

面向多节点协作ISAC的智能压缩反馈技术

陈露^{1,2}, 娄兴良^{1,2}, 夏文超^{1,2}, 沈璐瑶^{1,2}

(1. 南京邮电大学教育部泛在网络健康服务系统工程研究中心, 江苏 南京 210003; 2. 南京邮电大学江苏省无线通信与物联网重点实验室, 江苏 南京 210003)

摘要: 在通感一体化 (ISAC, integrated sensing and communication) 系统中, 基站、无线接入点 (AP, access point) 等各类节点相互协作可以增强感知的广度和精度。然而, 节点与融合中心之间的回传链路容量有限且存在异构性, 导致感知信号无法直接上传融合。针对该问题, 提出了一种基于自编码器技术的感知信号智能压缩反馈方法。具体来说, 编码器在 AP 处利用深度神经网络从感知信号中提取特征, 并通过回传链路上传至融合中心。融合中心利用解码器进行感知信号重构, 并基于重构信号和广义似然比 (GLRT, generalized likelihood ratio test) 检测器进行目标检测。此外, 考虑到不同节点的回传链路容量不同, 提出了基于迁移学习的自适应压缩反馈方法, 在预训练模型基础上, 冻结该模型的大部分层 (这些层已充分学习信号特征), 利用少量样本对模型结构进行微调以适应不同压缩比。最后, 仿真结果表明, 与决策融合方案相比, 所提方法在压缩比为 1/2 时的平均检测概率提升了 33.92%, 能够在感知性能和反馈开销之间取得较好的平衡。

关键词: 通感一体化; 容量受限; 压缩反馈; 自编码器; 迁移学习

中图分类号: TN92

文献标志码: A

doi: 10.11959/j.issn.2096-3750.XXXX.

Intelligent compression and feedback technology for multi-node collaborative ISAC

CHEN Lu^{1,2}, LOU Xingliang^{1,2}, XIA wenchao^{1,2}, SHEN Luyao^{1,2}

1. the Engineering Research Center of Health Service System Based on Ubiquitous Wireless Networks, Ministry of Education, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. Jiangsu Provincial Key Laboratory of Wireless Communications and IoT, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: In ISAC systems, the collaboration between various nodes, such as base stations and radio AP, can enhance sensing scope and accuracy. However, capacity-constrained and heterogeneous backhaul links between nodes and the fusion center impede the direct uploading and fusion of sensing signals. To address this issue, an intelligent compressed feedback method for sensing signals based on autoencoder techniques was proposed. Specifically, features were extracted from the signals at the AP by an encoder using deep neural networks and uploaded to the fusion center via backhaul links. The fusion center used a decoder to reconstruct signals, and then performed target detection via the GLRT detector. Moreover, considering heterogeneous backhaul capacities, an adaptive compression feedback method based on transfer learning was proposed. Based on the pre-trained model, most layers which had already sufficiently learned signal features, were frozen. The model structure was then fine-tuned with few samples to adapt to varying compression ratios. Finally, simulation results validate the proposed method achieves a 33.92% improvement in average detection probability over the decision-fusion method at a 1/2 compression ratio, showing a favorable balance between sensing performance and feed-

收稿日期: 2025-XX-XX; 修回日期: 2025-XX-XX

通信作者: 夏文超, xiawenchao@njupt.edu.cn

基金项目: 国家自然科学基金青年基金项目 (No. 62201285)。

Foundation Items: The National Natural Science Foundation of China (No. 62201285).

back overhead.

Key words: Integrated sensing and communication (ISAC), Constrained-capacity, compress and feedback, autoencoder, transfer learning

0 引言

随着移动通信与物联网快速发展,人们对6G的愿景将不再是单一的通信基础设施,而是融合无线通信、传感、计算和人工智能等多种功能的综合性平台,从而全面改变我们的生活和工作方式。而通信和感知一体化(ISAC, integrated sensing and communication)有望成为实现这一愿景的关键技术^[1],该技术的基本理念是实现通信和传感之间共享基础设施、资源和信号,从而提高频谱利用效率和信息处理效率、降低硬件成本。

当前,ISAC已迅速成为学术界关注的焦点,并引发了研究人员的广泛兴趣。在文献[2]中,提出了一种双功能大规模多输入多输出(MIMO, multiple input multiple output)雷达和多用户MIMO通信的联合发射波束模型,通过共享频谱和传输阵列在雷达和通信之间实现了有利的性能权衡。文献[3]考虑双功能雷达-通信系统并采用克拉美界(CRB, cramer-rao bound)作为度量指标,来优化目标估计性能。文献[4]考虑了一种主动感知场景,基站通过在连续的时隙中动态调整波束成形矩阵,自适应地完成感知任务。面向车联网多用户ISAC系统,文献[5]提出了一种MIMO正交时频空鲁棒传输方案,显著提升了高移动性场景下的通信性能和系统鲁棒性。然而上述工作都集中于单节点感知场景,其发射机和接收机共同位于同一基站内,存在显著的自干扰问题。虽然文献[6]优化了接收波束赋形以捕捉雷达目标的反射,避免了全双工操作带来的自干扰,但这仍不足以彻底解决问题。此外,单节点或双节点系统存在视角受限、覆盖不完整的问题,无法获取目标的全方位信息。事实上,在实际的蜂窝网络中,基站、无线接入点(AP, access point)、远端射频头等各类节点密集分布。这些节点共同感知可以获得协作增益,从而增强感知的广度和精度。

围绕多节点协作感知,文献[7]中作者研究了利用多个无人机作为ISAC收发器的网络,在保证感知精度的同时,联合优化无人机的定位、功率分

配和用户关联问题,实现网络总效用最大化。多节点感知还可以通过设置专用感知接收器,来解决上述单节点感知中的全双工问题。文献[8]中作者设置一组分布式ISAC发射机为其相应的用户服务,同时与多个感知接收器合作估计目标的位置,并针对该系统提出了一种功率分配。文献[9]在云无线接入网络架构中研究多静态感知的ISAC系统,并提出了最大信噪比的功率分配算法,显著提高了检测概率。但是,这些工作都是在理想条件下完成的,没有考虑感知信号回传时链路容量受限情况。虽然文献[10]中针对容量受限问题,作者给出了先决策后融合的解决方案,但决策融合高度依赖于AP的个体感知精度,导致最终感知性能受限。文献[11]中则提出了一种基于码本压缩策略的处理方法,并研究了给定容量约束下AP和天线的最优配置,但其压缩方法更多适用于前传链路容量受限的情况。然而,实际中回传链路的容量存在差异,如何根据回传容量不同实现感知信号自适应压缩成为一个具有挑战性的问题。

近些年来,深度学习的快速发展为解决上述挑战提供了潜在可能。深度学习通过构建多层神经网络对数据特征进行提取、抽象和处理,将线上推理复杂度转移到离线训练阶段,从而支持在线快速推理决策。如今,深度学习已被广泛应用于无线通信场景。例如信道状态信息反馈^[12]、信道估计^[13]、资源分配^[14]、预编码^[15]等方面。

根据上述文献可以看出,面向多节点协作ISAC系统的研究尚未给出针对回传链路容量受限情况下的自适应压缩方案,且深度学习技术还没有该方面的应用。受此激励,本文提出了一种基于深度学习的多节点感知信号智能压缩反馈技术,将多节点感知信息压缩后通过容量受限的回传链路上传到融合中心进行解压,并利用广义似然比(GLRT, generalized likelihood ratio test)检测器对解压缩后的信号进行目标检测。本文主要贡献如下:

1) 针对回传链路容量受限问题,提出了一种基于自编码器的智能压缩反馈方法,该方法采用深度神经网络(DNN, deep neural network)构建模型并

训练，通过在各个接收AP处部署编码器实现感知信号的高效压缩，反馈至融合中心利用解码器进行重构恢复，并利用重构的感知信号进行目标检测。

2) 考虑到回传链路容量大小不同，本文将迁移学习 (TL, transfer learning) 技术引入训练过程，通过冻结部分神经网络层保留预训练模型的特征提取能力和重构性能，再根据不同的压缩比调整网络结构，并对网络参数进行微调优化从而得到实现自适应压缩反馈的模型。

3) 本文采用GLRT检测器对解压缩后的多节点融合信号进行目标检测，并给出功率分配优化问题的求解，从而进一步提升感知精度。

最后仿真结果证明，所提方案能够获得多种压缩比条件下的模型，其在重构精度和泛化性能方面均表现出优势，有效权衡感知性能和反馈开销。特别地，在压缩比大于1/8时，本方案的感知性能优于决策融合方案，在压缩比为1/2时平均检测概率更是提升了33.92%。

1 系统模型

1.1 场景设置

在本文中，考虑一个异构ISAC系统，如图1所示。该系统中，基站发送ISAC信号，在长度为 L 的通信时隙内为 N_u 个通信设备 (CE, communication equipment) 提供下行通信服务，同时执行单目标检测任务。系统部署了 N_a 个AP用于接收目标的回波感知信号，并通过容量受限的回传链路反馈至融合中心进行处理；同时，AP会接收到来自基站的直达信号。值得注意的是，为避免自干扰问题，系统未利用基站接收到的回波感知信号进行目标检测。在硬件配置方面，基站配备有 M_t 根发射天线的均匀线性阵列，而每个AP则配备有 M_r 根接收天线的均匀线性阵列，CE为单天线。为了确保多用户通信中波束成形设计的可行性，并避免感知信息的丢失^[3]，通常假设 $N_u \leq M_t < M_r$ 。

设 $s_i \in \mathbb{C}^{L \times 1}$ 为第 i 个CE的下行通信符号， $s_0 \in \mathbb{C}^{L \times 1}$ 为与 s_i 相互独立的感知符号，且均值为零、方差为1。令 $l \in \{0, \dots, L-1\}$ ， $i \in \{1, \dots, N_u\}$ ，则基站的发射信号 $\mathbf{x}[l] \in \mathbb{C}^{M_t \times 1}$ 为

$$\mathbf{x}[l] = \sum_{i=0}^{N_u} \sqrt{\rho_i} \mathbf{v}_i s_i[l] \quad (1)$$

其中， $\mathbf{v}_0$ 和 $\mathbf{v}_i$ 分别为感知信号和第 i 个CE对应的单




图1 所考虑的异构ISAC系统示意图

位发射预编码矢量， ρ_i 为对应的符号功率。

假设目标与基站之间为视距 (LOS, line of sight) 传输，且天线阵列中相邻天线的间隔均为半波长，则发射天线阵列对目标方位角 θ 的响应向量可表示为^[16]

$$\mathbf{a}(\theta) = [1 \ e^{j\pi \sin(\theta)} \ \dots \ e^{j(M_t-1)\pi \sin(\theta)}]^T \in \mathbb{C}^{M_t \times 1} \quad (2)$$

1.2 下行通信

将第 i 个CE与基站之间的信道记为 h_i ，假设其服从平坦瑞利衰落分布，且各信道间相互独立，则在每个CE处接收到的信号为

$$y_i[l] = \sum_{i=1}^{N_u} \sqrt{\rho_i} h_i^H \mathbf{v}_i s_i[l] + \sqrt{\rho_0} h_i^H \mathbf{v}_0 s_0[l] + \mathbf{n}_i[l] \quad (3)$$

其中， $\mathbf{n}_i[l]$ 是均值为0和方差为 σ_n^2 的加性高斯白噪声 (AWGN, additive white gaussian noise)。因此，第 i 个CE信干噪比 (SINR, signal-to-interference-plus-noise ratio) 可以表示为

$$\gamma_i = \frac{\rho_i |\mathbf{h}_i^H \mathbf{v}_i|^2}{\sum_{i'=1, i' \neq i}^{N_u} \rho_{i'} |\mathbf{h}_{i'}^H \mathbf{v}_{i'}|^2 + \rho_0 |\mathbf{h}_i^H \mathbf{v}_0|^2 + \sigma_n^2} \quad (4)$$

这里，采用正则化迫零 (RZF, regularized zero-forcing) 预编码^[18]，为第 i 个CE构造预编码矢量为

$$\bar{\mathbf{v}}_i = \left(\sum_{i=1}^{N_u} \mathbf{h}_i \mathbf{h}_i^H + \lambda \mathbf{I}_{M_t} \right)^{-1} \mathbf{h}_i \quad (5)$$

其中， λ 是正则化参数， $\mathbf{I}_{M_t} \in \mathbb{C}^{M_t \times M_t}$ 为单位矩阵， $\bar{\mathbf{v}}_i$ 归一化后得 $\mathbf{v}_i = \bar{\mathbf{v}}_i / \|\bar{\mathbf{v}}_i\|$ 。

1.3 多节点感知

本文假设目标为远离基站的非结构化点目标，基站发射的信号 $\mathbf{x}[l]$ 经目标反射后被AP接收。定义 θ_r 为第 r 个AP相对于目标的方位角，每个AP处

的接收天线阵列响应向量可表示为

$$\mathbf{b}(\theta_r) = [1 \ e^{j\pi \sin(\theta_r)} \ \dots \ e^{j(M_r-1)\pi \sin(\theta_r)}]^T \in \mathbb{C}^{M_r \times 1} \quad (6)$$

则在基站和第 r 个接收 AP 之间的感知信道建模为

$$\mathbf{H}_r = \alpha_r \mathbf{b}(\theta_r) \mathbf{a}^H(\vartheta) \quad (7)$$

其中, $r \in \{1, \dots, N_a\}$, $\alpha_r \sim \mathcal{CN}(0, \sigma_r^2)$ 为综合感知信道增益, σ_r^2 代表其包含目标的路径损耗和目标雷达散射截面积 (RCS, radar cross section) 的影响^{[9][17]}。感知信道采用 Swerling-I 模型, 即在 ISAC 信号传输过程中, 目标的变化速度远低于雷达的扫描频率。此外, 基站与第 r 个 AP 间的信道记为 $\mathbf{G}_r \in \mathbb{C}^{M_r \times M_t}$, 并假设其服从复高斯分布。因此, 第 r 个 AP 接收到的感知信号为

$$\mathbf{y}_r[l] = \mathbf{H}_r \mathbf{x}[l] + \mathbf{G}_r \mathbf{x}[l] + \mathbf{n}_r[l] \in \mathbb{C}^{M_r \times 1} \quad (8)$$

其中, $\mathbf{n}_r[l] \sim \mathcal{CN}(0, \sigma_n^2 \mathbf{I}_{M_r})$ 为 AWGN 向量。

为消除感知符号对 CE 的干扰, 感知预编码矢量也采用 RZF 方案设计为

$$\bar{\mathbf{v}}_0 = \left(\mathbf{I}_{M_t} - \sum_{i=1}^{N_a} \mathbf{h}_i \mathbf{h}_i^H \right)^{-1} \mathbf{a}(\theta_t) \quad (9)$$

其中, $\bar{\mathbf{v}}_0$ 归一化后得 $\mathbf{v}_0 = \bar{\mathbf{v}}_0 / \|\bar{\mathbf{v}}_0\|$ 。

最后, 每个 AP 需要将各自的 L 个观测样本, 即 $\{\mathbf{y}_r[l]\}_{l=1}^L$, 先压缩再发送到融合中心处理, 具体细节见第 2 节内容。

1.4 问题描述

为了优化系统的感知性能, 本文构建了以最大化目标检测概率为目标的发射功率分配优化问题, 具体表示为

$$\begin{aligned} \text{P1: } \max_{\rho \geq 0} P_D \\ \text{s.t. C1: } \gamma_i \geq \Gamma, i \in N_u \\ \text{C2: } \|\mathbf{p}\|_1 \leq P_{\max} \end{aligned} \quad (10)$$

其中, $\mathbf{p} = [\rho_0, \rho_1, \dots, \rho_{N_u}]$, P_D 代表检测概率, 具体表达式在 3.1 节给出, Γ 代表 CE 所需的最小 SINR 阈值, $P_{\max}$ 代表基站的发射功率预算。

值得一提的是, 本文是基于反馈的压缩信号 $\{\mathbf{y}_r[l]\}_{l=1}^L$ 进行目标检测。为实现该研究目标, 需要解决两个问题: 一是如何在回程容量受限的情况下, 对各个 AP 接收的感知信号进行高效压缩处理, 并反馈至融合中心进行信号重构; 二是如何基于重构后的感知信号进行目标检测, 对优化问题 P1 进行求解。

首先需要解决感知信号压缩反馈问题, 然而这并非易事。信号压缩问题本质上是非线性、非凸的, 同时由于回传链路容量受限且各链路容量大小不一, 进一步增加了问题的复杂度。针对这一挑战, 本文提出了基于自编码器的感知信号压缩反馈方法。




图2 所考虑的基于自编码器的网络结构

2 感知信号智能压缩反馈方法

本节首先阐述了所提出的压缩反馈方案, 并详细介绍了基于自编码器的网络结构设计。其次, 为了适应不同容量的回传链路, 进一步提出了一种基于 TL 的回传容量自适应压缩机制。

2.1 压缩反馈

考虑到 AP 需要通过容量受限的回传链路将接收到的感知信号传输至融合中心进行处理, 而直接发送原始感知信号会造成大量通信开销。为此, 本文引入基于自编码器的感知信号智能压缩反馈方法, 该方法在 AP 处和融合中心处分别部署编码器

和解码器，如图2所示^[19]。为了减少传输开销，AP将接收到的感知信号压缩成一个低维码字 $\ell \in \mathbb{C}^{N_t \times 1}$ 为

$$\ell = f_{en}(\mathbf{y}_r) \quad (11)$$

其中， $\mathbf{y}_r = [\mathbf{y}_r[1], \dots, \mathbf{y}_r[l], \dots, \mathbf{y}_r[L]]$ 代表 L 个符号集合， $f_{en}(\cdot)$ 表示编码器网络函数，对应的参数为 Θ_{en} 。融合中心接收到码字后，利用解码器网络进行解压缩与信号重构

$$\hat{\mathbf{y}}_r = f_{de}(\ell) \quad (12)$$

其中， $\hat{\mathbf{y}}_r = [\hat{\mathbf{y}}_r[1] \dots \hat{\mathbf{y}}_r[l] \dots \hat{\mathbf{y}}_r[L]]$ 为重构后感知信号， $f_{de}(\cdot)$ 表示解码器网络函数，对应的参数为 Θ_{de} 。感知信号矩阵大小为 $2M_r L$ ，压缩后码字大小为 N_t ，据压缩比 (CR, compression ratio) 被定义为

$$CR = \frac{N_t}{2M_r L} \quad (13)$$

对于编码器和解码器两个核心模块，本文采用深度神经网络 DNN 实现^[19]。在编码器部分，设计了7层卷积层，各层采用相同的 3×3 的卷积核，但设置不同数量的特征映射，以实现数据多层次特征提取。卷积层之后，通过 reshape 操作将特征映射重塑为平坦向量，并引入全连接层进行降维，从而实现感知信号矩阵的有效压缩。在解码器模块中，先利用全连接层对接收到的信号进行解压缩，经过维度重塑以恢复感知信号的原始维度特征后输入3个残差模块。每个残差模块用于精估计，采用统一结构，即3层 3×3 内核的卷积层，前两层分别生成8个和16个特征映射，第三层完成输出感知信号矩阵的最终重构任务。这种级联式残差结构通过多层次特征融合，有效提升了信号重构精度。

该模型的训练通过 Adam 优化器对参数集 $\Theta = \{\Theta_{en}, \Theta_{de}\}$ 在数据集 $\mathcal{Y}$ 上进行更新，损失函数采用均方误差 (MSE, mean squared error) 函数，即

$$L(\Theta) = \sum_{i=1}^{\mathcal{Y}} \|\mathbf{y}_r - \hat{\mathbf{y}}_r\|^2 \quad (14)$$

其中， $r \in \{1, 2, \dots, N_a\}$ 。

2.2 基于TL的训练框架

实际应用中，回传链路的容量存在差异，传统方法需要根据不同的容量需求重新训练整个模型以调整压缩比，导致巨大的计算开销。为解决这一问题，本文提出了一种基于TL的高效训练框架。该框架通过TL机制，在减少计算开销的同时，确保模型在不同压缩比下均能保持良好的重构性能，从

而实现自适应压缩反馈。

值得注意的是，对于不同的 CR ，本文引入压缩控制参数 $\zeta = 1/CR$ 对全连接层进行调整

$$units = \frac{T}{\zeta} \quad (15)$$

其中， T 为上一层输出的大小， $units$ 为全连接层的输出维度，决定了压缩后的码字长度。




图3 基于TL的训练示意图

所提训练框架分为预训练阶段和目标训练阶段。如图3所示，DNN被划分为三个部分：编码器特征处理部分 (S_1)，信号压缩/解压缩部分 (S_2)、解码器重构恢复部分 (S_3)，参数集 Θ 同样被分为 Θ_{S1} 、 Θ_{S2} 、 Θ_{S3} 。通过建模仿真构建预训练数据集和目标训练数据集分别为 $\mathcal{Y}_p$ 和 $\mathcal{Y}_r$ ， $\mathcal{Y}_p \gg \mathcal{Y}_r$ 。具体训练过程如下：

1) 预训练阶段：将压缩控制参数 ζ 设置为1，利用大规模数据集 $\mathcal{Y}_p$ 对模型进行训练，参数集 $\Theta = \{\Theta_{S1}, \Theta_{S2}, \Theta_{S3}\}$ 的更新采用 Adam 优化器。得益于 $\mathcal{Y}_p$ 的充分样本量，该阶段训练可获得一个具有较强特征提取能力的 DNN_p 。特别地，其 S_1 和 S_3 部分在此过程积累了丰富的数据特征提取和重构知识。

2) 目标训练阶段：该阶段首先根据目标压缩比需求，调整压缩控制参数 ζ 的取值，以自适应地重构模型 S_2 部分的网络架构。然后基于TL技术，将预训练模型 DNN_p 的参数 Θ_{S1} 和 Θ_{S3} 加载至目标训练任务，并固定参数 Θ_{S1} 和 Θ_{S3} 的梯度更新，从而冻结对应的网络层 S_1 和 S_3 。该冻结策略缓解了因数据集规模减小而导致的模型性能退化问题，同时保留了 DNN_p 的特征提取能力和重构性能。在优化过程中，采用 Adam 优化器对可训练参数 Θ_{S2} 进行微调，并在 $\mathcal{Y}_r$ 上进行迭代训练。当模型收敛至最优状态时，即可获得适用于目标任务的深度网络模

型 DNN_{TR} 。

具体训练算法过程见表 1。

表 1 感知信号压缩反馈中基于 TL 的训练算法

算法 1 感知信号压缩反馈中基于 TL 的训练算法
设置 $\zeta = 1$, 建立模型 DNN_p 。
采用 Adam 优化器更新参数集 Θ 。
在 $\{\mathcal{Y}_p\}$ 上进行迭代训练。
保存训练好的参数集 $\Theta = \{\Theta_1, \Theta_2, \Theta_3\}$ 。
根据 CR 设置 ζ , 重新建立模型 DNN_{TR} 。
加载 $\Theta_1 \rightarrow S_1, \Theta_3 \rightarrow S_3$
固定参数 Θ_1 和 Θ_3 , 冻结网络层 S_1 和 S_3 。
采用 Adam 优化器更新参数 Θ_{S_2} 。
在 $\{\mathcal{Y}_r\}$ 上进行迭代训练对 DNN_{TR} 进行微调优化。
输出: 优化后适用于目标压缩反馈任务的 DNN_{TR}

$$\begin{aligned}\tilde{\mathbf{y}}_r &= \text{vec}(\tilde{\mathbf{Y}}_r) = \frac{1}{\sqrt{L}} \mathbf{a}_r F_r + \varepsilon_r \\ &= \frac{1}{\sqrt{L}} \mathbf{a}_r \text{vec}(L \mathbf{b}(\theta_r) \mathbf{a}^H(\vartheta) \mathbf{V}) + \frac{1}{\sqrt{L}} \text{vec}((\mathbf{G}_r \mathbf{x} + \mathbf{n}_r) \mathbf{S}^H)\end{aligned}\quad (17)$$

其中, $\text{vec}(\cdot)$ 代表向量化操作, 第一项为期望信号矢量, 其中 $\mathbf{a}_r$ 代表未知的信道系数, 而 $F_r \in \mathbb{C}^{M_r(N_u+1) \times 1}$ 对于融合中心为已知部分, 这是因为基站、AP 以及目标位置是固定的。第二项 ε_r 为背景干扰和噪声矢量, 服从零均值的复高斯分布, 由自相关运算得其协方差矩阵为

$$R_r = \mathbb{E}\{\varepsilon_r \varepsilon_r^H\} = \text{blkdiag}\{R_{r_0}, R_{r_1}, \dots, R_{r_{N_u}}\} \quad (18)$$

其中, $R_{r_0} = R_{r_i} = \sigma_n^2 \mathbf{I}_{M_r} + \mathbf{G}_r \mathbf{V} \mathbf{V}^H \mathbf{G}_r^H = \hat{R}_r \in \mathbb{C}^{M_r \times M_r}$ 。

随后, 融合中心联合处理来自 N_a 个 AP 的重构感知信号, 利用 GLRT 检测器进行目标检测, 相应的统计假设检验问题为

$$\begin{aligned}\mathcal{H}_0: \hat{\mathbf{y}}_R &= \sum_{r=1}^{N_a} \varepsilon_r \\ \mathcal{H}_1: \hat{\mathbf{y}}_R &= \sum_{r=1}^{N_a} \mathbf{a}_r F_r / \sqrt{L} + \varepsilon_r\end{aligned}\quad (19)$$

其中, 零假设 $\mathcal{H}_0$ 表示区域内不存在目标的场景, 备择假设 $\mathcal{H}_1$ 表示目标存在的场景。

在 Neyman-Pearson 准则下, 对应的 GLRT 检测器为

$$\Lambda = \frac{\max_a f(\hat{\mathbf{y}}_R | \mathbf{a}, \mathcal{H}_1)}{f(\hat{\mathbf{y}}_R | \mathcal{H}_0)} \underset{\mathcal{H}_0}{\geq} \xi \quad (20)$$

其中, $\mathbf{a} = [\alpha_1, \alpha_2, \dots, \alpha_{N_u}]^T$ 为未知信道系数集合,

3 基于重构信号的目标检测

3.1 目标检测

在利用解码器网络获得重构感知信号 $\hat{\mathbf{y}}_r$ 后, 融合中心首先采用发射符号 $\mathbf{S} = [s_0, s_1, \dots, s_{N_u}]^H$ 充分统计 L 个通信时隙的信号, 即进行匹配滤波处理^[20]

$$\begin{aligned}\tilde{\mathbf{Y}}_r &= \frac{1}{\sqrt{L}} \hat{\mathbf{y}}_r \mathbf{S}^H \\ &= \sqrt{L} \mathbf{H}_r \mathbf{V} + \sqrt{L} \mathbf{G}_r \mathbf{V} + \frac{1}{\sqrt{L}} \mathbf{n}_r \mathbf{S}^H\end{aligned}\quad (16)$$

其中, $\mathbf{V} = [\sqrt{\rho_0} \mathbf{v}_0, \sqrt{\rho_1} \mathbf{v}_1, \dots, \sqrt{\rho_{N_u}} \mathbf{v}_{N_u}] \in \mathbb{C}^{M_r \times (N_u+1)}$ 。

为了方便送入检测器进行检测, 经过向量化计算得到

$f(\hat{\mathbf{y}}_R | \mathcal{H}_0)$ 和 $f(\hat{\mathbf{y}}_R | \mathbf{a}, \mathcal{H}_1)$ 分别表示在假设 $\mathcal{H}_0$ 和 $\mathcal{H}_1$ 下观测向量 $\hat{\mathbf{y}}_R$ 的联合条件概率密度函数。 ξ 为检测器使用的判决阈值, 用来确保虚警概率 P_{FA} 满足预设的期望值。因此, 对未知 $\mathbf{a}$ 进行极大似然估计有^[20]

$$\hat{\mathbf{a}} = \frac{\sum_{r=1}^{N_a} F_r^H R_r^{-1} \tilde{\mathbf{y}}_r}{\sum_{r=1}^{N_a} F_r^H R_r^{-1} F_r} \quad (21)$$

将估计的 $\hat{\mathbf{a}}$ 代入检测器, 可推导出对数形式的检验统计量为

$$\ln(\Lambda) = \frac{\sum_{r=1}^{N_a} |F_r^H R_r^{-1} \tilde{\mathbf{y}}_r|^2}{\sum_{r=1}^{N_a} F_r^H R_r^{-1} F_r} \quad (22)$$

其服从自由度为 $\kappa = 2N_a M_r (N_u + 1)$ 的中心和非中心卡方分布^[21]

$$\ln(\Lambda) \sim \begin{cases} \chi_\kappa^2 & \mathcal{H}_0 \\ \chi_\kappa^2(v) & \mathcal{H}_1 \end{cases} \quad (23)$$

其中, 非中心参数 v 为

$$v = \sum_{r=1}^{N_a} \sigma_r^2 \text{Ltr} \left(\frac{\mathbf{A}_r \mathbf{V} \mathbf{V}^H \mathbf{A}_r^H}{\hat{R}_r} \right) \quad (24)$$

其中, $\mathbf{A}_r = \mathbf{b}(\theta_r) \mathbf{a}^H(\vartheta)$, $\text{tr}(\cdot)$ 代表取迹函数。其对应阈值可表示为

$$\ln(\xi) = \mathcal{F}_{\chi^2_\kappa}^{-1}(1 - P_{FA}) \quad (25)$$

则检测概率为^[22]

$$P_D = 1 - \mathcal{F}_{\chi^2_\kappa(v)}(\ln(\xi)) \quad (26)$$

其中, $\mathcal{F}_{\chi^2_\kappa(v)}(\cdot)$ 表示自由度为 κ 的非中心卡方累计分布函数。至此, 完成了基于重构信号的目标检测。

3.2 功率分配优化

得到 P_D 表达式后, 可以对优化问题 $\mathcal{P}1$ 进行求解, 确保目标检测任务始终是基于最优发射功率分配策略, 从而进一步优化系统感知性能。

观察到 P_D 随非中心参数 v 单调递增且 L 为常数, 所以 $\mathcal{P}1$ 可以等价

$$\mathcal{P}2: \max_{\rho \geq 0} \sum_{r=1}^{N_a} \sigma_r^2 \text{tr} \left(\frac{\mathbf{A}_r \mathbf{V} \mathbf{V}^H \mathbf{A}_r^H}{\hat{R}_r} \right) \text{s.t. C1, C2} \quad (27)$$

借助矩阵迹的性质对 v 的计算式进行处理, $\mathcal{P}2$ 可重述为

$$\mathcal{P}3: \min_{\rho \geq 0} - \sum_{r=1}^{N_a} \frac{\sigma_r^2 \text{tr}(\text{diag}(\mathbf{p}) \hat{\mathbf{V}}^H \mathbf{A}_r^H \mathbf{A}_r \hat{\mathbf{V}})}{M_r \sigma_n^2 + L \text{tr}(\text{diag}(\mathbf{p}) \hat{\mathbf{V}}^H \mathbf{G}_r^H \mathbf{G}_r \hat{\mathbf{V}})} \quad (28)$$

s.t. C1, C2

其中, $\hat{\mathbf{V}} = [\mathbf{v}_0, \mathbf{v}_1, \dots, \mathbf{v}_{N_a}]^T$ 。

针对 $\mathcal{P}3$ 这一分式规划问题, 本文引用文献[23]中的方法, 利用二次变换技术将其转化为一个标准的半定规划问题, 最后通过CVX工具箱进行求解。

4 仿真结果

本节将提供仿真结果以验证智能压缩反馈方案的有效性。仿真场景设置如下: 在 $[0, 500]$ m范围内, 目标固定于区域中心位置, 基站、CE、AP采用随机分布方式部署, 如图4所示。

采用信道模型为 $\mathbf{h}_i = \sqrt{\mathbf{d}_i} \tilde{\mathbf{h}}_i \in \mathbb{C}^{M_i \times 1}$, 其中 $\mathbf{d}_i = 128.1 + 37.6 \lg(\omega)$ 代表大尺度衰落, ω 代表CE与基站间的距离, $\tilde{\mathbf{h}}_i \sim \mathcal{CN}(0, \mathbf{I}_{M_i})$ 代表小尺度衰落^[24]。无目标信道 $\mathbf{G}$ 生成方式类似。其他仿真参数如表2所示^[10]。

图5展示了分配给通信的功率预算不同时, SINR阈值 Γ 与非中心参数 v 的对比关系图, Γ 和 v 分别反映了通信性能和感知性能。从图中可以看出, 当更多的功率预算用于通信时, SINR阈值 Γ 显著提升, 但同时非中心参数 v 逐渐减小。后续仿真中SINR阈值设置为 $\Gamma = 15$ dB。

本文首先构建数据集用于训练网络。具体而




图4 ISAC系统二维位置示意图

表2 仿真参数设计

参数	符号	数值
CE个数	N_u	8
AP个数	N_a	10
基站的发射天线个数	M_t	16
AP的接收天线个数	M_r	20
通信时隙长度	L	32
虚警概率	P_{FA}	0.000 01
噪声功率	σ_n^2	-94 dBm
基站的功率预算	$P_{\max}$	30 dBm
载波频率	-	3.2 GHz




图5 不同功率分配下, Γ 与 v 的对比关系图

言, 本文通过MATLAB仿真生成1 000个随机样本, 考虑不同 σ_r^2 下AP接收到的感知信号, 范围从-30~10 dB, 所以预训练数据集 $\mathcal{Y}_p$ 长度为 $1000 \times 41N_a = 410\,000$, 而目标训练数据集 $\mathcal{Y}_t$ 将选取100、

1 000、10 000 三种长度构建并进行对比。所有数据集都以 8:1:1 的比例划分为训练集、验证集、测试集^[25]。预训练阶段的批大小为 1 000、训练轮次为 400，目标训练阶段的批大小为 64、训练轮次为 200，学习率始终为 0.001^[19]。

为了验证 TL 训练框架的性能，本文将直接训练作为对比训练方案，即没有加载 DNN_p 并且训练所有网络层参数，记为 DNN_T 。同理，本文所提的方案是基于训练出的 DNN_{TR} 实现的，所以记为 DNN_{TR} 。

仿真中，本文通过对 1 000 个随机样本的检测结果进行均值计算得到其平均检测概率，作为评估各方案感知性能的指标。同时采用归一化均方误差 (NMSE, normalized mean squared error) 和余弦相似度 Υ 来衡量重构感知信号质量^[12]，定义分别如下

$$NMSE = 10 \lg \left(\frac{\| \mathbf{y} - \hat{\mathbf{y}} \|_2^2}{\| \mathbf{y} \|_2^2} \right) \quad (29)$$

$$\Upsilon = \mathbb{E} \left(\frac{|\mathbf{y}^H \hat{\mathbf{y}}|}{\| \mathbf{y} \|_2 \| \hat{\mathbf{y}} \|_2} \right) \quad (30)$$

图 6 展示了 $CR = 1/2$ 时， $\mathcal{Y}_T$ 为不同长度并基于两种训练方案实现的感知性能对比。从图中可以看出，平均检测概率对于数据集 $\mathcal{Y}_T$ 规模具有高度依赖性，这是因为当训练数据量不足时，模型重构质量显著降低，导致感知性能下降。但与 DNN_T 相比，本文方案在不同数据集规模下均展现出更高的平均检测概率，且这一优势在小规模数据集上表现尤为显著。这是因为本文所提方案在模型冻结部分保留了在预训练过程中学习到的丰富信号特征，有效保证了在目标压缩任务中的信号重构质量。其次，得益于预训练模型提供的强大泛化能力，即使在少量新任务数据的情况下，本文方案仍能凭借其更鲁棒的特征表示能力突破 DNN_T 的局部最优限制，从而获得更优的模型性能。特别是在面对未知数据分布时，本文所提方案在目标检测过程中展现出显著的感知性能提升。

图 7 展示了 $CR = 1/2$ 时，不同冻结层比例对平均检测概率和 σ_r^2 关系的影响。从图中可以看出，随着冻结层比例的增加，在相同 σ_r^2 下平均检测概率越高，说明本文采取的冻结策略是有效的。值得注意的是，当只冻结 S3 部分网络层时，其感知性能与本文采取的冻结策略基本相同，且明显优于只冻结 S1 部分的情况。这说明 S3 部分网络层由于包含 3 个残差模块，网络结构更复杂且直接影响重构




图 6 $CR = 1/2$ 时，不同训练方案的平均检测概率和 σ_r^2 的关系图

精度，对保留 DNN_p 的重构能力起关键作用。相比之下，S1 部分对整体性能的影响较小。




图 7 $CR = 1/2$ 时，不同冻结层比例的平均检测概率和 σ_r^2 的关系图

在选取目标训练数据集 $\mathcal{Y}_T$ 的长度为 10 000 的情况下，本文选取不同 CR 下的 DNN_{TR} 对比模型重构性能， $CR = 1$ 时对应预训练模型 DNN_p ，其与 NMSE 和 Υ 的对比曲线如图 8 所示。从图中可以看出，训练得到的 DNN_{TR} 的 NMSE 随着的 CR 减小而增大， Υ 随着 CR 减小而减小，但始终维持在 80% 以上。这是因为本文所采用的压缩方法是基于降维原理， CR 越小，维度越低，码字 ℓ 可表征的数据特征随之减少，不可避免地导致部分信息的丢失，造成重构质量下降。所以在实际应用场景中，需要综合考虑反馈开销与重构质量之间的平衡，选择合适

的压缩比配置。




图8 不同CR下, NMSE和 γ 对比曲线图

为了进一步论证所提方案的优越性，本文引入文献[10]中的决策融合方案作为基线方案，该方案通过各AP独立做出决策，并将二元推理结果发送给融合中心进行最终融合。此外，为提供性能上限参考，本文设置了回传链路容量不受限时AP直接将感知信号反馈给融合中心的理想情况进行比较，记为容量不受限。

本文所提方案基于图8训练出的模型实现感知信号多种压缩比反馈，并执行目标检测。图9展示了不同反馈方案的平均检测概率均随 σ_r^2 的增加而增加。可以看出，本文所提方案基于预训练模型 DNN_p 实现时，已经基本接近容量不受限条件下的平均检测概率上限。由于感知性能与模型重构性能存在强相关性，随着CR的减小，反馈信号所包含的有效信息逐渐减少，导致检测能力逐渐减弱。通过对比可以发现，所提方法采用 $CR = 1/2$ 时相较于决策融合方案在 $\sigma_r^2 \in [-27, -9]$ dB内，平均检测概率提升了33.92%。此外，当 $CR \geq 1/8$ 时，本文的方案与决策融合方案相比展现出更显著的感知性能优势；然而，当 $CR \leq 1/8$ 时，由于过度压缩造成的信息丢失问题加剧，本文所提方案的反馈效果受到限制，此时采用决策融合方案能够更好地维持感知性能。

在图10中展示了在 $\sigma_r^2 = -18$ dB的情况下，不同反馈方案的平均检测概率和AP数量的关系。从图中可以看出，随着AP数量增加，各方案的平均




图9 不同反馈方案的平均检测概率和 σ_r^2 的关系图

检测概率均呈现递增趋势，且本文所提方案表现出更显著的性能提升幅度。这是因为在多节点协作感知机制下，系统能够获取更丰富的目标感知信息。本文所提方案通过将各AP接收到的感知信号压缩回传，充分利用协作感知带来的增益，从而更好地提升感知性能。




图10 $\sigma_r^2 = -18$ dB, 不同反馈方案平均检测概率和AP数量的关系图

5 结语

针对多节点协作ISAC系统中回传链路容量有限的问题，本文提出了一种多节点感知信号智能压缩反馈方法。该方法设计了一种基于自编码器的

DNN 模型, 通过在各个 AP 处部署编码器对感知信号进行特征提取和压缩, 反馈至融合中心利用解码器重构, 并利用重构的感知信号进行目标检测。其次, 针对回传链路容量存在异构性, 提出了基于迁移学习技术的训练框架, 通过预训练、冻结和微调得到不同压缩比的模型, 实现自适应压缩反馈。仿真结果证明, 所提方案训练得到的多种压缩比模型具有更优的重构精度和泛化性能, 对比基线方案能够有效实现感知性能和反馈开销之间的平衡。

值得一提的是, 迁移学习侧重于知识迁移, 而元学习更侧重学习策略, 未来拟在元学习的基础上开展研究, 从而进一步提升感知性能。

参考文献:

- [1] 潘成康. 通信感知一体化技术思考[J]. 中兴通讯技术, 2022, 28(5): 53-56.
- [2] PAN C K. Reflections on Integrated Sensing and Communication Technology[J]. ZTE Technology Journal, 2022, 28(5): 53-56.
- [3] LIU X, HUANG T Y, SHLEZINGER N, et al. Joint Transmit Beamforming for Multiuser MIMO Communications and MIMO Radar[J]. IEEE Transactions on Signal Processing, 2020, 68: 3929-3944.
- [4] LIU F, LIU Y F, LI A, et al. Cramér-Rao Bound Optimization for Joint Radar-Communication Beamforming[J]. IEEE Transactions on Signal Processing, 2022, 70: 240-253.
- [5] ATTIAH K M, YU W. Active beamforming for integrated sensing and communication[C]//2023 IEEE International Conference on Communications Workshops (ICC Workshops). Rome, Italy: IEEE Press, 2023: 1469-1474.
- [6] 王为栋, 高晖, 栗欣, 等. 面向车联网的感知辅助通信的大规模 MIMO-OTFS 鲁棒传输方案[J]. 物联网学报, 2023, 7(4): 39-51.
- [7] WANG W D, GAO H, SU X, et al. A massive MIMO-OTFS robust transmission scheme for vehicular networks using sensing-assisted communication[J]. Chinese Journal on Internet of Things, 2023, 7(4): 39-51.
- [8] LIYANAARACHCHI S D, BAQUERO BARNETO C, RIIHONEN T, et al. Joint Multi-User Communication and MIMO Radar Through Full-Duplex Hybrid Beamforming[C]//2021 1st IEEE International Online Symposium on Joint Communications & Sensing (JC&S). Dresden, Germany: IEEE Press, 2021: 1-5.
- [9] WANG X Y, FEI Z S, ZHANG J A, et al. Constrained Utility Maximization in Dual-Functional Radar-Communication Multi-UAV Networks[J]. IEEE Transactions on Communications, 2021, 69(4): 2660-2672.
- [10] HUANG Y, FANG Y, LI X M, et al. Coordinated Power Control for Network Integrated Sensing and Communication[J]. IEEE Transactions on Vehicular Technology, 2022, 71(12): 13361-13365.
- [11] BEHDAD Z, DEMIR Ö T, SUNG K W, et al. Power Allocation for Joint Communication and Sensing in Cell-Free Massive MIMO [C]//GLOBECOM 2022 - 2022 IEEE Global Communications Conference. Rio de Janeiro, Brazil: IEEE Press, 2022: 4081-4086.
- [12] LOU X Y, XIA W C, WONG K K, et al. Power Optimization for Integrated Active and Passive Sensing in DFRC Systems[J]. IEEE Transactions on Communications, 2024, 72(6): 3365-3377.
- [13] DONG Y Y, WANG H, YANG Z H, et al. Cell-free ISAC massive MIMO systems with capacity-constrained fronthaul links[J]. Digital Signal Processing, 2024, 145: 104341.
- [14] WEN C K, SHIH W T, JIN S. Deep Learning for Massive MIMO CSI Feedback[J]. IEEE Wireless Communications Letters, 2018, 7(5): 748-751.
- [15] HE H T, WEN C K, JIN S, et al. Deep learning-based channel estimation for beamspace mmWave massive MIMO systems[J]. IEEE Wireless Communications Letters, 2018, 7(5): 852-855.
- [16] HE C F, HU Y, CHEN Y, et al. Joint Power Allocation and Channel Assignment for NOMA With Deep Reinforcement Learning [J]. IEEE Journal on Selected Areas in Communications, 2019, 37(10): 2200-2210.
- [17] HUANG H J, SONG Y S, YANG J, et al. Deep-Learning-Based Millimeter-Wave Massive MIMO for Hybrid Precoding[J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 3027-3032.
- [18] BJÖRNSSON E, HOYDIS J, SANGUINETTI L. Massive mimo networks: Spectral, energy, and hardware efficiency[J]. Foundations and Trends in Signal Processing, 2017, 11(3-4): 154-655.
- [19] ZHAO N, WANG Y L, ZHANG Z, et al. Joint Transmit and Receive Beamforming Design for Integrated Sensing and Communication[J]. IEEE Communications Letters, 2022, 26(3): 662-666.
- [20] DEMIR Ö T, BJÖRNSSON E, SANGUINETTI L. Foundations of user-centric cell-free massive MIMO[J]. Foundations and Trends in Signal Processing, 2021, 14(3-4): 162-472.
- [21] ZENG J, SUN J L, GUI G, et al. Downlink CSI Feedback Algorithm With Deep Transfer Learning for FDD Massive MIMO Systems[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(4): 1253-1265.
- [22] KHAWAR A, ABDELHADI A, CLANCY C. Target Detection Performance of Spectrum Sharing MIMO Radars[J]. IEEE Sensors Journal, 2015, 15(9): 4928-4940.
- [23] KAI S, HALL P. Fundamentals of Statistical Signal Processing, Volume II: Detection Theory[M]. Englewood Cliffs, NJ: Prentice-Hall, 1993.
- [24] BEKKERMAN I, TABRIKIAN J. Target Detection and Localization Using MIMO Radars and Sonars[J]. IEEE Transactions on Signal Processing, 2006, 54(10): 3873-3883.
- [25] LOU X L, XIA W C, CHEN S Y, et al. Precoding for Multi-Static ISAC System With Integrated Active and Passive Sensing[J]. IEEE Communications Letters, 2024, 28(9): 2036-2040.
- [26] XIA W C, ZHENG G, ZHU Y X, et al. A Deep Learning Frame-

- work for Optimization of MISO Downlink Beamforming[J]. IEEE Transactions on Communications, 2020, 68(3): 1866-1880.
- [25] CUI Y M, GUO J J, WEN C K, et al. Communication-Efficient Personalized Federated Edge Learning for Massive MIMO CSI Feedback[J]. IEEE Transactions on Wireless Communications, 2024, 23(7): 7362-7375.