

# 城轨车-地场景下基于 CGAN-LSTM 网络的 OTFS-ISAC 系统信道估计

杨骞<sup>1,2</sup>, 苏宏升<sup>1</sup>, 陶旺林<sup>1,3</sup>, 刘大为<sup>2</sup>

(1. 兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070; 2. 兰州工业学院电气工程学院, 甘肃 兰州 730300;  
3. 中国移动通信集团甘肃有限公司, 甘肃 兰州 730070)

**摘要:** 为解决商用 B5G/6G 城轨车-地场景下通信感知一体化 (ISAC) 信号传输信道估计问题, 提出了一种基于深度学习的信道估计方法。建立基于正交时频空 (OTFS) 调制的 ISAC 信号传输系统模型, 引入 OTFS 导频辅助, 设计条件生成对抗网络和长短期记忆网络结合的 CGAN-LSTM, 将混沌博弈优化算法与经典 Adam 优化器结合, 对网络参数进行优化, 利用优化网络完成信道估计。仿真结果表明, 所提方法在归一化均方误差和误码率方面, 优于传统的信道估计方法, 为 ISAC 信号检测和恢复提供必要数据基础。

**关键词:** 通信感知一体化; 正交时频空; 条件生成对抗网络; 长短期记忆; 混沌博弈优化

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2025032

## OTFS-ISAC system channel estimation based on GAN-LSTM network in urban rail train-infrastructure scenario

YANG Qian<sup>1,2</sup>, SU Hongsheng<sup>1</sup>, TAO Wanglin<sup>1,3</sup>, LIU Dawei<sup>2</sup>

1. School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China  
2. School of Electrical Engineering, Lanzhou Institute of Technology, Lanzhou 730300, China  
3. China Mobile Communications Group Gansu Company Limited, Lanzhou 730070, China

**Abstract:** In order to solve the problem of integrated sensing and communication (ISAC) signal transmission channel estimation in commercial B5G/6G urban rail train-infrastructure scenario, a channel estimation method based on deep learning was proposed. An ISAC signal transmission system model based on orthogonal time frequency space (OTFS) modulation was established, the OTFS pilot was introduced, with OTFS pilot introduced to aid, CGAN-LSTM combining conditional generative adversarial network (CGAN) and long short-term memory (LSTM) network was designed. Chaos game optimization (CGO) algorithm was combined with classical Adam optimizer to optimize the network parameters, and the optimized network was used to complete the channel estimation. Simulation results show that the proposed method is superior to traditional channel estimation methods in normalized mean square error and bit error rate, and provides necessary data basis for ISAC signal detection and recovery.

**Keywords:** ISAC, OTFS, CGAN, LSTM, CGO

收稿日期: 2024-12-31; 修回日期: 2025-02-13

通信作者: 苏宏升, 2641433027@qq.com

基金项目: 甘肃省高校教师创新基金资助项目 (No.2025B-239); 兰州工业学院青年科技创新基金资助项目 (No.2024KJ-16); 甘肃省高校青年博士支持项目 (No.2023QB-049)

**Foundation Items:** The University Teachers' Innovation Fund Project of Gansu Province (No.2025B-239), The Youth Science and Technology Innovation Project of Lanzhou Institute of Technology (No.2024KJ-16), The University Young Doctor Support Project of Gansu Province (No.2023QB-049)

## 0 引言

下一代无线系统 (B5G/6G) 有望在高移动性环境中促进连续和可靠的通信, 城市轨道交通是 B5G/6G 技术应用的重要场景之一, 其中包括列车对基础设施 (T2I, train to infrastructure) 的信息交互等场景<sup>[1]</sup>。为了向列车运行控制提供实时可靠的列车信息, 需要高精度雷达传感和高效稳定的实时无线通信来响应城市轨道交通动态变化的信息交互环境。随着无线通信设备数量的陡增, 频谱资源稀缺的问题被放大, 一个长期可研的解决方案被提出, 即通信感知一体化 (ISAC, integrated sensing and communication), 该方案利用了雷达传感和无线通信在硬件系统结构、信道特征和信号处理技术上的相似性<sup>[2]</sup>。ISAC 在有效节省频谱资源和降低硬件成本的基础上, 通信和传感互相辅助, 使 T2I 的信息交互更丰富<sup>[3]</sup>。

ISAC 对于传感和通信的处理分为 2 个方向: 分开资源分配和统一信号设计。前者将感知信号和通信信号在基础设施对移动设备的下行链路中, 形成 2 个正交信号, 分开传输, 这样的处理方式导致发射机部分更高的硬件成本支出和高能耗需求<sup>[4]</sup>。近年来, 发射端的统一波形设计, 接收端参数估计和信道估计的互相辅助, 成为商用 ISAC 物理层技术的研究方向。文献[5]在共享频段中, 设计了适当的 ISAC 信号波形, 在满足状态感知失真约束条件的前提下, 获得显著的传输增益。为应对 ISAC 信号处理的需求, 文献[6]从数学基础理论角度分析了正交时频空 (OTFS, orthogonal time frequency space) 调制信号具备的通信和主动感知性能, 证明其作为 ISAC 基础信号的可靠性, OTFS 作为一种二维信号调制方法, 适合高迁移率环境<sup>[7-8]</sup>, 其时延-多普勒 (DD, delay-doppler) 域信道也表现出较好的稳定性和稀疏性<sup>[9]</sup>。针对 OTFS 信道估计, 文献[10]设计了一种适用于分数 DD 域场景的低复杂度迭代信道估计方法, 分别估计每个信道路径的时延、多普勒频移和信道增益, 这种估计方法不需要矩阵反演, 其复杂度更低。文献[11]开发了一种基于叠加导频和数据传输方案的数据辅助信道估计方法, 在提升频谱效率的同时, 利用接收端数据符号检测, 反向优化信道估计结果, 最终得到精确估计。但文献[10-11]只是针对通信信号传输的信道估计, 未将通信感知信号传输过程结合。文献[12]基

于 3GPP 信道模型将 6G ISAC 信道进行建模细分, 对传感信道和无线通信信道进行多环境类型的对应统一建模仿真, 为 ISAC 的信道估计提供理论模型。文献[13]基于 OTFS-ISAC 信号系统模型预测信道参数, 为 T2I 复杂环境中的感知参数估计和信道估计提供了相近模型作为参考。近年来深度学习被广泛应用于信道估计的过程中, 文献[14]构建了基于可重构智能反射面的辅助功能的基站对用户上下行链路通信与感知信道, 并将卷积神经网络 (CNN, convolutional neural network) 植入基站的信道估计中, 相对于传统的最小二乘估计, 有更高的估计精度。文献[15]提出了一种生成对抗网络 (GAN, generative adversarial network), 不需要复杂的理论分析或数据处理的自主无线信道建模问题, 仅通过简单的实验介绍了利用 GAN 进行信道建模的可行性, 缺乏深入研究。文献[16]中神经网络由于连续层的信息丢失, 很难生成更真实的信道矩阵。信道测量数据的获取对信道建模非常重要, 其测量过程耗时力, 因此通常缺乏足够的测量数据集。此外, 由于环境的变化或限制、主观判断失误和测量仪器的故障, 都会造成信道数据丢失或测量误差的结果。利用人工智能生成足够的数据集完成无线信道建模, 并完成信道估计, 可以最大程度消除测量数据误差。基于上述信道估计研究, 针对 ISAC 系统的特点, 本文提出了一种基于深度学习网络的信道估计方法, 具体工作如下。

1) 建立城轨 T2I 场景基于 OTFS 的 ISAC 系统模型, 即 OTFS-ISAC 系统。分别建立 OTFS-ISAC 系统的通信信号下行链路和传感回波上行链路信道响应和接收信号的数学模型, 引入携带信道信息的 OTFS 导频符号, 将复杂估计问题简化, 最终将 T2I 信道估计问题转化为图像处理问题。

2) 提出一种基于深度学习的信道估计方法, 利用 GAN 和长短期记忆 (LSTM, long short-term memory) 网络结合的深度学习网络克服城轨 T2I 场景数据集不足问题。本文采用条件生成对抗网络 (CGAN, conditional generative adversarial network), 相比传统固定损失的 GAN, 其更容易生成更真实的信道响应。2 种深度学习网络的结合, 提高了所需信道数据的质量和多样性, 在参数生成效率方面优于传统的信道建模。CGAN 的生成器模型, 选用了 U-Net 结构的编解码器方案。CGAN 结构对

CGAN-LSTM网络的优化有一定的修正作用,从而使信道估计即使在低信噪比的环境下也能保持良好性能。

3) 在传统的Adam优化器对深度学习模型权重参数的优化方案基础上,提出一种基于混沌博弈优化(CG0, chaos game optimization)的Adam优化器,利用此组合优化器对CGAN-LSTM网络参数进行优化,进一步提高信道估计精度和效率。

4) 用归一化均方误差(NMSE, normalized mean square error)和误码率(BER, bit error rate)作为评价指标,对本文所提出的基于深度学习的信道估计方法进行仿真分析,以此验证在T2I场景主要影响因素变化的情况下,基于CG0-Adam优化的CGAN-LSTM网络的信道估计性能优于传统的信道估计和其他深度学习网络信道估计。

## 1 OTFS-ISAC系统模型

### 1.1 系统模型

图1为城轨T2I场景OTFS-ISAC系统模型,可简化为一个轨旁基站(BS, base station)盖的多列

车网络。BS在毫米波波段工作,配备了由 $N_t$ 个天线组成的发射均匀线性阵列(ULA, uniform linear array)和 $N_r$ 个天线组成的接收ULA。在发射端和接收端阵列间间隔足够时,可以不考虑列车车身反射的传感回波对一体化信号下行传输的影响,模型中的BS平行于轨道线路进行布置。针对列车相对BS的运动,设列车只沿着线路 $x$ 轴的正或负方向运动,将其简化为点式目标模型<sup>[17]</sup>,列车配备了用来接收来自BS的信息的多输入多输出(MIMO, multiple-input multiple-output)天线。BS与MIMO天线之间的ISAC信号传输路径包含了视线线路(LoS, line of sight)和非视距(NLoS, non line of sight)路径,本文针对LoS路径ISAC信号传输进行信道估计。

### 1.2 OTFS调制

单符号OTFS信号具有 $M$ 个带宽为 $\Delta f$ 的子载波,由此信号带宽则为 $B = M\Delta f$ 。单符号周期为 $T$ ,单帧 $N$ 个符号的OTFS信号周期为 $NT$ 。设OTFS信号发送端星座调制输入序列为 $x[k, l]$ ,其中 $k \in [0, N - 1], l \in [0, M - 1]$ ,其被排列于一个 $N \times$

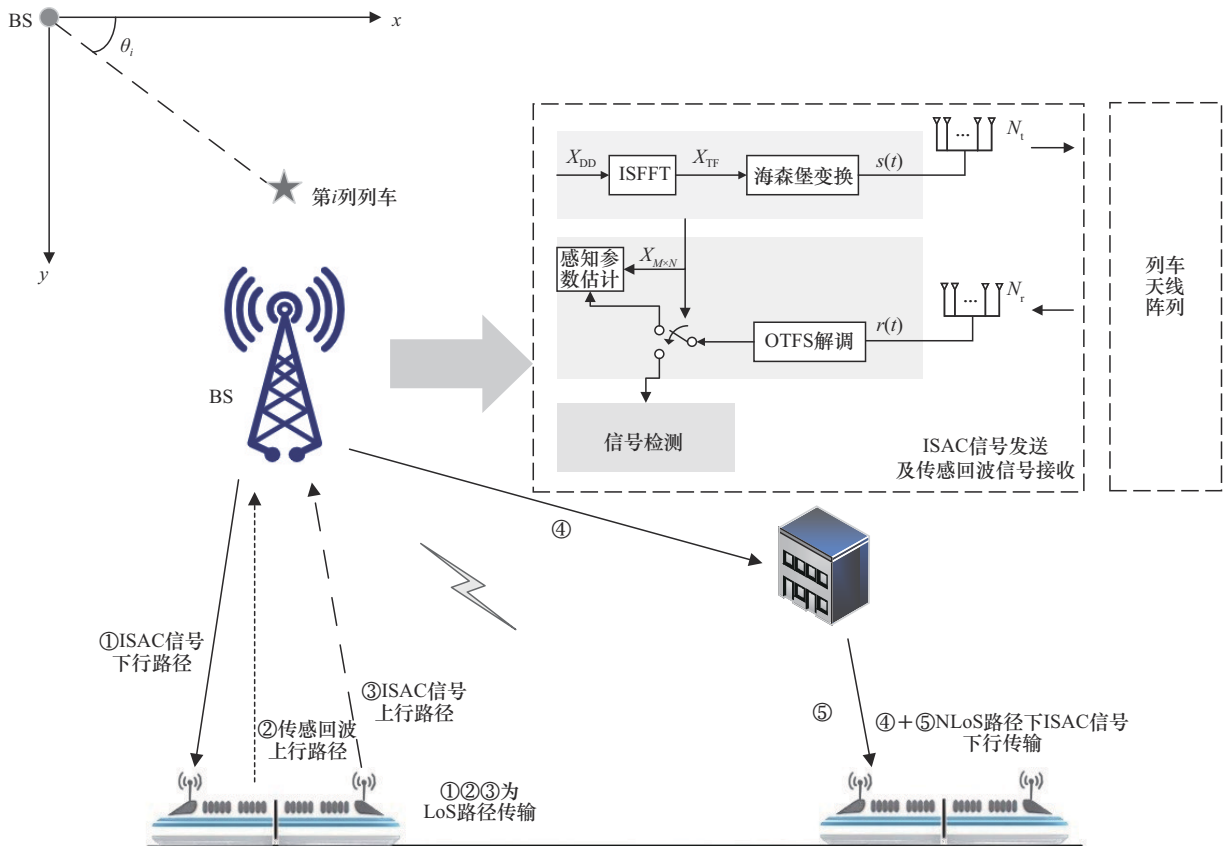


图1 城轨T2I场景OTFS-ISAC系统模型

$M$  的时延-多普勒域二维网格之中。发射端星座调制序列  $x[k, l]$  经逆辛有限傅里叶变换 (ISFFT) 后的时频域信号为

$$X[n, m] = \frac{1}{\sqrt{NM}} \sum_{k=0}^{N-1} \sum_{l=0}^{M-1} x[k, l] \exp \left[ j2\pi \left( \frac{nk}{N} - \frac{ml}{M} \right) \right] \quad (1)$$

其中,  $n = 0, \dots, N-1$ ,  $m = 0, \dots, M-1$ 。经海森堡变换后的时域信号为

$$s(t) = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} X[n, m] g_{tx} \cdot (t - nT) \exp [j2\pi m \Delta f (t - nT)] \quad (2)$$

其中,  $g_{tx}(\cdot)$  为发送脉冲, 式(2)的连续时间信号通过时延信道进行传输。为了准确建立感知目标的时延和多普勒频移相关模型, 将时延信道转换为 DD 域信道。在这种情况下, 时延  $\tau$  在  $[0, \tau_{\max}]$  范围内, 多普勒频移  $\nu$  在  $[-\nu_{\max}, \nu_{\max}]$  范围内,  $\tau_{\max}$  和  $\nu_{\max}$  表示 DD 域信道的最大时延和多普勒频移。DD 域信道响应可表示为

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

其中,  $P$  为信号传播路径数,  $h_i$  是信道增益,  $\delta(\cdot)$  为狄拉克函数,  $\tau_i$  和  $\nu_i$  分别是第  $i$  个传播路径的时延和多普勒频移。

## 2 OTFS-ISAC 数学模型

### 2.1 OTFS-ISAC 信号下行传输模型和上行回波模型

预设轨旁 BS 的 ULA 具备  $N_t$  个发射天线和  $N_r$  个接收天线, 列车接收天线数为  $N_u$ , 则对准  $P$  列列车的时域信号  $\mathbf{s}(t)$  可表示为

$$\mathbf{s}(t) = [s_1(t), \dots, s_P(t)]^T \quad (4)$$

轨旁 BS 与线路为平行放置, 进入 BS 覆盖范围内的列车按先后顺序标记, 第  $i$  列列车对应接收的信号则为  $s_i(t)$ 。用波束矩阵  $\mathbf{F} \in \mathbb{C}^{N_t \times P}$  作为信号波束成形系数, 多波束时域信号为

$$\tilde{\mathbf{s}}(t) = \mathbf{F} \mathbf{s}(t) \quad (5)$$

波束矩阵的第  $i$  列为  $\mathbf{f}_i = \sqrt{\frac{p_i}{N_t}} \mathbf{a}_{N_t}(\tilde{\theta}_i)$ , 决定了天线功率分配策略和信号波方向, 其中  $p_i$  为功率分配因子, 列向量  $\mathbf{a}_{N_t}(\tilde{\theta}_i)$  为期望方向  $\tilde{\theta}_i$  的发射转向向量

$$\mathbf{a}_{N_t}(\theta_i) = [1, e^{j\pi \sin \theta_i}, \dots, e^{j(N_t-1)\pi \sin \theta_i}]^T \quad (6)$$

由于大规模 ULA 趋近正交特性, 本文基于轨旁 BS 到列车间的视距传输对信道进行建模, 根据式(3), 针对第  $i$  列列车的下行通信信道可表示为

$$\mathbf{H}_i(\tau, \nu) = h_i \mathbf{a}_{N_u}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \delta(\tau - \tau_i) \delta(\nu - \nu_i) \quad (7)$$

其中, 信道增益  $h_i = \sqrt{\frac{c}{4\pi f_c d_i^2}}$ ,  $c$  为光速,  $f_c$  为载波频率,  $d_i^2$  为轨旁 BS 到第  $i$  个目标列车之间的欧氏距离, 列向量  $\mathbf{a}_{N_u}(\theta_i) = [\mathbf{a}_1(\theta_i), \dots, \mathbf{a}_{N_u}(\theta_i)]^T$  为列车接收天线的转向向量, 接收端信号可表示为

$$y_i(t) = h_i \mathbf{r}_i^H \mathbf{a}_{N_u}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \cdot \mathbf{f}_i s_i(t - \tau_i) e^{j2\pi \nu_i (t - \tau_i)} + w_i(t) \quad (8)$$

其中,  $\mathbf{r}_i \in \mathbb{C}^{N_r \times 1}$  为接收端波束成形矩阵,  $w_i(t)$  表示时域信道噪声。通过接收端脉冲整形滤波器  $g_{rx}(t)$ , 再经 Wigner 变换和辛傅里叶变换, 接收端 DD 域信号可表示为

$$\mathbf{Y}_{DD}[k, l] = h_i \mathbf{r}_i^H \mathbf{a}_{N_u}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \cdot$$

$$\mathbf{f}_i \mathbf{S}_{DD}[(k - k_i)_{N_s}, (l - l_i)_{M}] + \mathbf{W}_{DD}[k, l] \quad (9)$$

其中,  $k_i = \tau_i NT$ ,  $l_i = \nu_i M \Delta f$ ,  $\mathbf{S}_{DD}[k, l]$  为接收端还原后 DD 域信号,  $\mathbf{W}_{DD}[k, l]$  表示功率谱密度为  $N_0$  的高斯白噪声样本。根据式(7), 信号回波至 BS 的上行链路传感回波  $P$  个路径的多路径传输信道为

$$\mathbf{Q}(t, \tau) = \sum_{i=1}^P \beta_i \mathbf{a}_{N_t}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \delta(\tau - \tau_i^U) e^{j2\pi \nu_i^U t} \quad (10)$$

其中,  $\beta_i$ ,  $\tau_i^U$  和  $\nu_i^U$  分别为第  $i$  列列车接收下行信号后反射回波传输的反射系数、时延和多普勒频移。BS 处接收的列车感知回波可以表示为

$$\mathbf{r}(t) = \sum_{i=1}^P \beta_i \mathbf{a}_{N_t}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \tilde{\mathbf{s}}(t - \tau_i^U) e^{j2\pi \nu_i^U t} + \mathbf{z}(t) \quad (11)$$

其中,  $\mathbf{z}(t)$  是接收感知回波中的噪声向量。由于 MIMO 接收天线阵列各角度转向向量渐近正交, 感知回波中不同列车产生的 NLoS 路径反射干扰可以忽略, BS 根据到达角区分目标列车, BS 从第  $i$  个目标列车提取的感知回波为

$$r_i(t) = \beta_i \mathbf{b}_i^H \mathbf{a}_{N_t}(\theta_i) \mathbf{a}_{N_t}^H(\theta_i) \mathbf{f}_i s_i(t - \tau_i^U) e^{j2\pi \nu_i^U t} + z(t) \quad (12)$$

接收端波束成形  $\mathbf{b}_i = \mathbf{a}_{N_t}^H(\tilde{\theta}_i)$ 。根据 BS 接收端

波束天线增益和转向角度的关系,式(12)可写为

$$r_i(t) = G_a s_i(t - \tau_i^U) e^{j2\pi v_i^U t} + z(t) \quad (13)$$

本文MIMO复合天线增益为 $G_a = \sqrt{N_t N_r}$ ,式(13)经BS处滤波和OTFS解调处理后得到反射回波DD域表达为

$$\mathbf{R}[k,l] = G_a \sum_{k'=0}^{N-1} \sum_{l'=0}^{M-1} \mathbf{Q}_{DD}[k_i^U, l_i^U] \cdot \mathbf{S}_{DD}[(k - k_i^U)_N, (l - l_i^U)_M] + \mathbf{z}[k,l] \quad (14)$$

其中,  $\mathbf{Q}_{DD}[k_i^U, l_i^U]$ 为第*i*个目标回波信号在DD域传输的信道增益,其中 $k_i^U = \frac{v_i^U}{NT}$ ,  $l_i^U = \frac{\tau_i^U}{M\Delta f}$ 。

## 2.2 嵌入式导频设置

本文将在一体化信号中插入传统的OTFS导频符号,以辅助传感回波在上行链路传输的信道估计,如图2所示,本文信道估计用例只考虑整数多普勒频移的情况,  $s_p = \mathbf{S}_{DD}[k_p, l_p]$ 表示插入的导频符号,  $k_p$ 和 $l_p$ 表示导频在DD域网格中的位置。




图2 OTFS-ISAC系统导频设置

传输过程中完整的DD域信号可表示为

$$\mathbf{S}_{DD} = \begin{cases} s_p, & k = k_p, l = l_p \\ 0, & k \in [k_p - k_{\max}, k_p + k_{\max}], \\ & l \in [l_p - 2l_{\max}, l_p + 2l_{\max}] \\ \text{数据符号, 其他} \end{cases} \quad (15)$$

其中,  $k_{\max}$ 和 $l_{\max}$ 表示数据符号和导频符号之间的间距,标识了域内保护符号数,也对应目标的最大时延和多普勒频移。定义 $\mathbf{S}_d$ 和 $\mathbf{S}_p$ 为满足要求的数据符号矩阵和导频符号矩阵。数据符号矩阵表示为

$$\mathbf{S}_d[k,l] = \begin{cases} 0, & k \in [k_p - k_{\max}, k_p + k_{\max}], \\ & l \in [l_p - 2l_{\max}, l_p + 2l_{\max}] \\ \text{数据符号, 其他} \end{cases} \quad (16)$$

导频符号矩阵表示为

$$\mathbf{S}_p[k,l] = \begin{cases} s_p, & k = k_p, l = l_p \\ 0, & \text{其他} \end{cases} \quad (17)$$

根据上述对DD域信号的划分情况,式(9)也可表示为

$$\mathbf{Y}_{DD}[k,l] = \mathbf{Q}_{DD}[k,l] \otimes \mathbf{S}_{DD}[k,l] + \mathbf{W}_{DD}[k,l] = \mathbf{Q}_{DD}[k,l] \otimes (\mathbf{S}_d[k,l] + \mathbf{S}_p[k,l]) + \mathbf{W}_{DD}[k,l] \quad (18)$$

其中,  $\otimes$ 为循环卷积运算,  $\mathbf{Q}_{DD}[k,l]$ 为DD域信道响应表示。本文利用导频信息作为深度学习网络的输入,对信道状态信息(CSI, channel state information)进行还原,从而完成信道估计,用 $\mathbf{Y}_p \in \mathbb{C}^{M \times N}$ 表示导频矩阵

$$\mathbf{Y}_p[k,l] = \mathbf{Q}_{DD}[k,l] \otimes \mathbf{S}_p[k,l] + \mathbf{W}_{DD}[k,l] \quad (19)$$

$$\mathbf{Y}_p = \mathbf{Q}_p + \mathbf{W}_{DD} \quad (20)$$

其中,  $\mathbf{Q}_p[k,l] = \mathbf{Q}_{DD}[k,l] \otimes \mathbf{S}_p[k,l]$ 。就此定义真实接收的信号和信道响应的实虚部矩阵表达式分别为

$$\mathbf{Y} = \begin{bmatrix} [\mathbf{Y}_{PR}] \\ [\mathbf{Y}_{PI}] \end{bmatrix}, \mathbf{Q} = \begin{bmatrix} [\mathbf{Q}_{PR}] \\ [\mathbf{Q}_{PI}] \end{bmatrix} \quad (21)$$

其中,  $\mathbf{Y} \in \mathbb{C}^{k_{\max} \times 2l_{\max} \times 2}$ ,  $\mathbf{Q} \in \mathbb{C}^{M \times N \times 2}$ ,矩阵下标PR和PI分别表示导频部分的实虚部。所以,接收回波信号导频 $\mathbf{Y}$ 和回波信道矩阵 $\mathbf{Q}$ 可以看作具有维数的双通道图像,图像的2个通道表示复矩阵的实部和虚部,把信道估计问题作为图像转换问题处理。

## 3 OTFS-ISAC系统信道估计

### 3.1 CGAN-LSTM

时变信道CSI是一种典型的时间序列数据,具有数据量大,前后数据相关性大的特点。因此,可以使用递归神经网络(RNN, recursive neural network)模型来预测CSI。而RNN的缺点是容易出现梯度消失和梯度爆炸的问题,导致模型泛化性较差<sup>[18]</sup>。LSTM网络可以用梯度项来弥补RNN的缺陷,但随着输出数据维数的增加,预测精度会降低,模型预测的错误率增加<sup>[19]</sup>。为了解决上述2个问题,可以使用GAN的生成模型对LSTM网络进行优化。

### 3.1.1 CGAN

GAN 使用对抗性的结构来学习真实数据样本，一旦训练完成，就可以生成新的数据样本<sup>[20]</sup>，由生成器模型和鉴别器模型组成。生成器模型学习从随机噪声到真实数据的映射关系，但这种多维数据映射具有不稳定性和随机性。因此，CAGN<sup>[21]</sup>作为 GAN 模型的扩展结构被提出，学习具备特定条件的输入到真实数据的映射，其基础结构如图 3 所示。与具有固定损失函数的非 CGAN 结构的 CNN 相比，CGAN 的体系结构更稳定，更容易生成更真实的通道。图 1 中 MIMO 系统内置特殊的模数转换器（ADC, analog-to-digital converter），输出仅包含 0 和 1，这种 ADC 的主要特点是其输出分辨率仅为 1 位，通常用于特定的应用场景，如认知无线电中的频谱感知和雷达系统中的目标检测，这种 ADC 可以降低 MIMO 的功耗。由于其极低分辨率，通常会丢失信道数据细节，因此检测误差，且使传统估计方法的信号处理过程复杂度增加。本文设计的 CGAN 可在简化估计过程的基础上，最大限度地弥补缺失数据，从而提高信道估计性能。

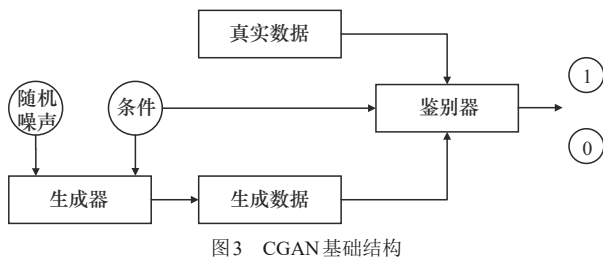
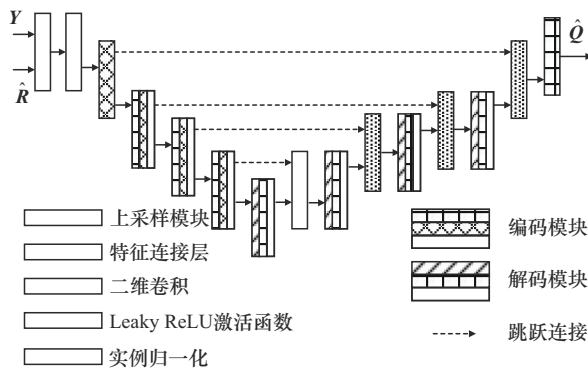


图3 CGAN 基础结构

CGAN 的目的是使生成器合成最真实的信道矩阵来欺骗鉴别器，而鉴别器需要训练学习尽可能不被欺骗，这 2 种网络都会对抗对手以获得最佳结果。



(a) 生成器结构

为了实现对抗中的优化，应用了 GAN 损失，加入条件参数  $c$ ，CGAN 模型损失函数  $\zeta_{CGAN}(G,D)$  为<sup>[21]</sup>

$$\begin{aligned} \zeta_{CGAN}(G,D,c) &= E_{x \sim p_{data}(x)} [\log(D(x|c))] + \\ &E_{z \sim p_z(z)} [\log(1 - D(G(z|c)))] = \\ &\arg \min_G \max_D \zeta_{CGAN}(G,D,R,Q,Y) = \\ &E_{x \sim p_{data}(x)} [\log(D(Q,Y))] + \\ &E_{z \sim p_z(z)} [\log(1 - D(G(R,Y)))] \end{aligned} \quad (22)$$


其中， $E_{x \sim p_{data}(x)} [\log(D(x|c))]$  表示条件  $c$  情况下对真实数据期望， $E_{z \sim p_z(z)} [\log(1 - D(G(z|c)))]$  表示条件  $c$  情况下对生成数据期望。为了防止逆向优化的产生，加入辅助损失函数<sup>[22]</sup>

$$\zeta = E [\|Q - G(R,Y)\|^2] \quad (23)$$

根据式(22)、式(23)得到 CGAN 的目标函数为

$$\begin{aligned} \zeta &= \arg \min_G \max_D \zeta_{CGAN}(G,D,R,Q,Y) + \\ &E [\|Q - G(R,Y)\|^2] \end{aligned} \quad (24)$$

本文 CGAN 生成器中采用了 U-Net<sup>[23]</sup> 架构，如图 4(a) 所示。其中每个二维卷积层由 128 个  $4 \times 4$  的滤波器构成，实例归一化比批归一化更有利于加速模型收敛。与普通的编码器-解码器结构相比，U-Net 的特殊之处是采用了跳跃连接，编码器模块和解码器模块的特征映射通过跳跃连接进行拼接，以保留不同分辨率的像素细节，即空间信息。因此，U-Net 对改善细节有明显的影响，其中可以保留不同尺度的信息。图 4(b) 为鉴别器结构，是一个简单的 CNN 结构。为了提高信息细节的恢复能力，将待识别区域划分成若干区域



(b) 鉴别器结构

图4 CGAN 生成器和鉴别器结构

块结构,不同于常规鉴别器,图4(b)中将输入映射到单个0维张量输出,表示真或假的结果,区域块鉴别器将输入映射到一个感受野,这当中每个元素都会表示输入的真假。为了实现上述过程,鉴别器的前端由一个二维卷积层、一个Leaky ReLU激活层和6个编码器模块组成,二维卷积层由512个4×4大小的滤波器构成。在鉴别器末端,用卷积层代替全连接层来得到感受野,所有的感受野区域取平均得到鉴别器的最终输出。

### 3.1.2 LSTM

LSTM可以有效地学习时间序列相关模型<sup>[24]</sup>中的长期依赖性。将图5(a)中的多层LSTM看作利用连续测量得到的 $k_{\text{LSTM}}$ 个先前状态来预测空间域中的下一个序列状态。LSTM模型的输出 $\mathbf{h}_t$ 包括从序列中获得的时间步长更新信息,并作为下一阶段深度神经网络的输入向量。

$$\mathbf{h}(n) = \arg \max_{\mathbf{h}} p(\mathbf{h}(n) | \mathbf{h}(n - k_{\text{LSTM}} + 1), \mathbf{h}(n - k_{\text{LSTM}} + 2), \dots, \mathbf{h}(n - 1)) \quad (25)$$


$$\mathbf{h}_t = f_{\text{LSTM}}(\mathbf{h}(n - k_{\text{LSTM}} + 1), \mathbf{h}(n - k_{\text{LSTM}} + 2), \dots, \mathbf{h}(n)) \quad (26)$$

其中,  $p(\cdot)$ 为条件概率密度函数。式(25)表示在给定 $j - 1$ 个历史状态序列条件下,通过最大化条件概率 $p$ ,预测最可能的状态 $\mathbf{h}(n)$ ,  $f_{\text{LSTM}}(\cdot)$ 表示多层LSTM模型函数。LSTM层数选取过程中,从1开始递增观察实验结果,选取1、2层时,模型训练时长较短,但NMSE结果不理想;选取3、4层时,NMSE结果相近,且未发生过拟合;选取5层及以上时,发生过拟合。考虑组合模型复杂度和计算效率,最终选3层LSTM,每层LSTM输出需传递隐藏状态和细胞状态2个状态到下一层中,故 $k_{\text{LSTM}} = 6$ 。


### 3.1.3 CGAN-LSTM

本文在CGAN生成器前添加一个由多层LSTM基础模块组成的LSTM网络,LSTM网络的输入为随机回波信号序列矩阵,LSTM模块利用连续测量得到的 $k_{\text{LSTM}}$ 个 $\mathbf{R}$ 先前状态来预测DD域中的下一个回波信号状态,如图5(a)所示,输出 $\hat{\mathbf{R}}$ 包括从随机回波信号矩阵 $\mathbf{R}$ 中获得的时间步长更新信息。在CGAN-LSTM网络中,LSTM的输出 $\hat{\mathbf{R}}$ 作为CGAN生成器的输入,回波信号的导频矩阵 $\mathbf{Y}$ 作为条件输入,据此架构的CGAN-LSTM网络优于原始的CGAN和LSTM的独立网络结构。为了节省计算资

源和时间,CGAN-LSTM网络分为离线训练和在线估计两部分,图5(a)先对模型进行离线训练,图5(b)利用训练好的生成器进行最终的信道估计。



(a) CGAN-LSTM离线训练部分



(b) CGAN-LSTM在线估计部分

图5 CGAN-LSTM网络信道估计

CGAN-LSTM网络模型训练算法如算法1所示。

#### 算法1 CGAN-LSTM网络模型训练算法

**初始化** 批次大小  $m_{\text{batch}}$ , CGAN生成器 $G$ 学习率 $\eta_G$ , 鉴别器 $D$ 学习率 $\eta_D$ , 鉴别器和生成器训练次数 $n_{\text{DG}}$ , 3层LSTM模块传递状态数 $k_{\text{LSTM}} = 6$ , 生成器初态参数 $\theta_{G_0}$ , 鉴别器初态参数 $\theta_{D_0}$

- 1) while 生成器参数 $\theta_G$ 未收敛 do
- 2) for  $t=1:n_{\text{DG}}$
- 3) for  $j=1:m_{\text{batch}}$
- 4) 多层LSTM对输入 $\mathbf{R}[k,l]$ 进行时间相关性映射,得到 $\hat{\mathbf{R}}[k,l]$
- 5) 对 $\hat{\mathbf{R}}[k,l]$ 进行随机噪声采样 $z \sim p(z)$ ,生成随机数联合条件信息 $\mathbf{Y}$ 输入生成器,生成器合成信道矩阵 $\hat{\mathbf{Q}}$
- 6) 将步骤5)中得到的 $\hat{\mathbf{Q}}$ 、式(21)的 $\mathbf{Q}$ 和条件信息 $\mathbf{Y}$ 输入鉴别器,输出鉴别结果
- 7) 根据式(24)的目标函数计算损失
- 8)  $\theta_D \leftarrow$ 利用CGO-Adam优化器优化 $\theta_{G_0}$
- 9) end for
- 10) 分别从真实数据和噪声数据中进行

采样

- 11)  $\theta_G \leftarrow$  利用 CGO-Adam 优化器优化  $\theta_{G_0}$
- 12) end for
- 13) end while

### 3.2 基于混沌博弈的 Adam 优化器

为了提高 CGAN-LSTM 模型 CSI 估计的性能, 本文采用 CGO-Adam 算法来优化 CGAN-LSTM 模型的网络参数。CGO 算法是基于混沌原理提出的一种优化算法<sup>[25]</sup>, 利用分形和混沌博弈的基本概念, 建立了 CGO 算法的数学模型。假设算法有一些候选解决方案 ( $\mathbf{X}$ ), 它们代表了锡尔平斯基 (Sierpinski) 三角形中的一些合格的种子。其中的每个候选解 ( $\mathbf{X}_i$ ) 由一些决策变量 ( $x_{ij}$ ) 组成, 这些决策变量表示合格的种子在 Sierpinski 三角形中的位置。合格种子的初始位置随机搜索为

$$x_{ij}^j(0) = x_{i,\min}^j + \text{rand}(x_{i,\max}^j - x_{i,\min}^j),$$

$$i = 1, 2, \dots, n, j = 1, 2, \dots, d \quad (27)$$

其中,  $x_{ij}^j(0)$  表示合格种子的初始位置,  $x_{i,\min}^j$  和  $x_{i,\max}^j$  分别为第  $i$  个候选解的第  $j$  个决策变量的最小值和最大值, rand 为 [0,1] 的随机数。

该数学模型的意义是在搜索空间内创建不同的合格种子, 以完成 Sierpinski 三角形的整体形状绘制。对于搜索空间  $\mathbf{X}_i$  中的每个合格种子, 将绘制一个包含 3 个种子的临时三角形, 3 个种子寻优机制为

$$\text{Seed}_i^1 = \mathbf{X}_i + \alpha_i \times (\beta_i \times \text{GB} - \gamma_i \times \text{MG}_i),$$

$$i = 1, 2, \dots, n \quad (28)$$

$$\text{Seed}_i^2 = \text{GB} + \alpha_i \times (\beta_i \times \mathbf{X}_i - \gamma_i \times \text{MG}_i),$$

$$i = 1, 2, \dots, n \quad (29)$$

$$\text{Seed}_i^3 = \text{MG}_i + \alpha_i \times (\beta_i \times \mathbf{X}_i - \gamma_i \times \text{GB}),$$

$$i = 1, 2, \dots, n \quad (30)$$

其中, GB 为迄今为止全局最优解;  $\text{MG}_i$  为种群平均位置;  $\alpha_i$  为随机阶乘, 用于模拟种子的位置限制;  $\beta_i$  和  $\gamma_i$  表示 1 或 2 的随机整数, 用于模拟掷骰子的可能性。为了在搜索符合条件的种子位置更新过程中实现突变阶段, 还利用另一个过程生成第 4 个种子。

$$\text{Seed}_i^4 = \mathbf{X}_i(x_i^k = x_i^k + R), k = [1, 2, \dots, d] \quad (31)$$

其中,  $k$  是 [1,  $d$ ] 的随机整数,  $R$  是 [0,1] 内的均匀分

布随机数。

Adam 优化器是均方根传播优化算法<sup>[26]</sup>和随机梯度下降算法<sup>[27]</sup>的结合。元启发式算法多用于深度学习模型中无须梯度信息的非可微操作, 而 Adam 优化器则需要梯度信息实现, 两者结合使用可以在不需要梯度信息时使用元启发式算法进行全局搜索, 需要精细调整时使用 Adam 优化器进行局部优化。为了提高 CGO 算法种子的搜索能力, 本文将 CGO 算法和 Adam 优化器结合了起来。在该算法中, Adam 优化器使用从 CGO 算法中得到的解空间来继续搜索, 从而获得最终的解决方案空间。CGO-Adam 对 CGAN-LSTM 网络参数优化如算法 2 所示。

**算法 2** CGO-Adam 对 CGAN-LSTM 网络参数优化

输入 CGAN-LTSM 网络参数初值  $\theta_{D_0}$ ,  $\theta_{G_0}$ , 最大迭代次数  $\text{iter}_{\max} = 200$

输出 优化后的 CGAN-LTSM 网络参数  $\theta_D$ ,  $\theta_G$

初始化 种子位置, 即候选解空间  $\mathbf{X}_i = (x_i^1, x_i^2, \dots, x_i^d)$ , 其中  $x_i^j = (\theta_D, \theta_G)_i^j$

1) 计算每个候选种子的适应度值  $f(i) = \min[\zeta(i)]$ ;

2) 计算截至当前全局最优解 GB, 即候选最优种子的寻优路径;

3) while 迭代次数  $\text{iter} < \text{iter}_{\max}$  do

4) for  $i=1$ : 初始候选种子数

5) 对于每个合格的解空间  $\mathbf{X}_i$ , 随机选取种子计算  $\text{MG}_i$ ;

6) 对于每个合格的解空间  $\mathbf{X}_i$ , 确定由顶点  $\mathbf{X}_i$ 、 $\text{MG}_i$ 、 $\text{GB}_i$  构成的临时三角形

7) 计算  $\alpha_i$ 、 $\beta_i$ 、 $\gamma_i$

8) 对于每个临时三角形, 根据式(28)~式(31) 确定 4 个新种子位置

9) if 新种子位置不满足三角形边界条件  
10) 为新种子控制位置约束, 并做位置修正

11) end if

12) 计算每个新种子的适应度值

13) if 新种子的适应度值优于初始条件中最差的种子的适应度值

14) 用新种子代替初始条件最差的种子

- 15) end if
- 16) 更新已找到的更好新种子位置  $\mathbf{X}'$  对应的全局最优解
- 17) end for
- 18) 利用 Adam 优化器<sup>[28]</sup>更新已获得解空间, Adam 优化器参数初始化为  $\psi_0 = \mathbf{X}'$
- 19) iter = iter + 1
- 20) end while

## 4 仿真分析

本节通过对仿真结果的分析来验证所提出的基于 CGO-Adam 优化的 CGAN-LSTM 网络信道估计方法对 OTFS-ISAC 系统信道估计的高效性。

### 4.1 参数设置和评价指标

系统参数如表1所示。本文使用蒙特卡罗方法生成  $1 \times 10^4$  个样本, CGAN-LSTM 网络生成器学习率  $\eta_G$  和鉴别器学习率  $\eta_D$  均设置为 0.001, 处理批次  $m_{\text{batch}}$  大小为 128。为了评价信道估计的性能, 将本文提出的基于 CGO-Adam 优化的 CGAN-LSTM 网络信道估计方法与 3 种传统信道估计方法进行了比较, 包括最小二乘 (LS, least square)、正交匹配追踪 (OMP, orthogonal matching pursuit) 和最小均方误差 (MMSE, minimum mean square error) 等。利用归一化均方误差 (NMSE, normalized mean square error) 计算信道矩阵估计值  $\hat{\mathbf{Q}}$  和真实值  $\mathbf{Q}$  之间的差异。

表1 系统参数

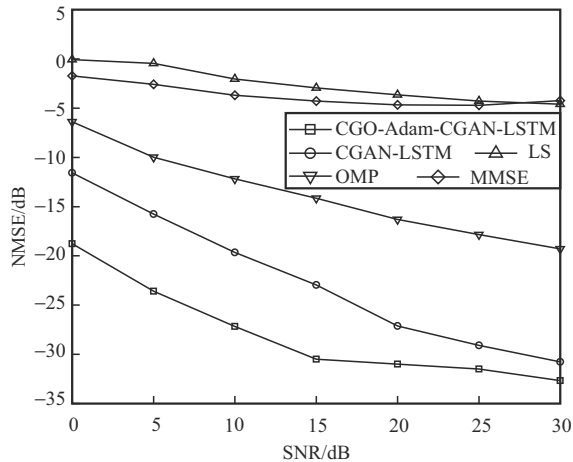
参数名称	参数设置
数字调制方式	4-QAM
符号数 $N$	16
子载波数 $M$	32
载波频率/GHz	4
子载波间距/kHz	15
主路径数 $P$	4
导频长度 $L_p$	16
BS 天线数	$N_t = N_r = 64$
信道模型	Rician 模型
最大时延 $k_{\text{max}}$	5
最大多普勒频移 $f_{\text{max}}$	4
列车移动速度/( $\text{km} \cdot \text{h}^{-1}$ )	120

$$\text{NMSE} = 10 \lg \left\{ \mathbb{E} \left[ \frac{\|\mathbf{Q} - \hat{\mathbf{Q}}\|_2^2}{\|\mathbf{Q}\|_2^2} \right] \right\} \quad (32)$$

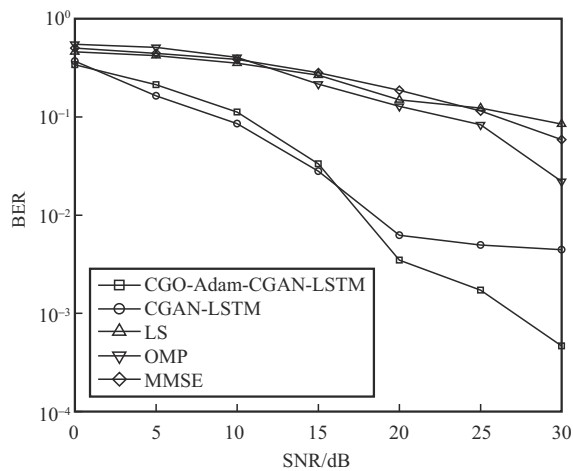
其中,  $\|\cdot\|_2$  表示矢量的二范数。

### 4.2 信道估计性能分析

传统信道估计方法在 OTFS-ISAC 系统中面临性能与资源消耗的权衡挑战。如图 6(a) 所示, LS 算法在低信噪比, 如  $\text{SNR} < 10$  dB 时, NMSE 指标较 MMSE 与 OMP 高 20%~50%, 其导频密集特性导致系统开销占比高达 30%, 严重压缩了通信感知一体化频谱的有效数据容量; MMSE 虽通过统计先验知识降低噪声敏感性, 但其 NMSE 在 SNR 从 20 dB 降至 10 dB 时仍升高 0.5 倍, 部分场景下甚至恶化 2~3 倍<sup>[29]</sup>。此外, OMP 虽可利用 DD 域信道稀疏性, 但在城轨高速场景中, 多径效应与列车动态运动导致信道持续非稀疏, 加之高噪声环境下需多轮迭代才能稳定收敛, 使其计算复杂度与实时性难以满足车-地通信需求<sup>[10]</sup>。上述问题本质源于传统方法对信道动态特性与噪声干扰的建模局限性: LS 缺乏噪声抑制机制, MMSE 依赖精确先验统计信息, OMP 受限于稀疏性假设, 三者均难以兼顾 OTFS-ISAC 系统对低 NMSE、低资源消耗与高实时性的综合需求。针对上述挑战, 本文提出的 CGAN-LSTM 网络通过深度融合数据驱动能力与 DD 域稀疏先验知识, 显著提升信道估计性能。实验表明, 未优化时该网络在低 SNR 下展现优异的 NMSE,  $\text{SNR}=25$  dB 时较 OMP 提升 13 dB, 性能增益 63%; 引入基于 CGO 算法的 Adam 优化器后, 其 NMSE 在  $\text{SNR}=15$  dB 时进一步优化 13 dB, 性能增益 33%。性能提升的本质原因在于: LSTM 网络通过时序建模捕捉高速场景下信道的时变特性, 增强对非稀疏信道的适应性; CGAN 框架通过对抗训练生成高保真信道响应, 弥补了传统信道估计方法对不完整 CSI 的还原缺陷; CGO-Adam 优化器通过动态调整学习率加速模型收敛, 降低计算时延。相较于传统信道估计方法, 该方案以较低复杂度实现 NMSE 的显著改善, 既避免了密集导频的资源浪费, 又通过端到端学习减少对先验统计信息的依赖, 更契合城轨车-地场景中 OTFS-ISAC 系统对高可靠、低时延与频谱高效的核心需求。



(a) NMSE与SNR之间的关系



(b) BER与SNR之间的关系

图6 CGO-Adam-CGAN-LSTM网络信道估计与其他信道估计方法性能对比

如图 6(b)所示, 与 LS、MMSE 和 OMP 相比, 基于 CGO-Adam 优化的 CGAN-LSTM (CGO-Adam-CGAN-LSTM) 网络信道估计在 SNR=30 dB 的高 SNR 情况下, 最多下降了 98%、99% 和 97%。与未做优化处理的 CGAN-LSTM 网络估计相比, 在中低 SNR 条件下, BER 略高, 当处于较高 SNR 条件时, 基于 CGO 算法的 Adam 优化器有展现其优势, 当 SNR=30 dB 时, CGO-Adam-CGAN-LSTM 网络 BER 有 89% 的降低。

在目前流行的基于深度学习的信道估计方法方面, 将 CGO-Adam-CGAN-LSTM 网络与基于 CNN<sup>[30-31]</sup>、基于本文所提 CGAN 和 Transformer<sup>[32]</sup> 等模型的 NMSE 性能进行对比, 结果如图 7 所示。CNN 在较高信噪比区域比深度学习模型性能弱。而与 CGAN-LSTM 网络相比, 单一 CGAN 和 Trans-

former 性能都与其接近, 但弱于 CGO-Adam-CGAN-LSTM 网络。

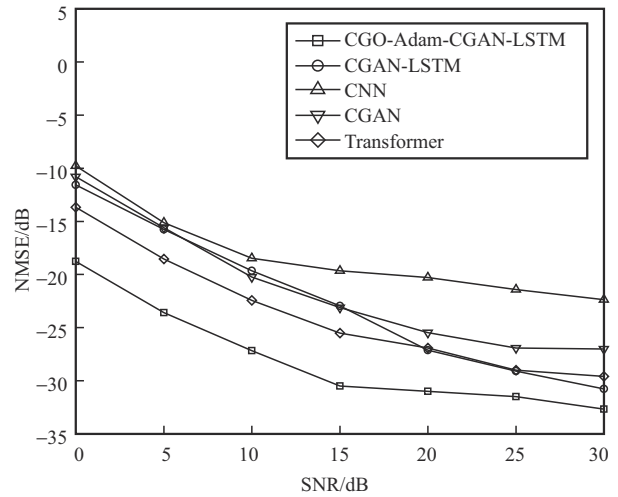


图7 基于深度学习的信道估计方法性能对比


将同为元启发算法的粒子群优化 (PSO, particle swarm optimization) 算法与 CGO 算法分别与 Adam 优化器结合, 对 CGAN-LSTM 网络参数进行优化, 在不同迭代次数下, NMSE 的结果如表 2 所示。可以看到, CGO 算法在 iter = 75 时, NMSE 趋于收敛, PSO 算法在 iter = 100 时, NMSE 趋于收敛, 两者 NMSE 收敛值接近, 但是 CGO 算法收敛较快。

表2 不同迭代次数 CGO 和 PSO 算法的 NMSE 对比


iter	NMSE	
	CGO	PSO
25	-22.351	-20.142
50	-27.167	-23.547
75	-31.516	-25.327
100	-31.509	-29.195
125	-32.082	-30.024
150	-31.491	-29.839
175	-31.507	-30.113
200	-32.704	-30.075

基于 OTFS 调制的通信感知一体化信号中的导频序列, 可以提供 CSI 信息用于信道估计, 越长的导频序列可以提供越多的信息, 从而提高信道估计的准确性。当导频序列增加到一定长

度, 由于DD域信道资源导频信号占用, 数据信号被搁置, 会降低原数据传输的效率, 间接影响传输误码率。从图8(a)中可以看出, 导频长度对CGO-Adam-CGAN-LSTM网络估计精度影响并不大,  $L_p=16$ 与 $L_p=4$ 相比NMSE最大降低了14%。当 $L_p$ 增大到64时, 相比 $L_p=16$ , NMSE最大降低了13%。相比之下, 导频长度呈4倍增加时, 估计精度的升高效率却几乎没有变化, 甚至当 $L_p=64$ 时, 在高信噪比30 dB情况下, 估计精度变化趋势略有降低。NMSE的变化趋势说明本文设计的深度学习网络学习能力较强, 并不需要大量导频序列来提供更多的CSI信息, 即可达到较高的信道估计精度。在图8(b)中的中低信噪比条件下, 导频长度越大, BER越低。当 $L_p=64$ 时, 相比 $L_p=4$ , BER最大降低了78%, 但当处于高信噪比区域25~30 dB时, 上述规律不成立。



(a) NMSE与SNR之间的关系



(b) BER与SNR之间的关系

图8 不同导频长度CGO-Adam-CGAN-LSTM网络信道估计性能分析

当BS的MIMO系统部署大量发送和接收天线时, 本文所提CGO-Adam-CGAN-LSTM网络信道估计方法仍然保持良好的性能。从图9中可以看到, 当 $L_p=4、8$ 和16, SNR=20 dB, BS天线数量从64条增加到256条时, 本文所提信道估计方法NMSE值略有增加, 但仍保持在-30 dB左右。另外, 单独将 $L_p=64$ 的OMP算法与本文方法比较时可以看到, 基于深度学习的信道估计方法优势明显。




图9 不同导频长度信道估计NMSE和BS天线数之间的关系

图10为CGO-Adam-CGAN-LSTM网络信道估计在不同列车速度下的BER性能随SNR变化的对比结果。仿真结果表明, 在任意SNR下, CGO-Adam-CGAN-LSTM网络信道估计在列车速度分别为60 km/h、120 km/h和240 km/h的BER性能差距几乎可以忽略。




图10 不同列车速度CGO-Adam-CGAN-LSTM网络信道估计BER与SNR之间的关系

### 4.3 复杂度分析

表3对本文所提方法与传统信道估计方法的复杂度进行了对比,采用每秒浮点运算次数(FLOPS, floating point operations per second)进行量化,CGAN-LSTM网络复杂度影响参数较多,故用FLOPS直接估算表示。结合图6的估计精度,本文所提方法展现出高效性,但在模型轻量化方面仍有提升空间。

表3 本文方法与传统信道估计方法复杂度对比

信道估计方法	复杂度	FLOPS
CGAN-LSTM	—	$10^6 \sim 10^7$
LS	$O((NM)^2)$	$10^5$
MMSE	$O((NM)^3)$	$10^8$
OMP	$O(N_r^3) + O(N_r^2(NM)) + O(N_r(NM)^2)$	$10^6$

本文采用MATLAB对系统建模,Python IDE Pycharm完成信道估计方法实现。图7中深度学习模型均是基于Pytorch框架开发,表4中利用torchsummary工具对深度学习模型的参数量和占用内存资源进行计算。Transformer的复杂度通常高于CGAN-LSTM,尤其是在OTFS信道数据处理这样的长序列任务中,其自注意力机制的计算复杂度随序列长度呈平方增长。

表4 不同深度学习模型的参数量和占用内存对比

深度学习模型	参数量	占用内存/MB
CGAN-LSTM	857 544	4.79
CNN	238 156	2.01
CGAN	507 291	3.25
Transformer	1 100 347	6.56

## 5 结束语

本文建立城轨车-地场景下的OTFS-ISAC系统模型,对ISAC信号传输信道估计进行研究。为了实现信道的高效准确估计,提出了一种基于深度学习框架的信道估计方法,设计了CGAN-LSTM网络,将复杂的信道估计问题转换为图像处理问题,然后利用CGO与Adam优化器结合的优化算法对CGAN-LSTM网络参数进行优化,平衡梯度影响,提升模型训练效果和泛化能力。最后建立评价指标,将本文信道估计方法与LS、MMSE、OMP

等传统OTFS系统信道估计方法和其他深度学习模型信道估计方法进行比较。仿真结果表明,本文所提CGO-Adam-CGAN-LSTM网络信道估计性能优于传统信道估计方法和其他深度学习模型估计方法,且模型受系统天线数、导频长度等因素影响较小,具有较好的鲁棒性和稳定性,该方法适用于基于OTFS实现的ISAC系统的信道估计和信号检测。

### 参考文献:

- [1] 未来移动通信论坛. 6G智能轨道交通白皮书[Z]. 2022. Future Mobile Communication Forum. 6G intelligent rail transit white paper[Z]. 2022.
- [2] 杨杰,黄艺璇,杜涛,等. 通信感知一体化原型验证的研究现状与发展趋势[J]. 通信学报, 2023, 44(11): 43-54. YANG J, HUANG Y X, DU T, et al. Prototype verification for integrated sensing and communications: current status and development trends[J]. Journal on Communications, 2023, 44(11): 43-54.
- [3] 朱洛言,何丹萍,钟章队,等. 雷达通信一体化在智能铁路中的应用[J]. 中国铁路, 2021(1): 17-24. ZHU L Y, HE D P, ZHONG Z D, et al. Application of radar communication integration in intelligent railway[J]. China Railway, 2021(1): 17-24.
- [4] 中国通信学会. 通感算一体化网络前沿报告[R]. 2022. China Institute of Communication. Advanced report on network of communication-sensing-computing integration[R]. 2022.
- [5] KOBAYASHI M, CAIRE G, KRAMER G. Joint state sensing and communication: optimal tradeoff for a memoryless case[C]//Proceedings of the 2018 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE Press, 2018: 111-115.
- [6] 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.
- [7] WEI Z Q, LI S Y, YUAN W J, et al. Orthogonal time frequency space modulation: part I: fundamentals and challenges ahead[J]. IEEE Communications Letters, 2023, 27(1): 4-8.
- [8] LI S Y, YUAN W J, WEI Z Q, et al. Orthogonal time frequency space modulation: part II: transceiver designs[J]. IEEE Communications Letters, 2023, 27(1): 9-13.
- [9] YUAN W J, WEI Z Q, LI S Y, et al. Orthogonal time frequency space modulation: part III: ISAC and potential applications[J]. IEEE Communications Letters, 2023, 27(1): 14-18.
- [10] KHAN I A, MOHAMMED S K. A low-complexity OTFS channel estimation method for fractional delay-doppler scenarios[J]. IEEE Wireless Communications Letters, 2023, 12(9): 1484-1488.
- [11] YUAN W J, LI S Y, WEI Z Q, et al. Data-aided channel estimation for OTFS systems with a superimposed pilot and data transmission scheme[J]. IEEE Wireless Communications Letters, 2021, 10(9): 1954-1958.
- [12] ZHANG Z Y, HE R S, AI B, et al. A general channel model for integrated sensing and communication scenarios[J]. IEEE Communications Magazine, 2023, 61(5): 68-74.

- [13] ZHANG B X, MA S B, LIANG W, et al. ISAC-assisted OTFS communication in vehicle networks[C]//Proceedings of the 2023 International Conference on Ubiquitous Communication (Ucom). Piscataway: IEEE Press, 2023: 7-11.
- [14] LIU Y, AL-NAHHALI, DOBRE O A, et al. Deep-learning channel estimation for IRS-assisted integrated sensing and communication system[J]. IEEE Transactions on Vehicular Technology, 2023, 72(5): 6181-6193.
- [15] YANG Y, LI Y, ZHANG W X, et al. Generative-adversarial-network-based wireless channel modeling: challenges and opportunities[J]. IEEE Communications Magazine, 2019, 57(3): 22-27.
- [16] GABRIÉ M, MANOEL A, LUNEAU C, et al. Entropy and mutual information in models of deep neural networks[C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems. New York: ACM Press, 2018: 1826-1836.
- [17] AYDOGDU C, KESKIN M F, CARVAJAL G K, et al. Radar interference mitigation for automated driving: exploring proactive strategies[J]. IEEE Signal Processing Magazine, 2020, 37(4): 72-84.
- [18] SHI J D, SUN Y N, SU H T, et al. Risk-taking behavior of drilling workers: a study based on the structural equation model[J]. International Journal of Industrial Ergonomics, 2021, 86: 103219.
- [19] WANG Z M, QIAO D S, YAN J, et al. A new approach to predict dynamic mooring tension using LSTM neural network based on responses of floating structure[J]. Ocean Engineering, 2022, 249: 110905.
- [20] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. arXiv Preprint, arXiv: 1406.2661, 2014.
- [21] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. arXiv Preprint, arXiv: 1411.1784, 2014.
- [22] ISOLA P, ZHU J Y, ZHOU T H, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 5967-5976.
- [23] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Berlin: Springer, 2015: 234-241.
- [24] VAN HOUTD G, MOSQUERA C, NÁPOLES G. A review on the long short-term memory model[J]. Artificial Intelligence Review, 2020, 53(8): 5929-5955.
- [25] TALATAHARI S, AZIZI M. Chaos game optimization: a novel meta-heuristic algorithm[J]. Artificial Intelligence Review, 2021, 54(2): 917-1004.
- [26] MAHMOOD K, ASAD S M, SAEED O B, et al. Rayleigh fading channel estimation using MMSE estimator for MIMO-CDMA system[C]//Proceedings of the 2015 International Conference on Communications, Signal Processing, and their Applications (ICCSPA'15). Piscataway: IEEE Press, 2015: 1-4.
- [27] RAMEZANI-KEBRYA A, KHISTI A, LIANG B. On the generalization of stochastic gradient descent with momentum[J]. Journal of Machine Learning Research, 2024, 25(22):1-56.
- [28] KINGMA D P, BA J, HAMMAD M M. Adam: a method for stochastic optimization[J]. arXiv Preprint, arXiv: 1412.6980, 2014.
- [29] DAS S S, RANGAMGARI V, TIWARI S, et al. Time domain channel estimation and equalization of CP-OTFS under multiple fractional dopplers and residual synchronization errors[J]. IEEE Access, 2020, 9: 10561-10576.
- [30] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. IEEE Communications Letters, 2019, 23(4): 652-655.
- [31] CHUN C J, KANG J M, KIM I M. Deep learning-based channel estimation for massive MIMO systems[J]. IEEE Wireless Communications Letters, 2019, 8(4): 1228-1231.
- [32] CHEN Z L, GU F L, JIANG R. Channel estimation method based on transformer in high dynamic environment[C]//Proceedings of the 2020 International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2020: 817-822.

## [作者简介]



杨骞 (1987-), 男, 甘肃兰州人, 兰州交通大学博士生、兰州工业学院讲师, 主要研究方向为通信感知一体化技术、交通信息工程及控制技术。



苏宏升 (1969-), 男, 甘肃靖远人, 博士, 兰州交通大学教授、博士生导师, 主要研究方向为智能控制与模式识别。



陶旺林 (1985-), 女, 甘肃白银人, 兰州交通大学博士生、中国移动通信集团甘肃有限公司工程师, 主要研究方向为通信感知一体化技术。



刘大为 (1977-), 男, 黑龙江哈尔滨人, 博士, 兰州工业学院副教授, 主要研究方向为交通流建模、交通控制。