

# 面向大语言模型协作感知的海域通信抗干扰

刘欢欢<sup>1</sup>, 肖 亮<sup>1\*</sup>, 林蔚祺<sup>1</sup>, 张朋丽<sup>1</sup>, 陈灏宇<sup>2</sup>, 陈宏毅<sup>2</sup>, 汤中卫<sup>1</sup>

(1. 厦门大学信息学院, 福建厦门 361102; 2. 厦门大学人工智能研究院, 福建厦门 361105)

**摘要:** 海域恶劣无线信道和干扰攻击增加了感知数据和反馈信息的传输难度, 进而降低了协作感知性能。为支撑基于大语言模型的协作感知和目标识别任务, 海域通信需为文本、图像、视频和点云等多模态数据提供高可靠传输, 满足多样化服务质量需求。为此, 提出面向大语言模型协作感知的海域通信抗干扰技术, 除了数据量、信道增益和历史性能外, 进一步利用大语言模型根据接收到的多模态数据和文本提示词推断生成的通信环境, 以及频谱感知获取的干扰特征, 联合优化传输功率、信道和模型选择, 在恶劣信道下防御干扰攻击和通信干扰, 支撑基于多模态数据的协作感知。针对恶劣海域信道导致的反馈延迟或丢失问题, 设计反馈恢复机制, 提升多模态数据传输质量。建立海域通信抗干扰博弈模型, 刻画海域终端和干扰机间的交互机理, 分析纳什均衡点存在条件并给出通感性能界限, 揭示模态数量和信道状态等参数对性能的影响。基于 WaterScenes 数据集和 LLaVA 等大语言模型的仿真结果表明, 在防御基于 Q 学习的智能干扰机时, 所提方案相较于对比方案可提升 13.6% 的感知精度, 降低 66.2% 的通信能耗和 21.7% 的时延。

**关键词:** 海域通信; 多模态; 协作感知; 大语言模型; 抗干扰; 智能通信

**基金项目:** 国家自然科学基金(No.U25A20388); 中央高校基本科研业务费专项资金资助(No.20720250036); 国家重点研发计划(No.2023YFB3107603)

中图分类号: TN92

文献标识码: A

文章编号: 0372-2112(2026)03-1252-11

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250620

## Anti-Jamming Maritime Communications for LLM-Assisted Collaborative Perception

LIU Huanhuan<sup>1</sup>, XIAO Liang<sup>1\*</sup>, LIN Weiqi<sup>1</sup>, ZHANG Pengli<sup>1</sup>, CHEN Haoyu<sup>2</sup>,  
CHEN Hongyi<sup>2</sup>, TANG Zhongwei<sup>1</sup>

(1. School of Infomatics, Xiamen University, Xiamen, Fujian 361102, China;

2. Institute of Artificial Intelligence, Xiamen University, Xiamen, Fujian 361105, China)

**Abstract:** Harsh maritime wireless channels and jamming attacks increase the transmission difficulty of sensing data and feedback information, thereby degrading collaborative perception performance. To support large language model (LLM)-assisted collaborative perception and object detection, maritime communications must provide highly reliable transmission for multi-modal data such as text, images, videos and point clouds to meet diverse quality-of-service requirements. In this paper, we propose an anti-jamming maritime communications scheme for LLM-assisted collaborative perception. Besides the data size, channel gain, and historical performance, the communication environment extracted by LLM based on received multi-modal data and prompt, as well as jamming features obtained via spectrum sensing, are further used to optimize the transmit power, channel and LLM selection for transmitting the multi-modal data to support collaborative perception against jamming and interference under harsh channel conditions. A feedback recovery mechanism is designed to address delayed feedback or loss caused by harsh maritime channels and improve the reliability of multi-modal data transmission. The interaction between maritime terminals and the jammer is formulated as the maritime anti-jamming game and the upper bound in terms of communication and perception performance is provided based on the Nash equilibrium to show the impact of the number of modalities and channel states. Simulation results based on the WaterScenes dataset and LLMs such as LLaVA show the performance gain of our proposed scheme with 13.6% higher perception accuracy, 66.2% lower communication energy consumption and 21.7% less latency over benchmarks against the Q-learning-based smart jammer.

**Keywords:** maritime communications; multi-modal; collaborative perception; large language model; anti-jamming; intelligent communications

**Foundation Item(s):** National Natural Science Foundation of China (No.U25A20388); Fundamental Research Funds for the Central Universities (No.20720250036); National Key Research and Development Program of China (No.2023YFB3107603)

## 0 引言

随着智慧海洋的发展,终端可集成摄像头和激光雷达等多种传感器,获取语音、图像、视频、红外和点云等互补的多模态数据,并与计算和存储资源充足的控制中心协作,增强对环境的态势感知,以支撑环境监测和海上搜救等任务<sup>[1]</sup>。由于多模态数据在时空表征和语义表达方面存在异构性,且数据量显著增长,可部署 Flamingo、LLaVA 和 NExT-GPT 等大语言模型,利用其上下文理解和跨模态推理能力,实现高精度目标识别<sup>[2]</sup>。

然而,受到海面反射、波动起伏和降雨风暴等极端气象条件的影响,信道条件恶劣多变,终端易受到快变恶意干扰攻击,降低感知和反馈信息传输可靠性,劣化通感性能,导致任务失败和设备失控等后果。另外,在业务密集区域,浮标、终端、无人机和无人艇等设备竞争频谱资源激烈,通信干扰严重,进一步影响海域通感性能<sup>[3]</sup>。

基于强化学习的无线抗干扰方案根据终端位置、信道状态和数据特征等信息,优化传输功率、信道和中继节点,抵御干扰攻击,提升信干噪比,降低能耗与时延<sup>[4-8]</sup>。例如,文献[6]中提出了一种单模态数据抗干扰无线通信方案,发射机根据功率谱密度采用双重动作网络选择功率和信道,抵御固定、扫频和随机干扰。然而,该方案在智能干扰攻击和海域恶劣信道下,感知数据和反馈信息易延迟或丢失,系统性能严重衰减,难以满足多模态业务服务质量需求。

本文提出了一种面向大语言模型协作感知的海域通信抗干扰技术,优化传输信道、功率和模型选择,抵御恶意干扰与通信干扰。根据各模态数据量、大语言模型提取的通信环境特征、接收干扰强度和信道条件等信息,提高感知精度,降低通信能耗和时延。另外,为缓解恶劣海域信道导致的反馈延迟或丢失的问题,采用历史时隙效用的加权平均和偏差修正项,减少传输策略决策过程中价值估计误差,保证多模态数据可靠传输,支撑协作感知与海域目标识别。

建立海域通信抗干扰博弈模型以模拟建模终端与干扰机间交互过程。其中,终端选择发射功率、信道和控制中心侧运行的大语言模型,以更低的通信能耗和时延提高感知精度;干扰机选择干扰功率,以最小化控制中心端接收信干噪比。依据纳什均衡给出时延、通信能耗和感知精度的性能界限,揭示信道增益、控制中心计算能力和模态数等因素对通感性能的影响。另外,分析所提方案的计算复杂度,结果表明其随大语言模型数量、量化功率电平和可选信道数线性增加。

仿真评估了7个终端抵御基于Q学习调节干扰功率和中心频率的智能干扰机的通感性能增益。终端以最高100 mW功率在2.4 GHz的6个可用信道上将WaterScenes数据集<sup>[9]</sup>中200 KB文本与图像发送至搭载多种LLaVA<sup>[10]</sup>轻量化模型的控制中心,在文本提示词的驱动下感知通信环境与船只等目标。仿真结果表明,相较于无线智能抗干扰方案DAS<sup>[6]</sup>(Distributed Antenna System)和TLS<sup>[7]</sup>(Transport Layer Security)分别提升了13.6%和16.5%的感知精度,降低了66.2%和69.8%的通信能耗以及21.7%和24.2%的时延。

## 1 相关工作

船只和无人机等终端可根据信道条件、数据特征和计算资源等信息,优化发射功率,提高通信安全和服务质量<sup>[4-5,11-13]</sup>。例如,文献[4]提出高效海域通信方案,基于信道状态信息优化发射功率和传输与能量收集的时间分配,抵御随机功率干扰。文献[5]提出海域抗干扰通信方案,无人机基于自身位置、接收信号功率和干扰强度等信息,采用对决网络优化向船只传输海域消息的发射功率,降低通信能耗和误码率,抵御智能干扰。文献[11]提出无人机辅助海上安全通信系统,采用迭代算法优化船只轨迹和无人机干扰功率,抵御窃听者。文献[12]提出海域智能数据传输方案,节点根据数据量大小、任务级别和信道增益,优化计算资源分配和发射功率,降低任务传输时延。文献[13]提出海上协作搜救网络,根据无人机和船只位置和信干噪比,采用多智能体强化学习优化发射功率和轨迹,以最短路径实现目标探测,提升网络吞吐量。

优化信道选择,躲避强干扰区域,提高通信可靠性和频谱利用率<sup>[7-8,14-16]</sup>。文献[7]提出无线抗干扰方案,接入点根据信道状态和从周边设备迁移的干扰行为,加速优化传输信道,提升扫频干扰和随机干扰下的成功传输次数。文献[8]提出动态频谱抗干扰方案,接收机根据频谱瀑布图优化跳频策略并反馈至发射机,提高信干噪比,对抗扫频干扰、组合干扰和智能干扰等。文献[14]提出基于相似性样本的智能无线抗干扰技术,无线接收机根据可选信道的平均接收功率优化通信信道和数据速率,并利用状态动作对间的相似性加快算法收敛,防御多路扫频干扰和阻塞干扰,提高归一化吞吐量。文献[15]提出软件定义的海上通信架构,控制器根据信道状态和缓存状态,统一调度中继节点和信道分配,降低传输时延,节省传输成本与能耗,满足多媒体应用需求。文献[16]提出自适应抗干扰扩频通信技术,接收端采用快速傅里叶变

换检测干扰强度和类型,优化频域点选择,降低误码率,提升对阻塞式干扰的适应性。

大语言模型中可训练参数量呈指数级增长,可通过模型压缩、语言架构调整或减少标记数等方法,降低资源占用,提高计算效率<sup>[17-21]</sup>。例如,文献[17]根据注意力分数的稀疏分布度量每个标记的重要性,自适应选择重要标记,减少空间冗余。文献[18]采用专家混合机制,稀疏激活模型参数,降低计算成本。文献[19]则通过集成参数更小的语言模型,以提升模型的泛化能力和部署灵活性。文献[20]从视觉编码器、连接模块和语言模型选择及训练优化等多个维度,探索轻量化设计对多模态大语言模型性能的影响。文献[21]提出云边协同大模型块重训方法,采用大模型重训缩放定律,结合动态输入数据分布和可用资源情况,评估不同模型块对感知精度的贡献,并通过启发式算法快速搜索最优重训方案生成用于协同训练的小模型。

## 2 系统模型

本节介绍面向大语言模型协作感知的海域通信的网络模型、干扰模型和问题建模。

### 2.1 网络模型

如图1所示的海域无线通信中,在时隙 $k$ ,船只或无人机等终端位于 $\mathbf{L}^{(k)} \in \mathbb{R}^{3 \times 3}$ 搭载温湿度传感器、摄像头和激光雷达等设备,在固定高度的二维平面内以速度 $\mathbf{v}^{(k)} \in [0, V]$ 和方向 $\theta^{(k)} \in [0, 2\pi]$ 移动,采集由文本、音频、图像、视频和雷达点云等 $U$ 种模态组成的多模态海域数据 $\mathbf{x}^{(k)} = [x_{1 \leq i \leq U}^{(k)}]$ ,实现互补传感<sup>[1]</sup>。例如,图像中包含丰富的语义信息,雷达可在恶劣光照与天气条件下提供有关物体的距离、速度和方位角的信息。




图1 面向大语言模型协作感知的海域通信示意图

Figure 1 Illustration of maritime communications for LLM-assisted collaborative perception

终端评估各模态的数据量 $\mathbf{z}^{(k)} = [z_{1 \leq i \leq U}^{(k)}]$ 和信息量 $\mathbf{t}^{(k)} = [t_{1 \leq i \leq U}^{(k)}]$ <sup>[22]</sup>,使用导频信号估算与控制中心间的信道增益 $h^{(k)}$ 并估计通信能耗 $\zeta^{(k)}$ 。其中,各模态的数据量存在量级差异,如文本的数据量通常为字节级,而图像的数据量可达到数百千字节。

由于多模态数据的异构性和增长的数据量,将其

与选择的大语言模型编号打包成如图2所示的数据帧,其中每个终端传输上行消息并接收来自控制中心的下行反馈。以功率 $a_1^{(k)} \in [0, P]$ 在带宽 $B$ 的信道 $a_2^{(k)} \in \{1, 2, \dots, F\}$ 上传输至控制中心处理,降低本地计算负载,实现协作感知。大语言模型处理多模态数据的性能与可训练参数量之间呈正相关幂律关系,但计算和存储资源需求也随之增加<sup>[21]</sup>。以 Google DeepMind 发布的 Flamingo 为例,它拥有 800 亿个参数,在半精度浮点数据格式下需要 160 GB 的存储空间。因此,可采用模型压缩(如权重剪枝与量化)、架构调整(如缩小语言模型与专家混合稀疏化)和减少标记数等方法,构建 $M$ 种轻量化大语言模型 $a_3^{(k)} \in \{1, 2, \dots, M\}$ ,平衡感知性能与资源消耗<sup>[23]</sup>。其中,终端侧可部署资源占用最小的大语言模型,在高功率干扰和恶劣信道条件下本地执行目标识别任务。




图2 海域无线通信协议的帧格式

Figure 2 Frame format of maritime wireless communication protocol

在接收到终端发来的上行信息后,控制中心调用大语言模型 $a_3^{(k)}$ ,在文本提示词驱动下生成感知结果 $\mathbf{R}^{(k)}$ ,包括室内外、降雨和风暴等环境特征 $\mathbf{v}^{(k)} = [v_{1 \leq i \leq C}^{(k)}]$ 以及船只、码头和人员等目标类别 $\chi^{(k)} = [\chi_{1 \leq i \leq D}^{(k)}]$ 。具体来说,输入的多模态数据首先通过各自的编码器转化为特征向量,例如采用视觉编码器 ViT-L/14 提取图像特征,采用基于字节对编码的分词器将文本转化为词元。随后,利用多层感知机等投影器将各模态特征向量统一映射到文本嵌入空间,实现跨模态对齐,并得到对应的模态词元。各模态词元经过向量拼接后输入到包含多头自注意力模块和前馈神经网络的多层 Transformer 架构,提取语义相关性并通过自回归解码生成感知结果 $\mathbf{R}^{(k)}$ <sup>[24]</sup>。

另外,控制中心采用软件无线电设备通过频谱感知技术测量 $J$ 种干扰特征 $\lambda^{(k)} \in [\lambda_{1 \leq i \leq J}^{(k)}]$ ,如被干扰信道和接收干扰强度等,并评估信干噪比 $\mu^{(k)}$ 、感知精度 $\rho^{(k)}$ 、时延 $t^{(k)}$ (包括传输时延 $\tau^{(k)}$ 和推断时延 $\tilde{\tau}^{(k)}$ )和感知速度 $v^{(k)} = 1/t^{(k)}$ 。大语言模型输出的感知结果 $\mathbf{R}^{(k)}$ 与上述通感性能在控制信道上被共同反馈给终端,辅助多模态数据传输策略优化,提升通感业务的服务质量。

传输时延与推断时延基于网络时间协议同步时间戳进行测量。感知速度定义为系统完成一次感知

任务的总时延(包括传输时延和推断时延)的倒数。感知精度是指控制中心侧感知船只、码头和人员等海域目标的准确性。根据文献[25],置信度分数可在基于文本、图像和视频等多模态感知数据开展目标识别等场景中,估计感知结果正确的概率,因此借助置信度分数对感知精度进行实时评估,适应动态变化的海域环境。另外,可采用混合式人机协作方法<sup>[26]</sup>优化大语言模型输出的感知结果,用户依据自身偏好对若干候选结果进行初步评价(如“好”或“坏”),引导大语言模型构建输出标准,并根据实际需求对其进行修改、删除、确认或补充,以满足多样化感知任务。

## 2.2 干扰模型

恶意干扰机可采用能量检测技术监听信道传输状态  $\zeta^{(k)}$ (存在通信活动时  $\zeta^{(k)}=1$ , 否则为 0), 并发射干扰信号, 恶意中断控制中心与终端间的合法通信链路, 降低多模态数据传输可靠性, 严重时引发感知任务失败和设备失控等。智能干扰机配备如通用软件无线电外设等可编程设备, 动态调整干扰策略  $y^{(k)}=[y_1^{(k)}, y_2^{(k)}]$ 。例如, 基于传输状态  $\zeta^{(k)}$  和到控制中心的信道增益  $g^{(k)}$  等信息, 采用 Q 学习等强化学习算法, 持续优化发射功率  $y_1^{(k)} \in [\underline{Y}, \bar{Y}]$  和中心频率  $y_2^{(k)} \in [f_1, f_2]$ , 以较低成本最大化干扰攻击能力。

另外, 当  $W$  个邻近终端  $\mathcal{W}=\{1, 2, \dots, W\}$  传输数据时, 容易与当前终端发生频谱冲突。为此, 引入干扰级别  $I$  量化当前终端遭受的通信干扰, 与相邻设备的发射功率  $p_j^{(k)}$ 、与控制中心的信道增益  $h_j^{(k)}$  和处于相同信道  $\omega_j^{(k)} \in \{0, 1\}$  相关, 可表示为

$$I^{(k)} = \sum_{j=1}^W \omega_j^{(k)} p_j^{(k)} h_j^{(k)} \quad (1)$$

恶意干扰和通信干扰的影响均作用于信干噪比  $\mu^{(k)}$ , 即  $\mu^{(k)} = ph/(\sigma + yg + I)$ , 从而劣化感知精度、时延和通信能耗等性能。为了避免混淆, 下面将省略上标  $k$ 。重要的符号如表 1 所示。

## 2.3 问题建模

终端选择传输功率  $a_1$ 、信道  $a_2$  和控制中心端运行的大语言模型  $a_3$  以最大化由感知精度  $\rho$ 、时延  $t$  和通信能耗  $\zeta$  加权构成的长期累计效用:

$$\max \mathbb{E}_{a_1^{(k)}, a_2^{(k)}, a_3^{(k)}} \left[ \sum_{n=k}^{\infty} \gamma^{n-k} (\rho^{(n)} - \omega_0 t^{(n)} - \omega_1 \zeta^{(n)}) \right] \quad (2)$$

$$\text{s.t. } a_1^{(k)} \in [0, P] \quad (3)$$

$$a_2^{(k)} \in \{1, 2, \dots, F\} \quad (4)$$

$$a_3^{(k)} \in \{1, 2, \dots, M\} \quad (5)$$

其中,  $\gamma$  是折扣因子, 用来衡量即时效用和未来效用的重要性; 终端在每时隙的感知精度  $\rho$ 、时延  $t$  与通信

表 1 重要符号列表

Table 1 List of important symbols

符号	含义
$U$	模态数
$\mathbf{x}^{(k)} = [x_{1 \leq i \leq U}^{(k)}]$	$k$ 时隙获取的多模态数据
$z_i^{(k)}$	各模态数据量
$i_i^{(k)}$	各模态信息量
$h^{(k)}$	终端与控制中心间信道增益
$\mu^{(k)}$	信干噪比
$\zeta^{(k)}$	通信能耗
$\rho^{(k)}$	感知精度
$v^{(k)}$	感知速度
$t^{(k)}$	时延
$\lambda^{(k)} \in [\lambda_{1 \leq i \leq J}^{(k)}]$	干扰特征
$\mathbf{v}^{(k)} \in [v_{1 \leq i \leq C}^{(k)}]$	环境特征
$\chi^{(k)} \in [\chi_{1 \leq i \leq D}^{(k)}]$	目标类别
$a_1^{(k)}$	终端上行传输功率
$a_2^{(k)}$	终端-控制中心传输信道
$a_3^{(k)}$	控制中心搭载的大语言模型
$y_1^{(k)}$	干扰功率
$y_2^{(k)}$	干扰频率

能耗  $\zeta$  均随信干噪比  $\mu$  的变化而波动, 而该信干噪比  $\mu$  依赖于干扰模型、与控制中心的信道增益和周边设备的传输状态, 用于反映当前海域信道条件及混合干扰下的通信质量。

由于下一时隙的感知精度和速度等状态信息仅取决于当前状态和传输策略, 而独立于历史状态和策略, 终端重复性抗干扰决策可建模为马尔可夫决策过程。然而, 在恶劣多变的海域动态环境下, 难以准确且及时地获取干扰特征和信道增益。为此, 本文设计无需先验知识的强化学习算法, 通过与环境交互和试错机制, 逐步学习到最优多模态感知数据抗干扰传输策略。

## 3 面向大语言模型协作感知的海域通信抗干扰技术

本节提出了一种面向大语言模型协作感知的海域通信抗干扰方案(后文简称“RMMA”), 可靠传输文本、图像、视频和点云等多模态数据至控制中心, 识别海域环境特征和船只等目标, 如图 3 所示。根据数据特征、接收干扰功率等干扰特征和大语言模型提取的环境特征, 终端采用基于最大熵的 Soft Actor-Critic 强化学习算法, 优化传输功率、信道和模型选择, 提升由感知精度、时延和通信能耗加权和构成的抗干扰效用, 具体算法流程如算法 1 所示。针对恶劣海域信道条件下通感性能反馈延时或丢失的问题, 设计反馈恢复机制, 提升多模态数据传输质量, 以支撑大语言

模型辅助的协作感知任务。




图3 面向大语言模型协作感知的海域通信抗干扰方案

Figure 3 Illustration of anti-jamming maritime communications for LLM-assisted collaborative perception

#### 算法1 面向大语言模型协作感知的海域通信抗干扰

1. 初始化  $\delta, \gamma, \phi, \psi$  和  $\mathcal{P} \neq \emptyset$
2. FOR  $k = 1, 2, \dots$  DO
3. 测量多模态数据量  $\mathbf{z}$  与信息量  $\boldsymbol{\mu}$ , 估计与控制中心信道状态  $h$ , 评估通信能耗  $\xi^{(k)}$
4. 根据式(6)构建  $\mathbf{s}^{(k)}$
5. 根据式(7)选择  $\mathbf{a}^{(k)}$
6. 以功率  $a_1^{(k)}$  在信道  $a_2^{(k)}$  上传输多模态数据  $\mathbf{x}^{(k)}$  至搭载大语言模型  $a_3^{(k)}$  的控制中心
7. 获得干扰特征  $\boldsymbol{\lambda}^{(k)}$ 、感知速度  $b^{(k)}$ 、感知精度  $\rho^{(k)}$ 、信噪比  $\mu^{(k)}$ 、时延  $t^{(k)}$  和感知结果  $\mathbf{R}^{(k)}$
8. 根据式(8)评估  $u^{(k)}$
9.  $\mathcal{P} \leftarrow \mathcal{P} \cup \mathbf{e}^{(k)}$
10. IF  $|\mathcal{P}| \geq D$  do
11. 均匀随机采样  $D$  条经验构成  $\mathcal{D}$
12. 根据式(10)~(12)更新  $\phi$  和  $\psi$
13. END IF
14. END FOR

在时隙  $k$ , 终端作为智能体获取多模态数据量  $\mathbf{z} = [\mathbf{z}_{1 \leq i \leq U}]$  和信息量  $\boldsymbol{\mu} = [\boldsymbol{\mu}_{1 \leq i \leq U}]$ , 评估与控制中心间的信道增益  $h$  和通信能耗  $\xi$ , 以及接收控制中心反馈的干扰特征  $\boldsymbol{\lambda}$ 、感知精度  $\rho$ 、感知速度  $v$ 、时延  $t$  和大语言模型提取的环境特征  $\mathbf{v}$ , 构成状态向量  $\mathbf{s}^{(k)}$ :

$$\mathbf{s}^{(k)} = [\mathbf{z}, \mathbf{I}, h, \boldsymbol{\lambda}, \zeta, \rho, v, t, \mathbf{v}] \quad (6)$$

根据当前状态  $\mathbf{s}^{(k)}$ 、权重为  $\phi$  的策略网络, 即 Actor 网络, 生成概率分布  $\pi(\mathbf{s}^{(k)}, \mathbf{a}'; \phi)$ , 选择海域多模态数据传输策略  $\mathbf{a}^{(k)} = [a_1, a_2, a_3]$ , 包括上行传输功率  $a_1^{(k)} \in \{IP/L | 1 \leq l \leq L\}$  和信道  $a_2^{(k)} \in \{1, 2, \dots, F\}$  以及控制中心端运行的大语言模型  $a_3^{(k)} \in \{1, 2, \dots, M\}$ , 即

$$\Pr(\mathbf{a}^{(k)} = \mathbf{a}') = \pi(\mathbf{s}^{(k)}, \mathbf{a}'; \phi) \quad (7)$$

终端以功率  $a_1$  在信道  $a_2$  上传输多模态数据  $\mathbf{x}$  至控制中心, 避免频谱冲突的同时对抗干扰攻击。在接收到上行消息后, 控制中心运行大语言模型  $a_3$  进行环境理解, 提取环境特征, 识别海域环境和船只等目标。为了权衡通感性能, 终端评估抗干扰通信即时效用  $u^{(k)}$ :

$$u^{(k)} = \rho - \omega_0 t - \omega_1 \xi \quad (8)$$

其中,  $\omega_0$  和  $\omega_1$  分别表示时延和通信能耗对即时效用的重要性。所提方案采用该即时效用更新式(2)定义的长期累积效用, 从而通过与环境交互和试错机制, 逐步学习到该优化目标的最优策略。

为了提升样本利用率并打破时间相关性, 引入了经验回放机制从历史经验池中随机抽取样本来更新神经网络权重参数。具体来说, 终端根据当前时隙状态  $\mathbf{s}^{(k)}$ 、策略  $\mathbf{a}^{(k)}$ 、即时效用  $u^{(k)}$  以及观测到的下一时隙状态  $\mathbf{s}^{(k+1)}$ , 构建海域多模态数据传输经验  $\mathbf{e}^{(k)} = \{\mathbf{s}^{(k)}, \mathbf{a}^{(k)}, u^{(k)}, \mathbf{s}^{(k+1)}\}$ , 并存储在经验池  $\mathcal{P}$  中, 即  $\mathcal{P} \leftarrow \mathcal{P} \cup \mathbf{e}^{(k)}$ 。

然而, 受海面反射、波动起伏和降雨风暴等因素影响, 信道条件恶劣, 导致感知精度、时延和通信能耗等性能延迟反馈或丢失, 在策略学习中存在价值估计偏差。为此, 引入反馈恢复机制, 避免选择导致传输可靠性降低的策略, 影响协作感知任务的准确性。具体而言, 若在当前时隙  $k$  未收到反馈, 则使用过去  $T$  个时隙的效用值的加权平均和偏差修正项填补当前经验  $\mathbf{e}^{(k)}$  中的即时效用  $u^{(k)}$  的空白, 减少累计误差, 即

$$\hat{u}^{(k)} = \frac{1}{T} \sum_{m=1}^T u^{(k-m)} - \hat{u}^{(k-m)} + \sigma^{(k-m)} u^{(k-m)} \quad (9)$$

其中, 权重因子  $\sigma$  根据状态相似度或历史通感性能动态调整。在训练过程中, 从经验池  $\mathcal{P}$  中随机均匀抽取  $D$  个经验构成小批量数据  $\mathcal{D}$  用于梯度更新, 加速收敛。

另外, 在目标函数中引入熵项, 利用温度参数  $\delta$  平衡策略探索与利用, 同步最大化期望累积效用与策略的熵。策略网络采用策略梯度方法, 优化目标函数以更新权重  $\phi$ , 如下:

$$\mathcal{L}(\phi) = \frac{1}{D} \sum_{i=1}^D [\delta \log(\pi(\tilde{\mathbf{s}}, \tilde{\mathbf{a}}; \phi)) - Q(\tilde{\mathbf{s}}, \tilde{\mathbf{a}}; \phi)] \quad (10)$$

Critic 网络作为价值网络, 以概率分布  $\pi$  为输入, 依据贝尔曼方程更新输出  $Q$  值, 指导多模态数据传输策略更新。采用最小化均方误差方法更新权重参数  $\phi$ , 如下:

$$\mathcal{L}(\phi) = \frac{1}{D} \sum_{i=1}^D [u + \gamma \hat{Q}(\tilde{\mathbf{s}}, \tilde{\mathbf{a}}; \psi) - \delta \log(\pi(\tilde{\mathbf{s}}, \tilde{\mathbf{a}}; \phi)) - Q(\tilde{\mathbf{s}}, \tilde{\mathbf{a}}; \phi)]^2 \quad (11)$$

其中,  $\hat{Q}$  是由目标网络输出的目标值, 用来提高恶劣海域环境下的训练稳定性。目标网络与价值网络结构相同, 它的权重  $\psi$  通过软更新方式进行更新, 即通过加权平均的方式以系数  $\varpi$  逐步靠近价值网络权重  $\phi$ :

$$\psi \leftarrow \varpi \psi + (1 - \varpi) \phi \quad (12)$$

## 4 理论分析

### 4.1 博弈模型

为了研究  $N$  个终端和干扰机间的交互作用, 本节

构建了海域通信抗干扰博弈模型,并根据纳什均衡给出了时延、通信能耗和感知精度的性能界限。其中,  $N$  个终端  $\mathcal{N}$  选择传输策略  $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3] \in \mathcal{A}$ , 以功率  $\mathbf{a}_1 = [a_{i,1}]_{i \in \mathcal{N}}$  在带宽为  $B$  的信道  $\mathbf{a}_2 = [a_{i,2}]_{i \in \mathcal{N}}$  向运行大语言模型  $\mathbf{a}_3 = [a_{i,3}]_{i \in \mathcal{N}}$  的控制中心发送由  $U$  种模态组成的  $Z_{i \in \mathcal{N}}$  字节的多模态数据, 以支撑海域协作感知任务。整体效用  $\bar{u}$  由感知精度  $\rho_i$ 、时延  $t_i$  (包括传输时延和推断时延) 和反映通信能耗  $\xi_i$  的发射功率  $a_{i,1}$  的加权和构成, 即

$$\bar{u} = \sum_{i=1}^N \rho_i - \varpi_0 t_i - \varpi_1 a_{i,1} \quad (13)$$

其中, 感知精度  $\rho_i$  随大语言模型  $a_{i,3}$  呈幂律增长, 并随信干噪比  $\mu_i = a_{i,1} h_i / (\sigma + y g + I_i)$  呈指数型饱和增长, 可建模为  $\rho_i = (L - \Delta \rho / a_{i,3}) (1 - \exp(-\mu_i))$ ,  $L$  为大语言模型  $M$  的最大感知精度,  $\Delta \rho$  表示模型 1 和  $M$  的最大感知精度差。传输时延与数据量、带宽和信干噪比有关, 可表示为  $\tau_i = Z_i / (B \log_2(1 + \mu_i))$ 。推断时延由数据量、大语言模型  $M$  的浮点运算数  $A$  和控制中心的计算能力  $\Gamma$  决定, 表示为  $\tilde{\tau}_i = Z_i a_{i,3} A / (M \Gamma)$ 。

因此, 式(13)可重新表示为

$$\bar{u} = \sum_{i=1}^N \left( L - \frac{\Delta \rho}{a_{i,3}} \right) (1 - \exp(-\mu_i)) - \varpi_0 Z_i \left( \frac{1}{B \log_2(1 + \mu_i)} + \frac{a_{i,3} A}{M \Gamma} \right) - \varpi_1 a_{i,1} \quad (14)$$

干扰机  $\mathcal{J}$  在传输信道上选择干扰功率  $y \in [0, P_j]$ , 以最小成本降低传输质量, 导致海域协作感知任务失败。干扰机效用为

$$u_j = \sum_{i=1}^N \frac{1}{\mu_i} - \varpi_2 y \quad (15)$$

因此, 海域通信抗干扰博弈可建模为

$$\mathcal{G} = \{ \{ \mathcal{N}, \mathcal{J} \}, \{ \mathcal{A}, [0, P_j] \}, \{ \bar{u}, u_j \} \} \quad (16)$$

若终端和干扰机达到纳什均衡点, 则双方均无法通过单方面改变策略获得更高的效用, 此时满足:

$$\begin{aligned} \bar{u}(\mathbf{A}^*, \mathbf{y}^*) &\geq \bar{u}(\mathbf{A}, \mathbf{y}^*), \forall \mathbf{A} \in \mathcal{A}, \\ u_j(\mathbf{A}^*, \mathbf{y}^*) &\geq u_j(\mathbf{A}^*, \mathbf{y}), \forall \mathbf{y} \in [0, P_j] \end{aligned} \quad (17)$$

**定理 1** 当多模态数据量、终端  $i$ -控制中心通信链路和控制中心-干扰机通信链路的信道状态满足:

$$\begin{aligned} B \hat{\mu}_i \left( \varpi_1 P - \left( L - \frac{\Delta \rho}{M} \right) \exp(-\hat{\mu}_i) \right) \\ \leq \varpi_0 Z_i \leq \frac{\Delta \rho (1 - \exp(-\hat{\mu}_i))}{\Lambda M} \end{aligned} \quad (18)$$

$$g \geq \varpi_2 P \sum_{i=1}^N h_i \quad (19)$$

所提海域通信抗干扰方案下终端  $i$  的时延、通信能耗和感知精度的性能界分别为

$$\hat{t}_i = \frac{Z_i}{B \log_2(1 + \hat{\mu}_i)} + \frac{Z_i A}{\Gamma} \quad (20)$$

$$\hat{\xi}_i = \frac{P Z_i}{B \log_2(1 + \hat{\mu}_i)} \quad (21)$$

$$\hat{\rho}_i = \left( L - \frac{\Delta \rho}{M} \right) (1 - \exp(-\hat{\mu}_i)) \quad (22)$$

其中,

$$\hat{\mu}_i = \frac{P h_i}{\sigma + P_j g} \quad (23)$$

**证明** 根据式(14)和(18),  $\forall a_{i,1} \in [0, P]$ ,  $\forall a_{i,2} \in \{1, 2, \dots, F\}$ ,  $\forall a_{i,3} \in \{1, 2, \dots, M\}$  和  $y \in [0, P_j]$ , 有

$$\begin{aligned} \bar{u}(\mathbf{A}^*, P_j) &= \sum_{i=1}^N \left( L - \frac{\Delta \rho}{M} \right) \left( 1 - \exp\left(-\frac{P h_i}{\sigma + P_j g}\right) \right) \\ &\quad - \varpi_0 Z_i \left[ \frac{1}{B \log_2\left(1 + \frac{P h_i}{\sigma + P_j g}\right)} + \frac{A}{\Gamma} \right] - \varpi_1 P \\ &\geq \sum_{i=1}^N \left( L - \frac{\Delta \rho}{a_{i,3}} \right) \left( 1 - \exp\left(-\frac{a_{i,1} h_i}{\sigma + P_j g + I_i}\right) \right) \\ &\quad - \varpi_0 Z_i \left[ \frac{1}{B \log_2\left(1 + \frac{a_{i,1} h_i}{\sigma + P_j g + I_i}\right)} + \frac{a_{i,3} A}{M \Gamma} \right] - \varpi_1 a_{i,1} \\ &= \bar{u}(\mathbf{A}, P_j) \end{aligned} \quad (24)$$

其中,  $\mathbf{A}^* = [P \cdot \mathbf{I}_N, [1, 2, \dots, N], M \cdot \mathbf{I}_N]$ 。

根据式(15),  $y \in [0, P_j]$ , 有

$$u_j(\mathbf{A}^*, y) = \sum_{i=1}^N \left( \frac{\sigma + y g}{P h_i} \right) - \varpi_2 y \quad (25)$$

当式(19)成立, 根据式(25), 有

$$\frac{\partial u_j(\mathbf{A}^*, y)}{\partial y} = \sum_{i=1}^N \frac{g}{P h_i} - \varpi_2 \geq 0 \quad (26)$$

因此, 有

$$u_j(\mathbf{A}^*, P_j) \geq u_j(\mathbf{A}^*, y) \quad (27)$$

根据式(24)和(27),  $([P \cdot \mathbf{I}_N, [1, 2, \dots, N], M \cdot \mathbf{I}_N], P_j)$  是博弈  $\mathcal{G}$  的纳什均衡点, 所提方案 RMMA 的性能界为式(20)~(22)。

证毕。

**推论 1** 终端  $i$  以最大功率  $P$  将  $U$  种模态共  $Z_i$  字

节的数据,发送到运行大语言模型  $M$  的控制中心,抵御以最大功率  $P_j$  发送干扰信号的干扰机,支撑海域协作感知任务。如图4所示,当传输数据量和信道状态满足式(18)和(19)中约束时,所提方案可收敛至式(20)~(22)所给出的通感性能界限。

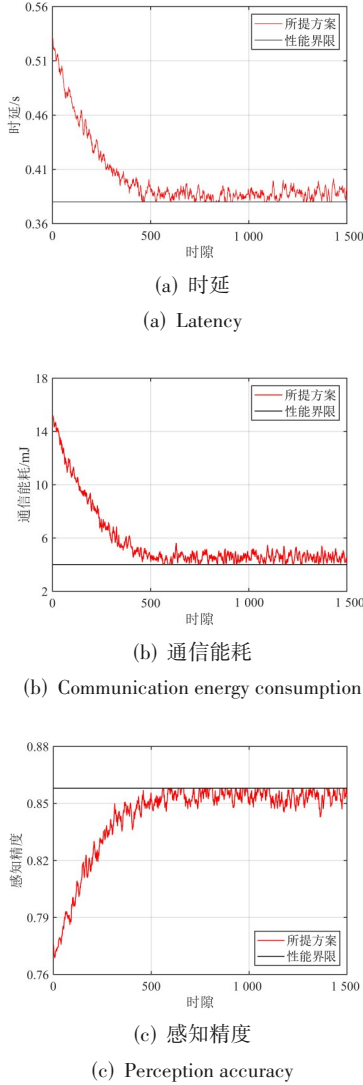


图4 所提海域通信抗干扰方案性能界限

Figure 4 Performance bound of the proposed anti-jamming maritime communication scheme

#### 4.2 计算复杂度

本节给出所提 RMMA 方案的计算复杂度  $\gamma$  主要取决于策略网络、价值网络和目标网络中的传输策略选择和权重更新的乘法次数。

策略网络由一个维度为  $\varepsilon = 2U + C + J + 5$  的输入层,两个分别包含  $c_1$  和  $c_2$  个节点的隐藏层,以及一个维度为  $MLF$  的输出层构成。根据文献[27],隐藏层神经元数取决于输出层维度  $MLF$  和学习样本数  $K$ ,即

$c_1 = \sqrt{KMLF} + 2\sqrt{K/(MLF)}$ ,  $c_2 = \sqrt{KMLF}$ 。输出维度由可选的功率级别、大语言模型数量以及可用信道数共同决定。价值和目标网络的网络结构相同,均由四个全连接层构成,分别包含  $\varepsilon + MLF$ 、 $d_1$ 、 $d_2$  和一个节点,其中  $d_1 = 3\sqrt{K}$  和  $d_2 = \sqrt{K}$ 。

在策略选择过程中,策略网络执行前向传播包括  $l_{A,F}$  乘法运算,即

$$l_{A,F} = \varepsilon c_1 + (c_1 + 1)c_2 + (c_2 + 1)MLF \quad (28)$$

更新权重  $\phi$  时,策略网络在前向和后向传播中分别执行  $l_{A,F}$  和  $l_{A,B}$  次乘法,价值网络额外在前向传播中执行  $l_{C,F}$  次乘法,即

$$l_{A,B} = 2\varepsilon c_1 + 3(c_1 + 1)c_2 + 3(c_2 + 1)MLF \quad (29)$$

$$l_{C,F} = (\varepsilon + MLF)d_1 + (d_1 + 1)d_2 + d_2 + 1 \quad (30)$$

权重  $\phi$  更新时,策略网络、价值网络和目标网络在前向传播中分别执行  $l_{A,F}$ 、 $l_{C,F}$  和  $l_{C,B}$  次乘法。除此之外,价值网络在后向传播中执行  $l_{C,B}$  次乘法,即

$$l_{C,B} = 2(\varepsilon + MLF)d_1 + 3(d_1 + 1)d_2 + 3(d_2 + 1) \quad (31)$$

RMMA 在每个时隙从经验池中抽取  $D$  条经验来更新网络权重,因此策略选择和权重更新中涉及的总乘法次数为  $l_T$ ,可表示为

$$l_T = (2D + 1)l_{A,F} + Dl_{A,B} + 3Dl_{C,F} + Dl_{C,B} \quad (32)$$

**定理2** 所提海域通信抗干扰方案 RMMA 的计算复杂度为  $O(DKMLF)$ 。

**证明** 根据式(28)~(32),RMMA 计算复杂度为

$$\begin{aligned} \gamma &= O\left((4D + 1)\varepsilon c_1 + (4D + 1)(c_1 + 1)c_2 \right. \\ &\quad \left. + (5D + 1)(c_2 + 1)MLF + 5D(\varepsilon + MLF)d_1 \right. \\ &\quad \left. + 5D(d_1 + 1)d_2 + 6D(d_2 + 1)\right) \\ &= O\left(D\varepsilon\sqrt{KMLF} + DKMLF + DMLF\sqrt{KMLF}\right) \end{aligned} \quad (33)$$

由于  $K \gg MLF \gg \varepsilon$ ,得  $\gamma = O(DKMLF)$ 。

证毕。

**推论2** RMMA 的计算复杂度  $\gamma$  随大语言模型数量  $M$ 、量化功率级别  $L$ 、可选信道数  $F$ 、批量大小  $D$  和学习样本数  $K$  线性增加。

#### 5 仿真分析

本节基于开源的 Python 平台和 MATLAB 等工具,搭建海域通信抗干扰仿真平台,评估7个终端在所提海域智能抗干扰方案下的通感性能增益,并与海域智能抗干扰方案 DDS(Direct Digital Synthesizer)<sup>[5]</sup>、无线智能抗干扰方案 DAS<sup>[6]</sup>和 TLS<sup>[7]</sup>进行对比。仿真拓扑图如图5所示,终端均按照随机游走模型移动,其中无人机飞行高度固定为15 m,速度最大为10 m/s,船只在海平面上最大速度为5 m/s<sup>[28]</sup>。

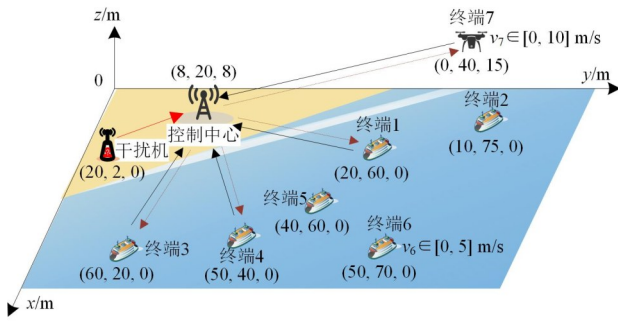


图5 仿真拓扑设置

Figure 5 Simulation topology settings

终端每秒以功率  $p \in \{20, 40, 60, 80, 100\}$  mW 在中心频点 2.4 GHz、带宽 10 MHz 的 6 个基于三射线模型<sup>[29]</sup>的海域信道上发送 200 KB 文本和 WaterScenes 数据集<sup>[9]</sup>中的图像至控制中心<sup>[24]</sup>。控制中心位于 (8, 20, 8) m 接收上行数据后,在提示词驱动下,采用 LLaVA<sup>[10]</sup> 等多种大语言模型识别海域环境和船只等目标,并将通感性能和干扰特征反馈至终端。

另外,采用 PyQt5 设计如图 6 所示的用户图形界面,可实时控制数据传输和抗干扰算法运行,动态可视输出多模态数据、终端抗干扰决策、大语言模型响应结果和通感性能指标等。同时,该界面支持在线存储与离线导出功能,便于后续性能对比分析。




图6 用户图形界面

Figure 6 User graphical interface


智能干扰机位于 (20, 2, 0) m 基于信道状态和接收信号强度,采用 Q 学习每秒选择高达 100 mW 干扰功率和 2.4 GHz 频段内带宽 20 MHz 的干扰信道,向控制中心发送高斯白噪声信号,以中断终端上行合法通信链路,劣化通感性能。策略、价值和目标网络中的全连接层均具有 128 个激活节点;随机抽取 32 个经验并采用 Adam 优化器以学习率  $10^{-4}$  更新网络权重  $\phi$  和  $\varphi$ ;采用参数  $\varpi = 0.005$  软更新  $\psi$ , 确保训练过程更加稳定;温度参数初始设为 1 并在 100 个时隙后衰减至 0.1, 以充分探索多模态数据传输策略;折扣因子  $\gamma = 0.7$ , 背景噪声功率为  $10^{-9}$  W<sup>[30]</sup>。

图 7 展示了在感知精度、传输时延和通信能耗方


面的收敛性能。在第 1 500 时隙,所提方案相对于无线智能抗干扰方案 DAS<sup>[6]</sup> 和 TLS<sup>[7]</sup>,感知精度分别提升了 13.6% 和 16.5%,通信能耗降低了 66.2% 和 69.8%,时延降低了 21.7% 和 24.2%,这是因为所提方案充分考虑了干扰特征和大语言模型输出的环境特征,联合优化功率和信道抵御智能干扰攻击。另外,所提方案由于针对恶劣海域信道条件设计了反馈恢复机制,相较于海域智能抗干扰方案 DDS<sup>[5]</sup> 提升了 8.2% 的感知精度,降低了 60.7% 的通信能耗和 14.8% 的时延。



(a) Latency



(b) Communication energy consumption

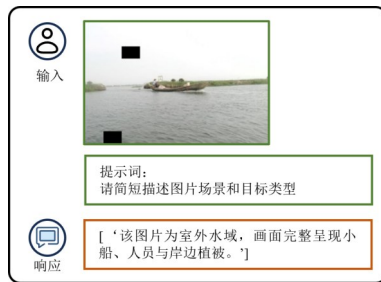


(c) Perception accuracy

图7 通感性能

Figure 7 Communication and perception performance

图 8 中大语言模型 LLaVA<sup>[10]</sup> 基于文本提示和接收到的图像进行目标识别的结果表明,所提抗干扰方案下,接收到图片质量较高,因此大语言模型在协作目标检测任务中具有更高的感知精度。



(a) 所提方案 RMMA

(a) Proposed RMMA

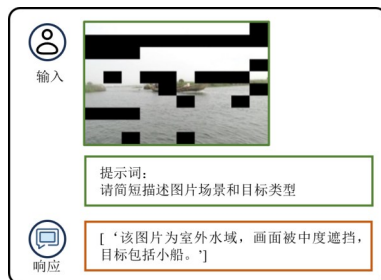
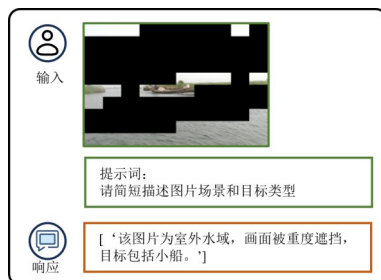
(b) 对比方案 DDS<sup>[5]</sup>(b) Benchmark DDS<sup>[5]</sup>(c) 对比方案 DAS<sup>[6]</sup>(c) Benchmark DAS<sup>[6]</sup>(d) 对比方案 TLS<sup>[7]</sup>(d) Benchmark TLS<sup>[7]</sup>

图 8 大语言模型对接收图片的响应

Figure 8 LLM responses to received images

## 6 结论

本文提出了面向大语言模型协作感知的海域通信抗干扰方案,根据多模态数据特征、环境特征、干扰特征和信道条件,优化数据传输信道、功率和模型

选择,权衡感知精度、时延和通信能耗,抵御通信与恶意干扰。设计反馈恢复机制,缓解恶劣海域信道导致的反馈延迟或丢失,避免收敛到次优策略而降低多模态数据传输可靠性,导致感知任务失败。性能界限表明,时延和通信能耗随模态数线性增加,感知精度随信道增益呈指数型饱和提升。基于文本提示和海域图像,采用 LLaVA 等大语言模型进行环境理解的仿真结果验证了所提方案的性能增益,其中感知精度提升 13.6%,通信能耗和时延分别降低 66.2% 和 21.7%。

## 参考文献

- [1] Qiao Yuanyuan, Yin Jiaxin, Wang Wei, et al. Survey of deep learning for autonomous surface vehicles in marine environments[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(4): 3678-3701.
- [2] Wu Shengqiong, Fei Hao, Qu Leigang, et al. NEX-T-GPT: Any-to-any multimodal LLM[C]//International Conference on Machine Learning. New York: ACM, 2024: 1-32.
- [3] 张海君, 陈安琪, 李亚博, 等. 6G 移动网络关键技术[J]. 通信学报, 2022, 43(7): 189-202.  
Zhang Haijun, Chen Anqi, Li Yabo, et al. Key technologies of 6G mobile network[J]. Journal on Communications, 2022, 43(7): 189-202. (in Chinese)
- [4] Yang Helin, Lin Kailong, Xiao Liang, et al. Energy harvesting UAV-RIS-assisted maritime communications based on deep reinforcement learning against jamming[J]. IEEE Transactions on Wireless Communications, 2024, 23(8): 9854-9868.
- [5] Liu Chuhuan, Zhang Yi, Niu Guohang, et al. Towards reinforcement learning in UAV relay for anti-jamming maritime communications[J]. Digital Communications and Networks, 2023, 9(6): 1477-1485.
- [6] Li Xiangchen, Chen Jienan, Ling Xiang, et al. Deep reinforcement learning-based anti-jamming algorithm using dual action network[J]. IEEE Transactions on Wireless Communications, 2023, 22(7): 4625-4637.
- [7] Janiar S B, Wang Ping. Intelligent anti-jamming based on deep reinforcement learning and transfer learning[J]. IEEE Transactions on Vehicular Technology, 2024, 73(6): 8825-8834.
- [8] Li Yangyang, Xu Yuhua, Li Guoxin, et al. Dynamic spectrum anti-jamming access with fast convergence: A labeled deep reinforcement learning approach[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 5447-5458.
- [9] Yao Shanliang, Guan Runwei, Wu Zhaodong, et al. Water-

- Scenes: A multi-task 4D radar-camera fusion dataset and benchmarks for autonomous driving on water surfaces[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(11): 16584-16598.
- [10] Liu Haotian, Li Chunyuan, Li Yuheng, et al. Improved baselines with visual instruction tuning[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2024: 26286-26296.
- [11] Wu Lei, Wang Wei, Ji Zengshuan, et al. UAV-assisted maritime legitimate surveillance: Joint trajectory design and power allocation[J]. *IEEE Transactions on Vehicular Technology*, 2023, 72(10): 13701-13705.
- [12] 苏新, 孟蕾蕾, 周一青, 等. 基于深度强化学习的海洋移动边缘计算卸载方法[J]. *通信学报*, 2022, 43(10): 133-145.  
Su Xin, Meng Leilei, Zhou Yiqing, et al. Maritime mobile edge computing offloading method based on deep reinforcement learning[J]. *Journal on Communications*, 2022, 43(10): 133-145. (in Chinese)
- [13] Yang Tingting, Jiang Zhi, Sun Ruijin, et al. Maritime search and rescue based on group mobile computing for unmanned aerial vehicles and unmanned surface vehicles[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(12): 7700-7708.
- [14] 周权, 牛英滔. 基于相似性样本生成的深度强化学习快速抗干扰算法[J]. *通信学报*, 2024, 45(7): 117-126.  
Zhou Quan, Niu Yingtao. Fast deep reinforcement learning anti-jamming algorithm based on similar sample generation[J]. *Journal on Communications*, 2024, 45(7): 117-126. (in Chinese)
- [15] Yang Tingting, Li Jiabo, Feng Hailong, et al. A novel transmission scheduling based on deep reinforcement learning in software-defined maritime communication networks[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2019, 5(4): 1155-1166.
- [16] 辜方林, 黄育侦, 赵莺, 等. 基于单载波频域均衡的直接序列扩频自适应抗干扰技术[J]. *通信学报*, 2022, 43(11): 26-34.  
Gu Fanglin, Huang Yuzhen, Zhao Ying, et al. Adaptive anti-jamming technologies based on direct sequence spread spectrum and single carrier frequency domain equalization[J]. *Journal on Communications*, 2022, 43(11): 26-34. (in Chinese)
- [17] Shang Yuzhang, Cai Mu, Xu Bingxin, et al. LLaVA-PruMerge: Adaptive token reduction for efficient large multimodal models[C]// IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2025: 22857-22867.
- [18] Lin Bin, Tang Zhenyu, Ye Yang, et al. MoE-LLaVA: Mixture of experts for large vision-language models[J]. *IEEE Transactions on Multimedia*, 2026: 1-14.
- [19] Zhu Yichen, Zhu Minjie, Liu Ning, et al. LLaVA-phi: Efficient multi-modal assistant with small language model[C]// Proceedings of the 1st International Workshop on Efficient Multimedia Computing under Limited. New York: ACM, 2024: 18-22.
- [20] Zhou Baichuan, Hu Ying, Weng Xi, et al. TinyLLaVA: A framework of small-scale large multimodal models[PP/OL]. V1. arXiv (2024-02-22)[2025-07-14]. <https://doi.org/10.48550/arXiv.2402.14289>.
- [21] 张青龙, 韩锐, 刘驰. 云边协同大模型块粒度重训方法[J]. *电子学报*, 2025, 53(2): 287-300.  
Zhang Qinglong, Han Rui, Liu Chi. Cloud-edge collaborative retraining of foundation models at the block granularity[J]. *Acta Electronica Sinica*, 2025, 53(2): 287-300. (in Chinese)
- [22] Wang Xiaowei, Wang Xue, Gao Jie, et al. A denoising method for cable partial discharge signals based on image information entropy and multivariate variational mode decomposition[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3500415.
- [23] Frantar E, Alistarh D. SparseGPT: Massive language models can be accurately pruned in one-shot[C]//International Conference on Machine Learning. New York: ACM, 2023: 10323-10337.
- [24] Sheng Ying, Zheng Lianmin, Yuan Binhang, et al. Flexgen: High-throughput generative inference of large language models with a single GPU[C]//International Conference on Machine Learning. New York: ACM, 2023: 31094-31116.
- [25] Khanmohammadi R, Miah E, Mardikoraem M, et al. Calibrating LLM confidence by probing perturbed representation stability[C]//Proceedings of the 2025 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2025: 10459-10525.
- [26] Shankar S, Zamfirescu-Pereira J D, Hartmann B, et al. Who validates the validators aligning LLM-assisted evaluation of LLM outputs with human preferences[C]//Proceedings of the 37th Annual ACM Symposium on User Interface Software and Technology. New York: ACM, 2024: 3676450.
- [27] Huang Guangbin. Learning capability and storage capacity of two-hidden-layer feedforward networks[J]. *IEEE*

Transactions on Neural Networks, 2003, 14(2): 274-281.

- [28] Nikookar S, Sakharkar P, Somasunder S, et al. Cooperative route planning framework for multiple distributed assets in maritime applications[C]//Proceedings of the 2022 International Conference on Management of Data. New York: ACM, 2022: 1518-1527.

- [29] Wang Yuzhen, Zhou Ting, Feng Wei, et al. When mari-

time wireless communications meet evaporation ducts: A three-ray path loss modeling perspective[J]. IEEE Wireless Communications Letters, 2025, 14(2): 470-474.

- [30] Zeng Hui, Su Zhou, Xu Qichao, et al. USV fleet-assisted collaborative computation offloading for smart maritime services: An energy-efficient design[J]. IEEE Transactions on Vehicular Technology, 2024, 73(10): 14718-14733.

### 作者简介



**刘欢欢** 女,1997年10月出生出生于黑龙江省五常市。现为厦门大学信息学院博士研究生。主要研究方向为无线通信抗干扰等。  
E-mail: 1046769527@qq.com



**陈灏宇** 男,1998年6月出生出生于福建省宁德市。现为厦门大学人工智能研究院博士研究生。主要研究方向为物理层安全博弈和无线定位。  
E-mail: haoyuchen98@qq.com



**肖亮** 女,1980年3月出生出生于河北省石家庄市。现为厦门大学信息学院教授、博士生导师。主要研究方向为无线通信、网络安全等。中国电子学会会员编号:E190014082S。  
E-mail: lxiao@xmu.edu.cn



**陈宏毅** 男,2001年9月出生出生于福建省宁德市。现为厦门大学人工智能研究院硕士研究生。主要研究方向为大语言模型协同推断和车联网协作感知技术。  
E-mail: 314948829@qq.com



**林蔚祺** 男,2002年9月出生出生于福建省龙岩市。现为厦门大学信息学院硕士研究生。主要研究方向为无线通信抗干扰。  
E-mail: 2140199773@qq.com



**汤中卫** 男,1999年12月出生出生于安徽省六安市。现为厦门大学信息学院博士研究生。主要研究方向为计算机视觉与无线通信网络。  
E-mail: 23320250157889@stu.xmu.edu.cn



**张朋丽** 女,2001年12月出生出生于河南省周口市。现为厦门大学信息学院博士研究生。主要研究方向为无人机通信抗干扰等。  
E-mail: 3024975773@qq.com