \in \mathbb{C}^{MN_d \times 1}$ 表示 DD 域发射数据符号向量, $\text{vec}(\cdot)$ 表示沿着矩阵的列顺序将矩阵重排为列向量, \otimes 表示克罗内克积。 $\bar{\mathbf{E}} \in \mathbb{C}^{MN_d \times MN_d}$ 表示置换矩阵^[24-25], $\mathbf{e}^{\text{DD}} \in \mathbb{C}^{MN_d \times 1}$ 表示均值为 0, 协方差矩阵为 $\sigma_d^2 \mathbf{I}_{MN_d}$ 的 DD 域信道噪声

$$\mathbf{H}^{\text{DD}} = (\mathbf{F}_{N_d} \otimes \mathbf{I}_M) \bar{\mathbf{E}}^T \bar{\mathbf{H}} \bar{\mathbf{E}} (\mathbf{F}_{N_d}^H \otimes \mathbf{I}_M) \in \mathbb{C}^{MN_d \times MN_d}$$
 表示 DD 域等效信道矩阵, 其中 $\bar{\mathbf{H}} \in \mathbb{C}^{MN_d \times MN_d}$ 由数据符号时间对应的时域 CIR 矩阵 $\tilde{\mathbf{H}}_{n_d} \in \mathbb{C}^{M \times M}$ 构成

$$\bar{\mathbf{H}} = \begin{bmatrix} \tilde{\mathbf{H}}_0 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \tilde{\mathbf{H}}_{N_d-1} \end{bmatrix} \quad (8)$$

则由式(7)与式(8)可知, OTFS系统在DD域中的信道估计问题可以等效地转换为时域信道估计问题。

2 基于BEM和双向LSTM网络信道估计

本节针对高速移动场景下的OTFS系统,提出了一种基于BEM和双向LSTM网络信道估计算法。首先采用BEM-LMMSE算法获取取频处的基系数向量估计值,将其作为双向LSTM层的输入序列。双向LSTM层借助其独特的双向循环架构,通过正向和反向的LSTM单元并行处理输入序列,有效捕获基系数在时域上的前后依赖关系;其门控机制能够选择性保留重要历史信息并融合未来上下文特征,实现对快时变信道动态特性的全面建模。在此基础上,引入SA机制,通过计算序列内部各时间步的相关性权重,动态聚焦于关键特征,增强对基系数序列全局长期依赖关系的建模能力。双向LSTM层擅长捕捉局部时序特征,SA机制专注于全局特征关联,二者协同构成强大的时序特征提取器。最终通过一个浅层神经网络(neural network, NN)进一步优化估计结果,增强模型的去噪声能力,提升基系数的估计精度。综上所述,所提出的基于BEM的自注意力增强的双向LSTM(bidirectional LSTM enhanced by self-attention, Bi-LSTM-SA)网络模型如图2所示。

2.1 BEM信道建模

BEM通过将时域CIR分解为一组基函数与基

系数乘积的组合,使得连续时变的信道估计问题转换为可估计基系数的重构问题,将需要估计的信道参数数量从 ML 减少到 QL ,其中 Q 表示BEM阶数且 $Q \ll M$ 。令 $\mathbf{G}_n = [\mathbf{g}_0, \mathbf{g}_1, \dots, \mathbf{g}_{L-1}] \in \mathbb{C}^{M \times ML}$, $\mathbf{h}_n = [\mathbf{h}_{n,0}^T, \mathbf{h}_{n,1}^T, \dots, \mathbf{h}_{n,L-1}^T]^T \in \mathbb{C}^{ML \times 1}$, 则可以得到式(3)的等效表达式为

$$\mathbf{y}_n = \mathbf{G}_n \mathbf{h}_n + \mathbf{e}_n \quad (9)$$

BEM将 $\mathbf{h}_{n,l}$ 表示为基函数与基系数的组合为

$$\mathbf{h}_{n,l} = \sum_{q=0}^{Q-1} c_l(q) \mathbf{b}_q + \boldsymbol{\xi}_l = \mathbf{B} \mathbf{c}_l + \boldsymbol{\xi}_l \quad (10)$$

其中, $\mathbf{c}_l = [c_0(l), c_1(l), \dots, c_{Q-1}(l)]^T \in \mathbb{C}^{Q \times 1}$ 为第 l 条路径的基系数向量, $\boldsymbol{\xi}_l \in \mathbb{C}^{M \times 1}$ 为第 l 条路径的建模误差。 $\mathbf{B} = [\mathbf{b}_0, \mathbf{b}_1, \dots, \mathbf{b}_{Q-1}] \in \mathbb{C}^{M \times Q}$ 为基函数矩阵, $\mathbf{b}_q = [b_q(0), b_q(1), \dots, b_q(M-1)]^T \in \mathbb{C}^{M \times 1}$ 为已知的GCE-BEM基函数向量, $q = 0, 1, \dots, Q-1$ 。 \mathbf{b}_q 中的第 m 个元素为

$$b_q(m) = e^{\frac{j2\pi(q-Q)m}{MR}} \quad (11)$$

其中, R 表示分辨率参数, 为正整数且通常取 $R \geq 2^{[26]}$ 。通过使用GCE-BEM对信道进行建模, 无需先验多普勒信息, 能够省去复杂的多普勒信息估计过程。同时, 对于给定的参数 Q , 在不同高速移动场景下, 基函数与基系数矩阵的维度均保持不变, 从而避免了重新配置的需求。

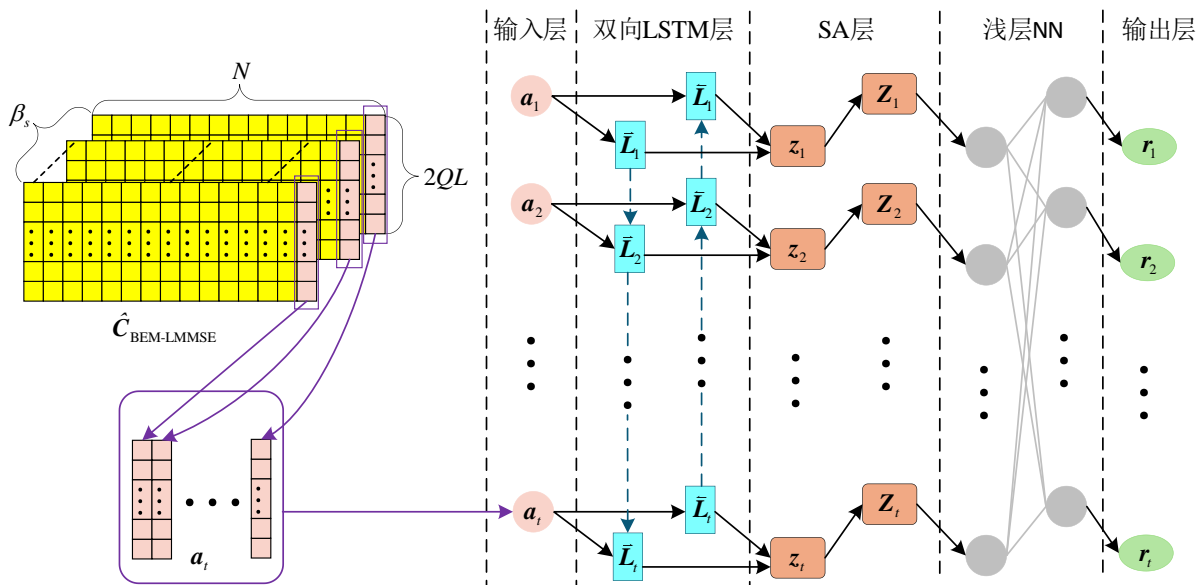


图2 基于BEM的Bi-LSTM-SA网络模型

综上, 第 n 个 OFDM 符号的时域 CIR 向量为

$$\mathbf{h}_n = \mathbf{P}\mathbf{c}_n + \boldsymbol{\varsigma} \quad (12)$$

其中, $\mathbf{c}_n = [\mathbf{c}_0^T, \mathbf{c}_1^T, \dots, \mathbf{c}_{L-1}^T]^T \in \mathbb{C}^{QL \times 1}$ 为基系数矩阵,

$\mathbf{P} = \mathbf{B} \otimes \mathbf{I}_L \in \mathbb{C}^{ML \times QL}$, $\boldsymbol{\varsigma} = [\boldsymbol{\xi}_0^T, \boldsymbol{\xi}_1^T, \dots, \boldsymbol{\xi}_{L-1}^T]^T \in \mathbb{C}^{ML \times 1}$ 为 GCE-BEM 整个运算过程中的压缩误差, 可以忽略^[26]。则由式(9)与式(12)可知, BEM 能够将时域信道估计问题等效地转换为基系数估计问题。

2.2 基系数初始估计

本文所提网络的估计过程始于 BEM-LMMSE 算法估计得到的导频信号处的基系数向量估计值。由式(5)、式(9)与式(12)可知 TF 域接收符号向量 \mathbf{y}_n^{TF} 为

$$\mathbf{y}_n^{\text{TF}} = \mathbf{F}_M \mathbf{G}_n \mathbf{P} \mathbf{c}_n + \boldsymbol{\omega}_n = \mathbf{D}_n \mathbf{c}_n + \boldsymbol{\omega}_n \quad (13)$$

其中, $\mathbf{D}_n = \mathbf{F}_M \mathbf{G}_n \mathbf{P} \in \mathbb{C}^{M \times QL}$ 为观测矩阵, $\boldsymbol{\omega}_n \in \mathbb{C}^{M \times 1}$ 表示均值为 0, 协方差矩阵为 $\sigma_\omega^2 \mathbf{I}_M$ 的频域噪声向量。当 $n \in U_p \cup U_{\text{pb}}$ 时, 前导序列和导频符号处对应的 \mathbf{G}_n 在接收端是已知的, 则公式(13)中导频位置对应的 \mathbf{D}_n 是已知的。

采用 LMMSE 算法对导频位置的基系数向量进行估计时, 需要将信道相关矩阵和噪声协方差矩阵映射到基函数向量张成的低维空间中才能完成估计, 映射关系为

$$\bar{\mathbf{R}}_{\text{HH}} = \left[(\mathbf{P}^H \mathbf{P})^{-1} \mathbf{P}^H \right] \mathbf{R}_{\text{HH}} \left[\mathbf{P} (\mathbf{P}^H \mathbf{P})^{-1} \right] \quad (14a)$$

$$\mathbf{R}_{\text{HH}}(\alpha, \beta) = \frac{1 - e^{-t_{\text{max}} \left(\frac{1}{\tau_{\text{rms}}} + j2\pi \frac{\alpha - \beta}{\kappa} \right)}}{(1 - e^{-\frac{t_{\text{max}}}{\tau_{\text{rms}}}}) \left(1 + j2\pi \frac{\alpha - \beta}{\kappa} \tau_{\text{rms}} \right)} \quad (14b)$$

$$\mathbf{E} = \left[(\mathbf{P}^H \mathbf{P})^{-1} \mathbf{P}^H \right] (\sigma_\omega^2 \mathbf{I}_{ML}) \left[\mathbf{P} (\mathbf{P}^H \mathbf{P})^{-1} \right] \quad (14c)$$

其中, $\alpha = 1, 2, \dots, ML$, $\beta = 1, 2, \dots, ML$, $\mathbf{R}_{\text{HH}} \in \mathbb{C}^{ML \times ML}$ 为时域 CIR 的自相关矩阵, τ_{rms} 表示均方根时延扩展, t_{max} 表示最大时延扩展, $\kappa = ML$ 表示信道抽头数。 $\bar{\mathbf{R}}_{\text{HH}} \in \mathbb{C}^{QL \times QL}$ 为映射后的自相关矩阵, $\mathbf{E} \in \mathbb{C}^{QL \times QL}$ 为映射后的信道噪声协方差矩阵。因此, 当 $n \in U_p \cup U_{\text{pb}}$ 时基于 BEM 的 LMMSE 算法对导频位置的基系数向量 $(\hat{\mathbf{c}}_n^p)_{\text{LMMSE}} \in \mathbb{C}^{QL \times 1}$ 进行估计表示为

$$(\hat{\mathbf{c}}_n^p)_{\text{LMMSE}} = \bar{\mathbf{R}}_{\text{HH}} (\bar{\mathbf{R}}_{\text{HH}} + \mathbf{E})^{-1} (\hat{\mathbf{c}}_n^p)_{\text{LS}} \quad (15)$$

其中, $(\hat{\mathbf{c}}_n^p)_{\text{LS}} \in \mathbb{C}^{QL \times 1}$ 由最小二乘 (least square, LS) 算法对 $n \in U_p \cup U_{\text{pb}}$ 时的基系数向量进行估计得到

$$(\hat{\mathbf{c}}_n^p)_{\text{LS}} = (\mathbf{D}_n^H \mathbf{D}_n)^{-1} \mathbf{D}_n^H \mathbf{y}_n^{\text{TF}} \quad (16)$$

令 $\bar{\mathbf{C}} = [\bar{\mathbf{c}}_0, \bar{\mathbf{c}}_1, \dots, \bar{\mathbf{c}}_{N-1}] \in \mathbb{C}^{QL \times N}$ 表示待估计的基系数矩阵。当 $n \in U_p \cup U_{\text{pb}}$ 时, $\bar{\mathbf{c}}_n = (\hat{\mathbf{c}}_n^p)_{\text{LMMSE}}$, 当 $n \in U_d$ 时, 对应的 $\bar{\mathbf{c}}_n$ 为零向量。由于复数值神经网络结构复杂, 所需神经元数目较多, 导致在线下训练网络和线上对基系数进行预测时会引起较长的运行时间, 并且整体计算复杂度较大。因此本文将样本数据的实部和虚部进行分离重组, 采用一个实值神经网络训练基系数的实部与虚部。将待估计的基系数矩阵表示为 $\hat{\mathbf{C}}_{\text{BEM-LMMSE}} = [\text{Re}(\bar{\mathbf{C}}); \text{Im}(\bar{\mathbf{C}})] \in \mathbb{R}^{2QL \times N}$, 将其作为双向 LSTM 的输入信号如图 2 所示。

2.3 基于双向 LSTM 的基系数估计

双向 LSTM 通过并行处理正向与反向两个方向的序列, 融合过去与未来的时序信息, 从而克服单向 LSTM 仅依赖历史信息的局限, 实现更精准的序列建模^[27]。本文采用双向 LSTM 对基系数序列建模, 以导频符号时间的基系数值作为已知信息, 利用正向与反向的基系数时序信息提取局部特征, 得到隐藏状态序列。

双向 LSTM 层结构如图 2 所示, 其中 \vec{L}_t 和 \overleftarrow{L}_t 分别表示正向和反向的 LSTM 单元, $t = 1, 2, \dots, N$ 。假设 LSTM 单元内隐藏单元的个数为 χ , 给定时间步 t 的小批量输入为 $\mathbf{a}_t \in \mathbb{R}^{\beta_s \times 2QL}$, β_s 为批量大小。在第 t 个时间步的 LSTM 单元内部设计了遗忘门 $\mathbf{f}_t \in \mathbb{R}^{\beta_s \times \chi}$ 、输入门 $\mathbf{i}_t \in \mathbb{R}^{\beta_s \times \chi}$ 、输出门 $\mathbf{o}_t \in \mathbb{R}^{\beta_s \times \chi}$ 和候选记忆细胞更新模块 $\tilde{\mathbf{p}}_t \in \mathbb{R}^{\beta_s \times \chi}$, 这些机制帮助调节历史信息传递, 有效缓解梯度消失和爆炸问题, 确保模型迭代的稳定性。 $\boldsymbol{\psi}_{t-1} \in \mathbb{R}^{\beta_s \times \chi}$ 表示时间步 t 的隐藏状态, 则有

$$\mathbf{f}_t = \sigma(\mathbf{a}_t \mathbf{W}_f + \boldsymbol{\psi}_{t-1} \mathbf{U}_f + \mathbf{b}_f) \quad (17)$$

$$\mathbf{i}_t = \sigma(\mathbf{a}_t \mathbf{W}_i + \boldsymbol{\psi}_{t-1} \mathbf{U}_i + \mathbf{b}_i) \quad (18)$$

$$\mathbf{o}_t = \sigma(\mathbf{a}_t \mathbf{W}_o + \boldsymbol{\psi}_{t-1} \mathbf{U}_o + \mathbf{b}_o) \quad (19)$$

$$\tilde{\rho}_t = \tanh(\mathbf{a}_t \mathbf{W}_c + \boldsymbol{\psi}_{t-1} \mathbf{U}_c + \mathbf{b}_c) \quad (20)$$

$$\rho_t = \sigma(\mathbf{f}_t \odot \rho_{t-1} + \mathbf{i}_t \odot \tilde{\rho}_t) \quad (21)$$

$$\boldsymbol{\psi}_t = \mathbf{o}_t \odot \tanh(\boldsymbol{\rho}_t) \quad (22)$$

其中, σ 为修正线性单元 (rectified linear unit, ReLU) 激活函数, \odot 表示点乘运算。 $\mathbf{W}_k \in \mathbb{R}^{2QL \times \chi}$ 和 $\mathbf{U}_k \in \mathbb{R}^{\chi \times \chi}$ 分别为输入连接和循环连接对应的权重矩阵, 其中下标 k 可以是遗忘门 (f)、输入门 (i)、输出门 (o) 和候选记忆细胞更新模块 (c)。 $\mathbf{b}_k \in \mathbb{R}^{\beta_s \times \chi}$ 为偏置参数, $\tanh(\cdot)$ 表示双曲正切函数, $\rho_{t-1} \in \mathbb{R}^{\beta_s \times \chi}$ 和 $\rho_t \in \mathbb{R}^{\beta_s \times \chi}$ 分别为第 $t-1$ 个时间步和第 t 个时间步的细胞状态, $\boldsymbol{\psi}_t \in \mathbb{R}^{\beta_s \times \chi}$ 为 t 时刻的隐藏状态。

SA 机制通过计算序列内部元素之间的相关性权重, 动态聚合全局上下文, 能够有效捕捉序列的长时间依赖关系, 以增强序列表征^[28]。在双向 LSTM 架构中, 采用特征维度拼接 (concat) 策略融合前向与反向处理结果作为输出

$$\mathbf{z}_t = \text{concat}(\vec{\boldsymbol{\psi}}_t, \overleftarrow{\boldsymbol{\psi}}_t) \quad (23)$$

其中, $\mathbf{z}_t \in \mathbb{R}^{\beta_s \times 2\chi}$, $\vec{\boldsymbol{\psi}}_t$ 和 $\overleftarrow{\boldsymbol{\psi}}_t$ 分别是正向和反向传播的 LSTM 单元在第 t 个时间步的隐藏状态输出。SA 层的查询向量 $\mathbf{Q}_z \in \mathbb{R}^{\beta_s \times d_z}$ 、键向量 $\mathbf{K}_z \in \mathbb{R}^{\beta_s \times d_z}$ 和值向量 $\mathbf{V}_z \in \mathbb{R}^{\beta_s \times d_z}$ 如下所示

$$\mathbf{Q}_z = \mathbf{z}_t \mathbf{W}_Q \quad (24)$$

$$\mathbf{K}_z = \mathbf{z}_t \mathbf{W}_K \quad (25)$$

$$\mathbf{V}_z = \mathbf{z}_t \mathbf{W}_V \quad (26)$$

其中, $\mathbf{W}_Q \in \mathbb{R}^{2\chi \times d_z}$ 、 $\mathbf{W}_K \in \mathbb{R}^{2\chi \times d_z}$ 和 $\mathbf{W}_V \in \mathbb{R}^{2\chi \times d_z}$ 是可学习的权重矩阵。计算归一化的注意力权重 $\boldsymbol{\varepsilon} \in \mathbb{R}^{\beta_s \times \beta_s}$ 表示为

$$\boldsymbol{\varepsilon} = \text{Softmax}\left(\frac{\mathbf{Q}_z \mathbf{K}_z^T}{\sqrt{d_z}}\right) \quad (27)$$

其中, $\mathbf{Q}_z \mathbf{K}_z^T$ 用于衡量相似度, $\sqrt{d_z}$ 是缩放因子, 保证训练过程中梯度的稳定性, Softmax 函数确保所有权重在 0 到 1 之间且和为 1。最终, SA 层的输出 $\mathbf{Z}_t \in \mathbb{R}^{\beta_s \times d_z}$ 计算如下所示

$$\mathbf{Z}_t = \boldsymbol{\varepsilon} \mathbf{V}_z \quad (28)$$

SA 层的输出融合了双向 LSTM 提取的局部时序特征与自注意力构建的全局依赖关系, 两者互为补充, 使模型能够在不同时间尺度上同时感知基系

数序列的细节波动与整体趋势, 从而更适应 OTFS 系统在复杂快时变信道下的信道估计需求。

为降低噪声干扰, SA 层的最终输出由一个包含 $2QL$ 个神经元的浅层 NN 进行处理, 浅层 NN 旨在对经由 SA 加权的双向特征进行非线性组合与误差校准, 实现对初始基系数估计值的精确更新。在优化过程中, 模型通过最小化其估计值与理想信道对应的基系数之间的差异完成学习。本文采用自适应矩估计 (adaptive moment estimation, ADAM) 优化器^[29], 学习率设为 0.001, 配合 ReLU 激活函数, 以动态调整参数直至模型收敛。浅层 NN 的训练目标是确定能使损失函数 γ 最小化的最优权重 $\tilde{\boldsymbol{\varphi}}$ 为

$$\tilde{\boldsymbol{\varphi}} = \underset{\boldsymbol{\varphi}}{\text{argmin}} \gamma(\boldsymbol{\varphi}, \mathbf{Z}_t, \mathbf{c}_t) \quad (29)$$

其中, $\boldsymbol{\varphi} \in \mathbb{R}^{d_s \times 2QL}$ 是浅层 NN 的权重矩阵, $\mathbf{c}_t \in \mathbb{R}^{2QL \times 1}$ 是从训练样本中获得的理想信道条件下的基系数向量。损失函数的计算如下所示

$$\gamma(\boldsymbol{\varphi}, \mathbf{Z}_t, \mathbf{c}_t) = \frac{1}{2QL} \|\mathbf{c}_t - f(\mathbf{Z}_t; \boldsymbol{\varphi})\|_2^2 \quad (30)$$

其中, $\|\cdot\|_2$ 表示二范数, $f(\mathbf{Z}_t; \boldsymbol{\varphi})$ 是浅层神经网络的输出, 它表示 SA 层的输出 \mathbf{Z}_t 的函数。在训练阶段这个过程是迭代进行的, Bi-LSTM-SA 网络会根据每个训练样本对 $f(\mathbf{Z}_t; \boldsymbol{\varphi})$ 进行调整。最终, 基系数向量在时间步 t 的输出值 $\mathbf{r}_t \in \mathbb{R}^{\beta_s \times 2QL}$ 为

$$\mathbf{r}_t = f(\mathbf{Z}_t; \tilde{\boldsymbol{\varphi}}) = \mathbf{Z}_t \tilde{\boldsymbol{\varphi}} + \mathbf{b}_{\text{NN}} \quad (31)$$

其中, $\mathbf{b}_{\text{NN}} \in \mathbb{R}^{\beta_s \times 2QL}$ 为浅层 NN 的偏置参数。令 $\mathbf{R} = [\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_N] = [\hat{\mathbf{C}}_1, \hat{\mathbf{C}}_2, \dots, \hat{\mathbf{C}}_{\beta_s}] \in \mathbb{R}^{\beta_s \times 2QL \times N}$ 表示不同样本的基系数矩阵在不同时间步的估计结果, $\hat{\mathbf{C}}_\mu = [\text{Re}(\hat{\mathbf{C}}_\mu); \text{Im}(\hat{\mathbf{C}}_\mu)] \in \mathbb{R}^{2QL \times N}$ 为第 μ 个样本的基系数矩阵估计值, $\mu = 1, 2, \dots, \beta_s$ 。 $\text{Re}(\hat{\mathbf{C}}_\mu) \in \mathbb{R}^{QL \times N}$ 与

$\text{Im}(\hat{\mathbf{C}}_\mu) \in \mathbb{R}^{QL \times N}$ 分别表示第 μ 个样本的基系数矩阵的实部与虚部的估计值。将第 μ 个样本的基系数矩阵实部和虚部进行重组, 最终得到基系数矩阵估计值 $\hat{\mathbf{C}}_{\text{final}} = [\hat{\mathbf{c}}_0, \hat{\mathbf{c}}_1, \dots, \hat{\mathbf{c}}_{N-1}] \in \mathbb{C}^{QL \times N}$ 。使用本文所提 Bi-LSTM-SA 网络能够充分利用导频处的先验信息, 自适应地捕获基系数序列的局部与全局时序依赖, 在快时变信道下实现高精度的基系数估计。获得基系数矩阵估计值后, 结合基函数矩阵, 即可

得到最终的时域 CIR 估计值。

3 低复杂度两级均衡器

本节提出一种低复杂度两级均衡器，以消除延时扩展与多普勒扩展对 OTFS 系统的影响。第一级在 TF 域中采用传统单抽头均衡器消除多径效应并完成初步 ICI 抑制。在此基础上，第二级在 DD 域中使用提出的 LLR-IIC 算法进一步对残余干扰进行抑制。该算法使用数据位置的 TF 域信道向量估计值计算 LLR 初始值，接着结合第一级 TF 域均衡器输出的数据软符号信息计算初始数据软符号均值。随后利用 DD 域等效信道矩阵的自相关矩阵重构残余干扰，并在每次迭代中基于干扰消除后的结果更新 LLR 值。同时，引入阻尼因子控制 LLR 值更新，有效抑制迭代过程中的误差传播与振荡现象，以确保迭代过程的收敛稳定性。

3.1 第一级均衡器

第一级均衡器在 TF 域中采用单抽头均衡器，其时间复杂度为 $\mathcal{O}(MN_d)^{[23]}$ 。通过基于 BEM 的 Bi-LSTM-SA 网络可以得到数据处的基系数最终估计值 $\tilde{\mathbf{c}}_{n_d} \in \mathbb{C}^{Q_L \times 1}$ ，结合式(4)与式(12)即可得到数据位置的时域 CIR 矩阵估计值 $\hat{\mathbf{H}}_{n_d} \in \mathbb{C}^{M \times M}$ 。数据处的 TF 域信道矩阵估计值 $\hat{\mathbf{H}}_{n_d}^{\text{TF}} \in \mathbb{C}^{M \times M}$ 表示为

$$\hat{\mathbf{H}}_{n_d}^{\text{TF}} = \mathbf{F}_M \hat{\mathbf{H}}_{n_d} \mathbf{F}_M^H \quad (32)$$

令 $\tilde{\mathbf{h}}_{n_d}^{\text{TF}} = \text{diag}(\hat{\mathbf{H}}_{n_d}^{\text{TF}}) \in \mathbb{C}^{M \times 1}$ 为第 n_d 个数据符号时间的 TF 域信道向量估计值，则均衡系数 $\bar{\mathbf{h}}_{n_d}^{\text{TF}} \in \mathbb{C}^{M \times 1}$ 可表示为

$$\bar{\mathbf{h}}_{n_d}^{\text{TF}} = \frac{\text{conj}(\tilde{\mathbf{h}}_{n_d}^{\text{TF}})}{|\tilde{\mathbf{h}}_{n_d}^{\text{TF}}|^2 + \sigma_w^2} \quad (33)$$

其中， $\text{conj}(\cdot)$ 表示共轭操作。经过单抽头均衡器后的数据软符号向量 $\hat{\mathbf{y}}_{n_d}^{\text{TF}} \in \mathbb{C}^{M \times 1}$ 表示为

$$\hat{\mathbf{y}}_{n_d}^{\text{TF}} = \bar{\mathbf{h}}_{n_d}^{\text{TF}} \odot \tilde{\mathbf{y}}_{n_d} \quad (34)$$

令 $\hat{\mathbf{Y}}^{\text{TF}} = [\hat{\mathbf{y}}_0^{\text{TF}}, \hat{\mathbf{y}}_1^{\text{TF}}, \dots, \hat{\mathbf{y}}_{N_d-1}^{\text{TF}}] \in \mathbb{C}^{M \times N_d}$ 表示 TF 域均衡器输出的数据软符号信息。将 $\hat{\mathbf{Y}}^{\text{TF}}$ 代入式(6)得到 DD 域均衡器的数据软符号输入 $\hat{\mathbf{Y}}^{\text{DD}} \in \mathbb{C}^{M \times N_d}$ 。

3.2 第二级均衡器

基于 $\hat{\mathbf{H}}_{n_d}$ 、式(7)与式(8)推导得到的 DD 域等效信道矩阵估计值 $\hat{\mathbf{H}}^{\text{DD}} \in \mathbb{C}^{MN_d \times MN_d}$ ，可设计第二级

DD 域均衡器以进一步消除 DD 域中相邻符号引入的残余干扰。初始 LLR 值 $\mathbf{v}^{(0)} \in \mathbb{C}^{MN_d \times 1}$ 计算如下

$$\mathbf{v}^{(0)} = \sqrt{\frac{|\hat{\mathbf{h}}^{\text{TF}}|^2}{\sigma_w^2}} \quad (35)$$

其中， $\hat{\mathbf{h}}^{\text{TF}} = [(\tilde{\mathbf{h}}_0^{\text{TF}})^T, (\tilde{\mathbf{h}}_1^{\text{TF}})^T, \dots, (\tilde{\mathbf{h}}_{N_d-1}^{\text{TF}})^T]^T \in \mathbb{C}^{MN_d \times 1}$ 。则初始数据软符号均值 $\hat{\mathbf{y}}^{(0)} \in \mathbb{C}^{MN_d \times 1}$ 为

$$\hat{\mathbf{y}}^{(0)} = \tanh(\text{vec}(\hat{\mathbf{Y}}^{\text{DD}}) \odot \mathbf{v}^{(0)}) \quad (36)$$

设定迭代次数为 K ，在第 k 次迭代中利用上一次迭代得到的数据软符号均值 $\hat{\mathbf{y}}^{(k-1)} \in \mathbb{C}^{MN_d \times 1}$ 重构残余干扰， $k = 1, 2, \dots, K$ 。则第 k 次干扰消除操作后的输出为

$$\tilde{\mathbf{y}}^{(k)} = \tilde{\mathbf{y}} - (\mathbf{R}^{\text{DD}} \hat{\mathbf{y}}^{(k-1)} - \text{diag}(\mathbf{R}^{\text{DD}}) \odot \hat{\mathbf{y}}^{(k-1)}) \quad (37)$$

其中， $\mathbf{R}^{\text{DD}} = (\hat{\mathbf{H}}^{\text{DD}})^H \hat{\mathbf{H}}^{\text{DD}}$ 为 DD 域等效信道矩阵的自相关矩阵， $\tilde{\mathbf{y}} = \hat{\mathbf{H}}^{\text{DD}} \mathbf{y}^{\text{DD}}$ 为 DD 域匹配滤波输出。基于高斯假设更新 LLR 值为

$$\tilde{\mathbf{v}} = \frac{\tilde{\mathbf{y}}^k}{(\text{diag}(\mathbf{R}^{\text{DD}}) \sigma_w^2)} \quad (38)$$

其中除法为逐元素相除运算。为防止迭代振荡，引入阻尼因子 $\alpha^\dagger \in (0, 1]$ 对 LLR 值进行平滑更新， α^\dagger 决定当前计算值与历史值在更新中的权重分配。本文取 $\alpha^\dagger = 0.7$ ，使当前计算值主导更新，同时保留部分历史值以抑制估计偏差的逐次放大。则第 k 次迭代的 LLR 值更新为

$$\mathbf{v}^{(k)} = \alpha^\dagger \tilde{\mathbf{v}} - (1 - \alpha^\dagger) \mathbf{v}^{(k-1)} \quad (39)$$

更新后的数据软符号均值 $\hat{\mathbf{y}}^{(k)} \in \mathbb{C}^{MN_d \times 1}$ 为

$$\hat{\mathbf{y}}^{(k)} = \tanh(\mathbf{v}^{(k)}) \quad (40)$$

基于上述思路，在经过 K 次迭代后，得到 DD 域均衡器的输出 $\hat{\mathbf{y}}^{(K)}$ 。

综上所述，本文基于 Bi-LSTM-SA 模型估计得到的基系数，提出一种两级均衡器。第一级在 TF 域中采用单抽头均衡器获得粗估计，第二级在 DD 域中采用基于 LLR 的迭代干扰消除实现精均衡，通过阻尼因子保证迭代收敛。

4 仿真结果与分析

本文数据集由不同移动速度条件下的扩展车辆信道模型 (extended vehicular a model, EVA) 样本构成, 样本移动速度在 0km/h 到 990km/h 范围内以 10km/h 为步长均匀采样, 共获得 100 个速度点, 每个速度点生成 100 个信道样本, 总计 10000 个样本。随机选取 80% 作为训练数据集, 10% 作为验证数据集, 10% 作为测试数据集。批量大小 β_s 被设定为远小于训练数据集的规模, 以加快模型的泛化和训练速度。同时谨慎设置训练轮数 (epoch), 以保证模型能够收敛。模型训练时使用 ReLU 作为激活函数, 并结合 ADAM 优化器, 该组合在引入必要的非线性变换能力的同时, 保持了较高的计算效率。神经网络训练阶段参数定义如表 1 所示。

表 1 训练阶段参数定义表

参数	数值
双向 LSTM 层中隐藏层的大小	χ
浅层 NN 中隐藏层的大小	$2QL$
训练样本数	8000
验证样本数	1000
测试样本数	1000
批量大小 (β_s)	128
训练轮数 (epoch)	500
优化器	ADAM
学习率	0.001

因为 OTFS 系统可视为在 OFDM 系统的基础上增加了预处理与后处理模块, 因此可采用一致的仿真参数。系统仿真参数如表 2 所示。

为了验证本文信道估计与均衡算法的性能, 共设计了以下 11 种不同配置方案。

1) 本文方案 (OTFS-BEM-Bi-LSTM-SA): 在 OTFS 系统中, 首先采用 BEM-LMMSE 获得导频位置的基系数估计值, 接着使用 Bi-LSTM-SA 网络模型预测数据位置的基系数估计值, 最终采用所提出的两级均衡器。

2) 对比方案 1 (OTFS-CCE): 在 OTFS 系统中, 采用 Hashimoto 等^[15]提出的 CCE 算法获取 DD 域信道参数, 最终采用 DD 域 MMSE 均衡器。

3) 对比方案 2 (OTFS-TCE): 在 OTFS 系统中, 采用 Raviteja 等^[16]提出的 TCE 算法获取 DD 域

表 2 系统仿真参数

参数	数值
载波频率 (f_c)	5.9GHz
子载波间隔 (Δf)	156.25kHz
系统带宽 ($B = M\Delta f$)	10MHz
符号持续时间 (T_s)	8 μ s
循环前缀长度 (M_{cp})	1.6 μ s
子载波数 (M)	64
前导序列符号数	1
数据字段符号数	14
信道模型	EVA ^[17,30]
多径抽头延迟 (ns)	[0,30,150,310,370,710,1090,1730,2510]
相对功率时延 (dB)	[0,-1.5,-1.4,-3.6,-0.6,-9.1,-7.0,-12.0,-16.9]

信道参数, 最终采用 DD 域 MMSE 均衡器。

4) 对比方案 3 (OFDM-BEM): 在 OFDM 系统中, 采用 LIAO 等^[17]提出的 BEM-LMMSE 结合拉格朗日插值算法获得基系数矩阵估计值, 最终采用 TF 域 MMSE 均衡器。

5) 对比方案 4 (OTFS-BEM): 在 OTFS 系统中, 采用 BEM-LMMSE 结合拉格朗日插值算法获得基系数参数, 最终采用 DD 域 MMSE 均衡器。

6) 对比方案 5 (OTFS-iROMP): 在 OTFS 系统中, 采用 LIAO 等^[18]提出的 BEM-iROMP 算法获得基系数矩阵估计值, 最终采用 DD 域 MMSE 均衡器。

7) 对比方案 6 (OFDM-BEM-Bi-LSTM-SA): 在 OFDM 系统中, 首先采用 BEM-LMMSE 获得导频位置的基系数估计值, 接着使用 Bi-LSTM-SA 网络模型预测数据位置的基系数估计值, 最终采用单抽头均衡器。

8) 对比方案 7 (OTFS with perfect CSI): 在 OTFS 系统中, 将理想的 CSI 转换为 DD 域信道矩阵, 最终采用 TF 域 MMSE 均衡与 DD 域 MMSE 均衡的两级均衡器。

9) 对比方案 8 (OTFS single-tap): 在 OTFS 系统中, 首先采用 BEM-LMMSE 获得导频位置的基系数估计值, 接着使用 Bi-LSTM-SA 网络模型预测数据位置的基系数估计值, 最终采用单抽头均衡器。

10) 对比方案 9 (OTFS-FDE): 在 OTFS 系统中, 首先采用 BEM-LMMSE 获得导频位置的基系数估计值, 接着使用 Bi-LSTM-SA 网络模型预测数据位置的基系数估计值, 最终采用 TF 域 MMSE 均衡器。

11) 对比方案 10 (OTFS-DDE): 在 OTFS 系统中, 首先采用 BEM-LMMSE 获得导频位置的基系数估计值, 接着使用 Bi-LSTM-SA 网络模型预测数据位置的基系数估计值, 最终采用 DD 域 MMSE 均衡器。

4.1 NMSE 与 BER 性能分析

图 3-图 4 和图 5 比较了不同信道估计算法在不同移动速度条件下的 NMSE 性能。当速度为 100km/h, 不同信道估计算法的 NMSE 性能随着信噪比 (signal-to-noise ratio, SNR) 增大呈现快速下降趋势, 这是因为 CIR 在一个符号时间内变化缓慢, 近似满足时不变假设。其中, 因在 OTFS-BEM、OFDM-BEM^[17]和 OTFS-iROMP^[18]中考虑了噪声的影响, 因此性能优于 OTFS-CCE^[15]和 OTFS-TCE^[16], 在高 SNR 条件下优势显著, 然而代价是所需的计算复杂度更高, 算法结构更复杂。OTFS-BEM-Bi-LSTM-SA 相较于 OTFS-iROMP 在低 SNR 情况下有峰值约 2.8dB 的 NMSE 增益, 在高 SNR 情况下 NMSE 增益达到 1dB 以上。当速度为 500km/h, 由于 CIR 在一个符号时间内快速变化, OTFS-CCE 和 OTFS-TCE 的 NMSE 性能下降速率减缓, 并在高 SNR 区域趋于饱和, 表明这两种算法难以有效跟踪快时变信道的动态特性。而 OTFS-BEM-Bi-LSTM-SA、OTFS-iROMP 和 OTFS-BEM 中因为采用了 BEM 对快时变信道进行建模, 准确捕捉了信道的快速变化, 故 NMSE 性能仍能随 SNR 增大保持下降。当速度为 1000km/h, OTFS-BEM-Bi-LSTM-SA 在所有 SNR 条件下仍保持最优 NMSE 性能。由数据集构造可知, 1000 km/h 不在训练范围内, 这表明双向 LSTM 捕获的局部时序特征经 SA 机制全局聚合后, 可有效表征基系数的动态变化规律, 使模型具备对训练集场景外的泛化能力。在不同移动速度场景下, 相同算法在 OTFS 系统中比在 OFDM 系统中均有明显的 NMSE 增益, 因为 OTFS 在 DD 域进行信号处理, 通过 ISFFT 变换将信号映射至 TF 域网格中, 从而在快时变信道下能够有效收集分散于不同位置的信号能量, 提升信道估计的

准确性。




图 3 移动速度为 100km/h 不同信道估计算法的 NMSE 性能




图 4 移动速度为 500km/h 不同信道估计算法的 NMSE 性能




图 5 移动速度为 1000km/h 不同信道估计算法的 NMSE 性能

图 6-图 7 和图 8 比较了不同方案在不同移动速度条件下的 BER 性能。当速度为 100km/h, 不同方

案的 BER 性能随着 SNR 增大快速下降。其中, OTFS-iROMP^[18]通过跟踪基函数矩阵中与基系数相关最大的向量来估计基系数,受噪声影响程度弱于 OTFS-BEM,因此 BER 性能更优。当速度为 500km/h, OTFS-CCE^[15]的性能显著下降,因为该算法基于信道准静态假设,难以有效跟踪 CSI 的快速变化。OTFS-TCE^[16]的性能较差,则是因为在高阶调制方式下,该算法在高 SNR 区域会出现误码平层现象。当速度为 1000km/h,随着 SNR 增大, OTFS-CCE、OTFS-TCE、OFDM-BEM^[17]、OTFS-BEM 和 OTFS-iROMP 基本达到了下限。在不同移动速度条件下, OTFS-BEM-Bi-LSTM-SA 的 BER 性能最接近对比方案 7 这一理想 CSI 基准,这说明所提的信道估计算法性能良好,并且通过两级均衡器之后消除了干扰的影响,因此 BER 性能接近完美信道估计与 MMSE 均衡结合的方案。同时, OTFS-BEM-Bi-LSTM-SA 的 BER 性能优于 OFDM-BEM-Bi-LSTM-SA,因为 DD 域信道矩阵具有缓变、稀疏的特性,使用 DD 域均衡器能够进一步消除 ICI 的影响,提升解调信号精度。




图6 移动速度为100km/h不同方案的BER性能

图9和图10分别对比了当 SNR=7dB 和 SNR=23dB 条件下不同速度不同信道估计算法的 NMSE 性能。其中,测试的所有速度点均未在本文所提的基于 BEM 的 Bi-LSTM-SA 网络模型训练过程中使用。从仿真结果上看,不同算法的 NMSE 性能都随着速度增加而下降。但本文所提出的 OTFS-BEM-Bi-LSTM-SA 表现出远低于其他算法的优异性能,特别是在高速移动场景中。并且对快时变信道具有更强的鲁棒性,证明了所提神经网络模型具有强泛




图7 移动速度为500km/h不同方案的BER性能




图8 移动速度为1000km/h不同方案的BER性能

化能力。图11和图12分别对比了当 SNR=7dB 和 SNR=23dB 条件下不同速度不同方案的 BER 性能,进一步验证了所提模型的泛化能力。在所有测试速度点上,本文所提 OTFS-BEM-Bi-LSTM-SA 的 BER 仅高于理想 CSI 基准,且其 BER 随速度上升的增幅最小,与理想 CSI 的差距始终保持最小,表明所提模型能够有效泛化至训练集中未出现过的速度场景,并在高速移动环境下保持良好的鲁棒性。

图13-图14和图15比较了不同均衡方案在不同速度下的 BER 性能。采用本文所提两级均衡器的方案始终保持最优 BER 性能,因其充分利用了 TF 域与 DD 域信道特性。第一级在 TF 域中利用信道矩阵的近似对角化特性,以低复杂度的线性处理实现了消除多径效应和 ICI 初步抑制;第二级利用 DD 域信道矩阵稀疏、缓变的特性,通过基于 LLR-IIC 算法消除残余干扰。相较于单独的 TF 域或 DD 域均衡器,该方案既避免了 TF 域均衡在高速场景

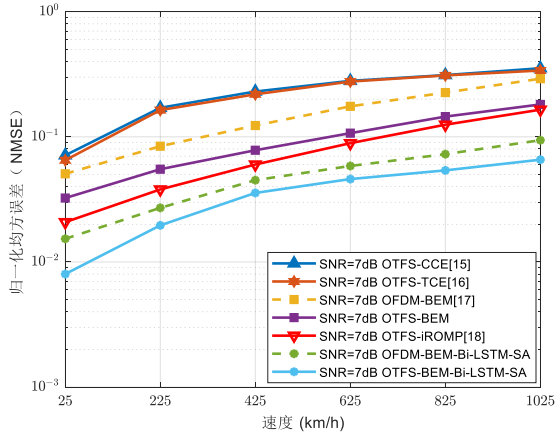


图9 SNR=7dB不同速度不同信道估计算法的NMSE性能




图12 SNR=23dB不同速度不同方案的BER性能

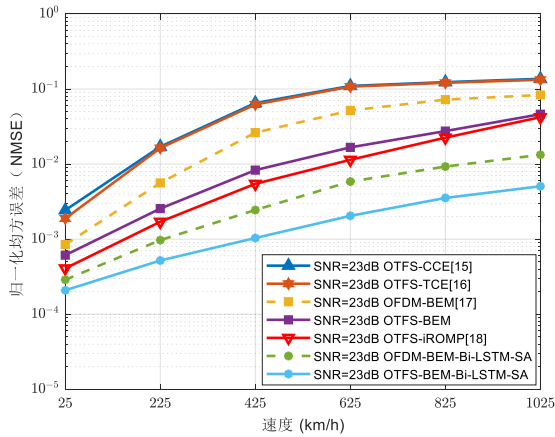


图10 SNR=23dB不同速度不同信道估计算法的NMSE性能

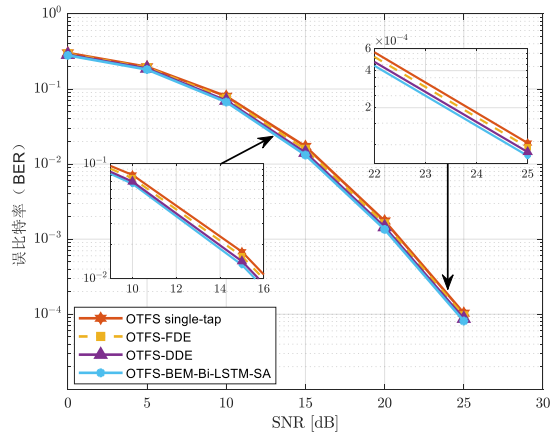


图13 移动速度为100km/h不同均衡方案的BER性能




图11 SNR=7dB不同速度不同方案的BER性能




图14 移动速度为500km/h不同均衡方案的BER性能

下难以有效抑制ICI的不足，也克服了DD域高维矩阵求逆运算复杂度高的问题。

4.2 收敛性分析

图 16 展示了 LLR-IIC 算法在 SNR = 15dB、

$\alpha^\dagger = 0.7$ 、不同移动速度条件下残量范数随着迭代过程的变化。本文将残量范数降至 10^{-5} 以下视为算法达到有效收敛，当残量范数低于该门限后，其后续变化对系统性能的影响可忽略。可以看出在不同




图 15 移动速度为1000km/h不同均衡方案的BER性能

移动速度条件下, 算法均在 10 次迭代内降至该门限以下, 验证了其快速收敛特性与有效性。




图 16 LLR-IIC算法的迭代收敛过程

4.3 频谱效率分析

除对比方案 1 和 2 之外, 其余方案采用图 1 中所提的帧结构, 传输帧的数据密度为

$$\eta_f = \frac{MN_d}{MN} = 80\% \quad (41)$$

其中, $N_d = 12$, $N = N_d + N_p + 1 = 15$ 。

OTFS-TCE^[16]在 DD 域中插入单个导频, 导频周围设有保护带, 不考虑添加已知的前导序列。其传输帧的数据密度为

$$\eta_{TCE} = \frac{M_s(N-1)}{M(N-1)} = 84.375\% \quad (42)$$

其中, $M_s = 54$ 表示数据符号所占子载波数。OTFS-CCE^[15]方案在两帧中分别发送导频与数据符号, 因此该传输帧的数据密度为

$$\eta_{CCE} = 50\% \quad (43)$$

本文通过比较频谱效率来分析实际有效数据传输量, 频谱效率的计算公式为

$$\delta_{\text{index}} = \eta_{\text{index}}(1 - \text{BER}_{\text{index}}) \quad (44)$$

其中, 索引(index)用于区分不同的信道估计算法。移动速度为 500km/h 不同方案的频谱效率对比如图 17 所示。OTFS-TCE^[16]在频谱效率方面性能最优, 这主要得益于其独特的导频结构设计, 有效降低了导频开销, 从而实现更高的频谱效率。相比之下, OTFS-BEM-Bi-LSTM-SA 的频谱效率虽略低于 OTFS-TCE^[16], 但其 BER 性能显著更优, 在一定程度上弥补了频谱效率的损失。移动速度为 500km/h 场景下不同帧长大小下不同方案的频谱效率对比如图 18 所示, 其中 SNR = 20dB, 仿真中仅改变传输符号数量 N 。从结果可以看出, 随着帧长大小的增加, OTFS-BEM-Bi-LSTM-SA 的频谱效率保持稳定。这是由于所提方案充分利用前导序列作为导频信号, 节约了额外的导频开销, 从而提高了传输资源的利用效率。




图 17 移动速度为500km/h频谱效率对比

4.4 算法复杂度分析

为了分析算法复杂度, 我们对不同信道估计算法和均衡器的复杂度分别进行了量化。文献[15]中的 CCE 算法使用快速傅里叶变换执行信道估计所需的相关运算, 该算法的计算复杂度为

$$\omega_{CCE} = \mathcal{O}(\lambda g M(N-1) \log(N-1)) \quad (45)$$

其中 g 为分数多普勒的分辨率, λ 为车载信道多径信道数, 对于 EVA 信道模型, $\lambda = 9$ ^[30]。文献[16]

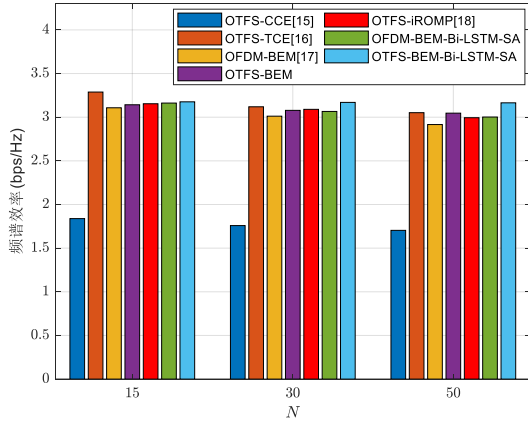


图 18 不同帧长大小下的频谱效率对比

中的 TCE 算法需要将所有符号与最大多普勒采样值按照给定阈值进行比较，其计算复杂度为

$$\varpi_{\text{TCE}} = \mathcal{O}(MN) \quad (46)$$

文献[18]中的 BEM-iROMP 算法利用反馈结果迭代以达到最优系数估计，其计算复杂度为

$$\varpi_{\text{BEM-iROMP}} = \mathcal{O}(4\bar{K}\bar{D}^2L^2MN\lg\bar{K} + \bar{K}\bar{D}LMN) \quad (47)$$

其中， \bar{D} 为 ICI 的单侧带宽， $\bar{K} = 8$ 为步长， \bar{K} 为迭代次数。

本文所提出的 Bi-LSTM-SA 模型采用 BEM-LMMSE 的估计结果作为初始估计值，BEM-LMMSE 部分的计算复杂度为

$$\varpi_{\text{BEM-LMMSE}} = \mathcal{O}(2N^2QL + 18NQ^2L^2 + 3Q^3L^3) \quad (48)$$

在得到初始估计值之后是 Bi-LSTM 层，其计算复杂度取决于输入大小及其隐藏层的大小 $\chi = 0.5M$ ，则 Bi-LSTM 层的计算复杂度为

$$\begin{aligned} \varpi_{\text{Bi-LSTM}} &= \mathcal{O}(2(4M^2 + 4\chi M + 3\chi)) \\ &= \mathcal{O}(6M^2 + 3M) \end{aligned} \quad (49)$$

SA 层计算复杂度主要由查询、键、值向量的投影及注意力权重的计算决定，其计算复杂度为

$$\varpi_{\text{SA}} = \mathcal{O}(4\chi^2 + 4\chi) = \mathcal{O}(M^2 + 2M) \quad (50)$$

浅层 NN 中有一个包含 $2QL$ 个神经元的隐藏层，输入层和输出层的神经元数量均为 $2M$ ，则其计算复杂度为

$$\varpi_{\text{NN}} = \mathcal{O}(2 \times 2QL \times 2M) = \mathcal{O}(8QLM) \quad (51)$$

综上所述，所提信道估计算法的计算复杂度为

$$\varpi_{\text{BEM-Bi-LSTM-SA}} = \varpi_{\text{BEM-LMMSE}} + \varpi_{\text{Bi-LSTM}} + \varpi_{\text{SA}} + \varpi_{\text{NN}} \quad (52)$$

本文所提信道估计算法与现有信道估计算法的时间复杂度及每秒浮点运算次数（floating point operations per second, FLOPS）整理如表 3 所示。

表 3 不同信道估计算法时间复杂度与 FLOPS 对比

信道估计算法	时间复杂度	FLOPS
CCE ^[15]	$\mathcal{O}(M(N-1)\log(N-1))$	10^8
TCE ^[16]	$\mathcal{O}(MN)$	10^3
BEM-LMMSE ^[17]	$\mathcal{O}(Q^3L^3)$	10^5
BEM-iROMP ^[18]	$\mathcal{O}(4\bar{K}\bar{D}^2L^2MN\lg\bar{K})$	10^6
BEM-Bi-LSTM-SA	$\mathcal{O}(Q^3L^3 + M^2)$	$10^6 \sim 10^7$

从表 3 中可以看出，TCE 算法的时间复杂度与 FLOPS 均为最低，CCE 算法因涉及快速傅里叶变换而两项指标均为最高。由于 $Q \ll M$ ， L 与 N 相差不大，故 BEM-LMMSE 与 BEM-iROMP 的复杂度远低于 CCE 算法。BEM-iROMP 的 FLOPS 高于 BEM-LMMSE，因为其迭代过程引入了额外计算。本文所提 BEM-Bi-LSTM-SA 算法的 FLOPS 处于 $10^6 \sim 10^7$ 之间，高于两类 BEM 对比算法，但以有限的神经网络计算开销换取了更优的性能，综合权衡是值得的。所提 Bi-LSTM-SA 网络模型的参数量约为 153984，占用内存约为 1.77MB。对比算法均为信号处理算法，无网络参数，故不适用此指标。

本文所提低复杂度两级均衡器与现有均衡器的时间复杂度整理如表 4 所示。

表 4 不同均衡器的时间复杂度对比

均衡器	时间复杂度
TF 域 MMSE 均衡器 ^[16]	$\mathcal{O}(M^3N_d^3)$
DD 域 MMSE 均衡器 ^[17]	$\mathcal{O}(M^3N_d^3)$
单抽头均衡器 ^[23]	$\mathcal{O}(MN_d)$
低复杂度两级均衡器	$\mathcal{O}(KM^2N_d^2)$

从表 4 中可以看出，单抽头均衡器复杂度最低，但因忽略了子载波间相关性，在高速场景下性能受限。相比之下 MMSE 均衡器在高速场景中性能更优，然而高维矩阵求逆导致其复杂度最高。本文所提低复杂度两级均衡器复杂度介于两者之间，该算法通过级联处理避免了高维矩阵求逆，在有效抑制干扰的同时大幅降低了计算开销，实现了性能

与复杂度之间的良好折衷。

5 结束语

本文针对 6G 高速移动场景中的快时变信道估计难题,提出一种融合 BEM 和双向 LSTM 的 OTFS 信道估计算法和低复杂度两级均衡器。所提算法将 DD 域信道估计问题转换为基于 BEM 的低维基系数估计。接着提出 Bi-LSTM-SA 网络模型,实现对基系数的高精度估计与非线性补偿,进而重构 CSI。在此基础上,提出了两级均衡器,兼顾单抽头均衡器低复杂度的优势与 DD 域均衡的强干扰抑制能力,有效避免了高速场景下 TF 域均衡性能差以及 DD 域均衡因高维矩阵求逆带来的复杂度瓶颈。结果表明,所提算法在不同移动速度条件下均能有效解调信号,在频谱效率及复杂度方面表现优异,证明了所提信道估计与均衡算法的有效性与鲁棒性。

参考文献:

- [1] 李华,郝诗雅,巩彩红,等.面向6G的新型多址与波形技术[J].电信科学,2022,38(10):36-45.
Li H, Hao S Y, Gong C H, et al. New multiple access and waveform technology for 6G[J]. Telecommunications Science, 2022, 38(10): 36-45.
- [2] Nguyen D C, Ding M, Pathirana P N, et al. 6G Internet of things: a comprehensive survey[J]. IEEE Internet of Things Journal, 2021, 9(1): 359-383.
- [3] Huang Z, Li G, Wu R, et al. Channel estimation for OTFS systems based on basis expansion model with UPF[J]. IEEE Wireless Communications Letters, 2025, 14(11): 3635-3639.
- [4] Wu Y, Han C, Chen Z. DFT-spread orthogonal time frequency space system with superimposed pilots for terahertz integrated sensing and communication[J]. IEEE Transactions on Wireless Communications, 2023, 22(11): 7361-7376.
- [5] Wang S, Guo J, Wang X, et al. Pilot design and optimization for OTFS modulation[J]. IEEE Wireless Communications Letters, 2021, 10(8): 1742-1746.
- [6] Shi J, Hu J, Yue Y, et al. Outage probability for OTFS based downlink LEO satellite communication[J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 3355-3360.
- [7] 邢旺,唐晓刚,周一青,等.面向OTFS的时延-多普勒域信道估计方法综述[J].通信学报,2022,43(12):188-201.
Xing W, Tang X G, Zhou Y Q, et al. Survey of channel estimation method in delay-Doppler domain for OTFS[J]. Journal on Communications, 2022, 43(12): 188-201.
- [8] 马彬,杨祖敏,谢显中.认知车联网中评估频谱稳定性的动态频谱接入算法[J].电子与信息学报,2025,47(5):1474-1485.
Ma B, Yang Z M, Xie X Z. Dynamic spectrum access algorithm for evaluating spectrum stability in cognitive vehicular networks[J]. Journal of Electronics & Information Technology, 2025, 47(5): 1474-1485.
- [9] Liu X, Guan Y L, Xie Y, et al. BEM-ANN receiver with linear complexity for severe doubly-selective fading channels[J]. IEEE Transactions on Vehicular Technology, 2024, 73(12): 19005-19018.
- [10] Benzine W, Bemani A, Ksairi N, et al. Models, methods, and waveforms for estimation and prediction of sparse time-varying channels[J]. IEEE Transactions on Wireless Communications, 2025, 25: 9623-9638.
- [11] Doosti-Aref A, Masouros C, Zhu X, et al. Performance analysis of OTSM under hardware impairments and imperfect CSI[J]. IEEE Transactions on Vehicular Technology, 2024, 73(9): 12991-13006.
- [12] Chen Y, Zhao L, Jiang Y, et al. OTFS waveform based on 3-d signal constellation for time-variant channels[J]. IEEE Communications Letters, 2023, 27(8): 1999-2003.
- [13] Yuan W, Wei Z, Li S, et al. Orthogonal time frequency space modulation-part III: ISAC and potential applications[J]. IEEE Communications Letters, 2022, 27(1): 14-18.
- [14] Sheng H T, Wu W R. Time-frequency domain channel estimation for OTFS systems[J]. IEEE Transactions on Wireless Communications, 2023, 23(2): 937-948.
- [15] Hashimoto N, Osawa N, Yamazaki K, et al. Channel estimation and equalization for CP-OFDM-based OTFS in fractional Doppler channels [C]//2021 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2021: 1-7.
- [16] Raviteja P, Phan K T, Hong Y. Embedded pilot-aided channel estimation for OTFS in delay-Doppler channels[J]. IEEE transactions on vehicular technology, 2019, 68(5): 4906-4917.
- [17] 廖勇,陈颖.基于基扩展模型的UKF-RTSS高可靠鲁棒V2V信道估计[J].电子与信息学报,2022,44(5):1792-1799.
Liao Y, Chen Y. Ultra-reliable and robust channel estimation using basis expansion model-based UKF-RTSS scheme for V2V systems[J]. Journal of Electronics & Information Technology, 2022, 44(5): 1792-1799.
- [18] 廖勇,蔡志镨.基于基扩展模型的改进正则化正交匹配追踪V2X快时变SC-FDMA信道估计[J].通信学报,2021,42(4):177-184.
Liao Y, Cai Z R. Basis expansion model-based improved regularized orthogonal matching pursuit channel estimation for V2X fast time-varying SC-FDMA[J]. Journal on Communications, 2021, 42(4): 177-184.
- [19] Ye H, Li G Y, Juang B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2017, 7(1): 114-117.
- [20] 杨骞,苏宏升,陶旺林,等.城轨车-地场景下基于CGAN-LSTM网络的OTFS-ISAC系统信道估计[J].通信学报,2025,46(2):59-71.
Yang Q, Su H S, Tao W L, et al. OTFS-ISAC system channel estimation based on GAN-LSTM network in urban rail train-infrastructure scenario[J]. Journal on Communications, 2025, 46(2): 59-71.
- [21] Dos Reis A F, Chang B S, Medjahdi Y, et al. LSTM-based time-frequency domain channel estimation for OTFS modulation[J]. IEEE Transactions on Vehicular Technology, 2024, 73(10): 15049-15060.
- [22] Jiang W, Schotten H D. Deep learning for fading channel prediction[J]. IEEE Open Journal of the Communications Society, 2020, 1: 320-332.
- [23] Junior R P, da Rocha C A F, Chang B S, et al. A two-dimensional FFT precoded filter bank scheme[J]. IEEE Transactions on Wireless Communications, 2023, 22(11): 8366-8377.
- [24] Li L, Wei H, Huang Y, et al. A simple two-stage equalizer with simplified orthogonal time frequency space modulation over rapidly time-

varying channels[J]. arXiv preprint arXiv: 1709.02505, 2017.

- [25] Thaj T, Viterbo E. Low complexity iterative rake decision feedback equalizer for zero-padded OTFS systems[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15606-15622.
- [26] Zhang X, Chen F, Feng J, et al. BEM based channel estimation via sparse bayesian learning for OTFS over fast time-varying channel[C]// 2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring). Piscataway: IEEE Press, 2024: 1-5.
- [27] Pan G L, Li J, Li M L. Multi-channel multi-step spectrum prediction using transformer and stacked Bi-LSTM[J]. China Communications, 2025, 22(5): 1-13.
- [28] François D, Saillot M, Klein J, et al. Drop-in efficient self-attention approximation method[J]. Machine Learning, 2025, 114(6): 139.
- [29] Goodfellow I, Bengio Y, Courville A, et al. Deep learning[M]. Cambridge: MIT press, 2016.
- [30] 王健, 王吉哲, 沈正华, 等. 面向车联网通信的 OTFS 信号检测算法综述[J]. 电讯技术, 2024, 64(2): 316-324.
Wang J, Wang J Z, Shen Z H, et al. A Survey on OTFS signal detection algorithms for V2X communications[J]. Telecommunication Engineering, 2024, 64(2): 316-324.



黄子懿 (1996-), 男, 四川岳池人, 重庆邮电大学博士生, 主要研究方向为高速移动通信、信道估计算法、5G/6G 通信等。



李国权 (1980-), 男, 河南方城人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为无线通信、5G/6G 通信、信号处理等。



林金朝 (1966-), 男, 四川蓬溪人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为无线通信、信号处理等。



庞宇 (1978-), 男, 浙江宁波人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为无线通信、5G/6G 通信、应急通信等。



武瑞恒 (1959-), 男, 内蒙古呼和浩特人, 博士, 伦敦布鲁内尔大学教授、博士生导师, 主要研究方向为信号处理、目标探测、计算机视觉等。