



专题：面向6G的通感算一体化

## 无蜂窝通感一体化中多级融合定位机制研究

裴荣康<sup>1,2</sup>, 王洁<sup>1,2</sup>, 李佳珉<sup>1,2</sup>, 王东明<sup>1,2</sup>, 朱鹏程<sup>1,2</sup>

(1. 东南大学移动通信全国重点实验室, 江苏 南京 210096;

2. 东南大学信息科学与工程学院, 江苏 南京 210096)

**摘要:** 随着6G移动通信技术的发展, 通信与感知一体化 (integrated sensing and communication, ISAC) 成为未来无线网络的重要方向。在大规模分布式场景中, 高精度定位仍面临计算和通信开销过大、参数不可靠等挑战。为此, 提出一种多级融合的ISAC定位架构: 在接入点 (access point, AP) 级对感知信号进行预处理, 并将结果上传至边缘分布式单元 (edge distributed unit, EDU); EDU级利用神经网络将信噪比映射为时延参数的权重, 并结合几何精度因子 (geometric dilution of precision, GDOP) 策略进行加权最小二乘局部定位; 中央处理单元 (central processing unit, CPU) 级则在全局视角下对EDU上传的可靠参数进行二次动态筛选与最终定位。仿真结果表明, 该架构能显著降低整体区域内的定位误差, 通信和计算开销均优于集中式方案, 具有良好的系统可扩展性。

**关键词:** 多级融合架构; 通信与感知一体化; 几何精度因子; 神经网络; 无蜂窝

**中图分类号:** TP393

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.2026044

## Research on multi-level fusion localization mechanisms in cell-free integrated sensing and communication systems

Pei Rongkang<sup>1,2</sup>, Wang Jie<sup>1,2</sup>, Li Jiamin<sup>1,2</sup>, Wang Dongming<sup>1,2</sup>, Zhu Pengcheng<sup>1,2</sup>

1. National Mobile Communications Research Laboratory, Southeast University, Nanjing 210096, China

2. School of Information Science and Engineering, Southeast University, Nanjing 210096, China

**Abstract:** With the development of sixth-generation mobile communication systems, integrated sensing and communication (ISAC) is recognized as an important direction for future wireless networks. In large-scale distributed scenarios, high-precision positioning still faces challenges such as excessive computational and communication overhead and unreliable parameters. To address these issues, a multi-level fusion ISAC positioning architecture was proposed: at the access point (AP) level, sensing signals were preprocessed, and the results were uploaded to the edge distributed unit (EDU); at the EDU level, the signal-to-noise ratio was mapped to the weights of delay parameters via a neural network, and weighted least squares local positioning was performed in combination with a geometric dilution of

收稿日期: 2025-08-29; 修回日期: 2025-10-08

通信作者: 李佳珉, jiaminli@seu.edu.cn

基金项目: 江苏省重大科技项目 (No.BG2024002)

**Foundation Item:** Major Science and Technology Project of Jiangsu Province (No.BG2024002)

precision (GDOP) strategy; at the central processing unit (CPU) level, the reliable parameters uploaded by the EDU were subjected to secondary dynamic screening and final positioning from a global perspective. Simulation results demonstrate that the proposed architecture significantly reduces positioning errors across the entire area. Moreover, it outperforms the centralized scheme in both communication and computational overhead, ensuring good system scalability.

**Key words:** multi-level fusion architecture, ISAC, GDOP, neural network, cell-free

## 0 引言

随着6G移动通信及智能化无线网络的发展,通信与感知一体化(integrated sensing and communication, ISAC)已成为未来无线系统的重要方向。ISAC系统不仅需要满足高速率与低时延的通信需求,还需要在复杂的环境中实现高精度的定位与感知<sup>[1]</sup>,而这仍然是一个亟待解决的关键问题。

传统的集中式融合方案通常依赖中央处理单元(central processing unit, CPU)对所有接入点(access point, AP)的原始数据进行统一处理。例如,文献[2]基于CPU分两阶段集中处理所有AP上传的感知信号:第一阶段利用傅里叶变换提取感知参数,第二阶段则去除病态测量值,以实现高精度定位。文献[3]提出了一种集中式融合定位方法,在该方法中每个AP先利用贝叶斯推理生成目标的局部像素级估计,再由CPU集中融合所有AP的局部估计结果。文献[4]提出了一种多天线网络化ISAC系统架构:在不同同步条件和接收机能力下,中心控制器都能通过优化波束成形策略最大化联合检测目标的概率。尽管集中式融合的方式能够最大限度利用所有感知信息,但其劣势同样显著:一方面,大量的原始数据传输和集中处理会带来通信和计算开销的急剧增加;另一方面,观测参数往往容易受到噪声、遮挡等因素的影响,如果不对这些不可靠的参数进行辨别,容易导致系统的定位精度下降。因此,集中式方法在大规模ISAC系统中的扩展性和鲁棒性均存在明显不足。

针对上述问题,近年来,有研究提出分布式或多级处理架构,将部分计算任务下发至本地节点,以降低中心处理单元的压力。文献[5]提出了一种多级协作架构,通过在空间扩展单元与中央处理单元之间进行分层处理,实现了上行通信信号的分级解码,在保证系统性能的同时,显著提升了大规模多输入多输出(multiple-input multiple-output, MIMO)系统的可扩展性和易部署性。文献[6]将无蜂窝大规模MIMO系统划分为远程无线电单元、边缘分布式单元和以用户为中心的分布式单元,分析了三者的部署方式对系统通信性能的影响。然而,现有研究大多聚焦于通信层面的负载均衡,对感知参数在多级架构下的逐层筛选与优化考虑不足。在目标定位的过程中,如何有效剔除不可靠参数,并将高质量结果逐渐上传至更高层级,是实现高精度与可扩展性融合定位的核心挑战。

为此,本文提出了一种多级融合的ISAC定位架构,其处理流程分为AP级、边缘分布式单元(edge distributed unit, EDU)级与CPU级3个层次。在AP级,对接收信号进行初步处理,提取时延和信噪比等参数,并上传至EDU;在EDU级,利用神经网络将信噪比映射为时延参数的可靠性权重,再结合几何精度因子(geometric dilution of precision, GDOP)策略对观测路径进行初步筛选与加权最小二乘融合,从而得到局部的定位估计结果及可靠参数;在CPU级,利用全局视角对来自EDU的可靠观测参数进行二次筛选与优化,最终得到全局范围内的最优定位结果。

该架构兼顾了局部筛选和全局优化的优势,



一方面，有效降低了CPU的数据处理和通信负担；另一方面，通过分级逐步提升参数质量，实现了高精度、强鲁棒性和良好可扩展性的定位性能。该多级融合架构为未来大规模分布式ISAC系统中的高精度定位提供了一种切实可行的参考方案。

## 1 系统模型

### 1.1 无蜂窝通感一体中的多级融合定位架构

本文研究了无蜂窝系统中基于ISAC的多AP协作定位问题。无蜂窝通感一体中的多级融合定位架构如图1所示。在该架构中，有一个CPU，连接着 $G$ 个EDU，而每个EDU通过前传链路连接着 $I$ 个发射AP和 $P$ 个接收AP，每个发射AP和接收AP分别配备了 $N_{\text{tx}}$ 和 $N_{\text{rx}}$ 个水平均匀线性排列的天线。发射AP在通信的基础上，将发送额外的感知符号，与通信符号共用相同的时频资源。接收AP接收来自目标反射的信号，进行处理后逐级上传至EDU和CPU，最终实现目标定位。

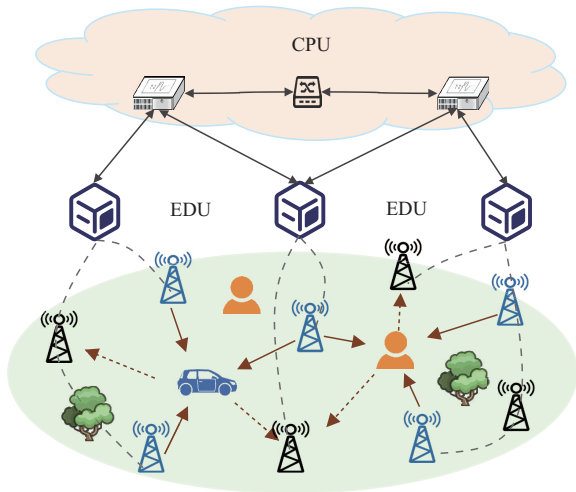


图1 无蜂窝通感一体中的多级融合定位架构

## 1.2 信号模型

### 1.2.1 发送信号模型

在本系统中，信号使用MIMO-OFDM模型。

因此，第 $i$ 个发射AP使用正交频分复用（orthogonal frequency division multiplexing, OFDM）信号，可以表示为<sup>[7]</sup>：

$$x_i(t) = \sum_{m=1}^{M_{\text{sym}}} \sum_{n=1}^{N_c} \text{Re} \left( d_{m,n}^i e^{j2\pi(f_c + n\Delta f)t} \right) \text{rect} \left( \frac{t - (m-1)T}{T} \right) \quad (1)$$

其中， $m$ 和 $n$ 分别表示OFDM子载波和符号的索引， $\text{Re}$ 表示取实部， $N_c$ 和 $M_{\text{sym}}$ 分别表示OFDM的子载波数和符号数； $d_{m,n}^i$ 表示第 $i$ 个发射AP的调制符号； $f_c$ 表示载波频率； $\Delta f = 1/T_{\text{OFDM}}$ 表示子载波间隔， $T_{\text{OFDM}}$ 表示OFDM基本符号的持续时间； $T = T_{\text{OFDM}} + T_{\text{CP}}$ ，表示符号的总持续时间， $T_{\text{CP}}$ 表示循环前缀的持续时间； $\text{rect}(\cdot)$ 表示宽度为 $T$ 的矩形窗函数。

### 1.2.2 接收信号模型

仅考虑单个目标情况下的信号传播，在EDU $g$ 内，对于发射AP $g,i$ ，接收AP $g,p$ 和目标 $s$ ，接收AP $g,p$ 接收来自第 $g,i$ 个发射AP的第 $n$ 个子载波、第 $m$ 个OFDM符号上的信号可以表示为<sup>[8]</sup>：

$$y_{g,p}^i(m,n) = b_{g,p}^i e^{j2\pi m T f_{g,p}^i} e^{-j2\pi n \Delta f \tau_{g,p}^i} \mathbf{a}_{\text{rx},g,p}^T(\phi_{g,p}) \mathbf{a}_{\text{tx},g,i}^T(\theta_{g,i}) \mathbf{x}_{m,n}^{g,i} + \mathbf{z}_{g,p}^i \quad (2)$$

其中， $b_{g,p}^i = \frac{\lambda^2}{\sqrt{(4\pi)^3 (r_s^{g,i})^2 (r_{g,p}^s)^2}} \zeta$ 是信号传播过程的衰减， $\zeta$ 是目标反射系数， $\lambda = c/f_c$ 为信号波长； $f_{g,p}^i$ 表示多普勒频移； $\tau_{g,p}^i = (r_s^{g,i} + r_{g,p}^s)/c$ 表示信号传播时延； $\mathbf{x}_{m,n}^{g,i} \in \mathbb{C}^{N_{\text{tx}} \times 1}$ 表示第 $g$ 个EDU中发射AP $g,i$ 发送的感知符号； $\mathbf{z}_{g,p}^i \in \mathbb{C}^{N_{\text{rx}} \times 1}$ 表示均值为0、方差为 $\sigma^2$ 的加性复高斯白噪声矢量。

通感信号传播示意图如图2所示。图中， $r_s^{g,i}$ 和 $r_{g,p}^s$ 分别表示发射AP $g,i$ 到目标 $s$ 、目标 $s$ 到接收AP $g,p$ 的直线距离； $\phi_{g,p}$ 和 $\theta_{g,i}$ 分别表示到达角




图2 通感信号传播示意图

和离开角； $\mathbf{a}_{\text{rx},g,p}(\phi_{g,p})$ 和 $\mathbf{a}_{\text{tx},g,i}(\theta_{g,i})$ 分别表示接收 AP  $g,p$  的导向矢量和发射 AP  $g,i$  的导向矢量<sup>[9]</sup>，表达式如式 (3) 和式 (4) 所示。

$$\mathbf{a}_{\text{rx},g,p}(\phi_{g,p}) = \begin{bmatrix} e^{j2\pi\left(\frac{d_r}{\lambda}\right)\sin(\phi_{g,p})}, e^{j4\pi\left(\frac{d_r}{\lambda}\right)\sin(\phi_{g,p})}, \dots, e^{jN_{\text{rx}}2\pi\left(\frac{d_r}{\lambda}\right)\sin(\phi_{g,p})} \end{bmatrix}^T \quad (3)$$

$$\mathbf{a}_{\text{tx},g,i}(\theta_{g,i}) = \begin{bmatrix} e^{j2\pi\left(\frac{d_r}{\lambda}\right)\sin(\theta_{g,i})}, e^{j4\pi\left(\frac{d_r}{\lambda}\right)\sin(\theta_{g,i})}, \dots, e^{jN_{\text{tx}}2\pi\left(\frac{d_r}{\lambda}\right)\sin(\theta_{g,i})} \end{bmatrix}^T \quad (4)$$

其中， $d_r$ 是相邻两根天线之间的距离。

综合所有 EDU 中的所有发射 AP，EDU  $g$  中的接收 AP  $g,p$  接收到的信号总和可以表示为：

$$Y_{g,p}(m,n) = \sum_{g=1}^G \sum_{i=1}^I y_{g,p}^i(m,n) \quad (5)$$

对接收 AP 的接收信号进行处理，可以估计对应的时延参数，并且进行融合定位。

## 2 多级融合定位机制

多级融合定位方案示意图如图3所示。首先，由 AP 进行信号初步处理，以提取时延和信噪比信息，并上传至 EDU。然后，神经网络将信噪比 (signal-to-noise ratio, SNR) 转化为时延参数的最优权重，以评估其可靠性，并利用 GDOP 筛选更加可靠的时延参数，以及进行 EDU 级的局部融合，得到目标定位的初步估计值，将结果继续上传至 CPU。最后，CPU 基于全局视角重新筛选 AP 估计的时延参数，以得到更加精确的定位值。下面将详细阐述 AP 级、EDU 级和 CPU 级的功能和算法。

### 2.1 AP 级处理

广泛分布的发射 AP、接收 AP 可从多个地理位置和角度发送、接收感知信号，从而采集更加丰富且全面的感知信息，并覆盖更大的感知区域。在现有集中式定位架构中，AP 通常仅作为透明转发节点，将原始接收信号直接上传至 CPU<sup>[10]</sup>。这种方式虽然能够保留完整信息，却会带来巨大的通信负担和数据冗余，不利于大规模系统的实时运行。为此，本文在 AP 级引入轻量化处理策略，通过本地化的信号预处理，仅提取关键的时延参数和信噪比，实现对上传数据的有效压缩与特征提取。这一设计既减轻了网络通信压力，又为后续 EDU 和 CPU 的融合奠定了高效、可靠的基础。下面将详细说明 AP 的信号处理

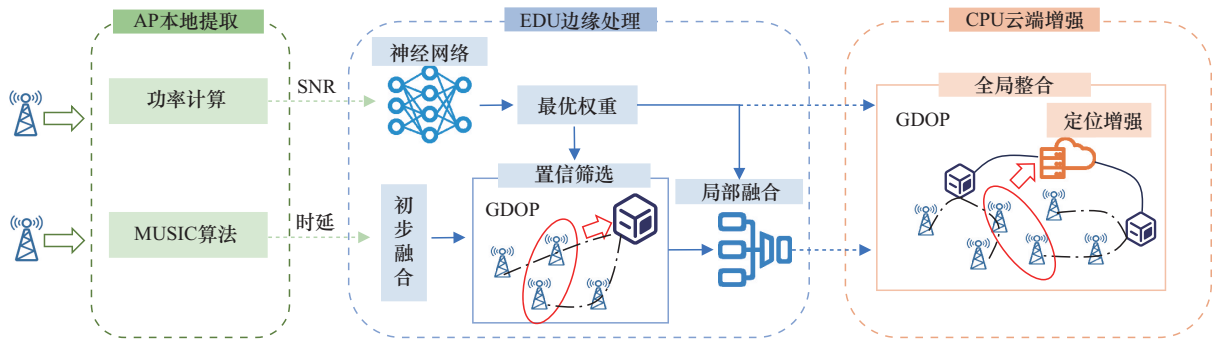


图3 多级融合定位方案示意图



方法。

考虑所有 AP 都通过 EDU 和 CPU 连接起来，发射的感知符号  $x_{m,n}^{g,i}$  是已知的，因此将接收 AP  $g,p$  的接收信号  $y_{g,p}^i(m,n)$  (见式 (2))，右乘  $x_{m,n}^{g,i}$  的广义逆矩阵  $\mathbf{X}_{m,n}^f = \left( x_{m,n}^{g,i} \left( x_{m,n}^{g,i} \right)^H + \rho \mathbf{I} \right)^{-1}$  得到<sup>[8]</sup>：

$$y_{g,p}^i(m,n) \mathbf{X}_{m,n}^f = b_{g,p}^i e^{j2\pi n T f_{g,p}^i} e^{-j2\pi n \Delta f t_{g,p}^i} \mathbf{a}_{\text{rx},g,p}^T(\phi_{g,p}) \mathbf{a}_{\text{tx},g,p}^T(\theta_{g,i}) \mathbf{I} + \mathbf{z}_{g,p}^i \mathbf{X}_{m,n}^f \quad (6)$$

其中， $\mathbf{I}$  是单位阵； $\rho$  是一个正则化参数，用于提高稳定性和精度。

式 (6) 可以看作等效提取由发射 AP  $g,i$  经过目标反射到达接收 AP  $g,p$  的信道  $\hat{H}_{g,p}^i$ ，可以写作：

$$\hat{H}_{g,p}^i(m,n) = y_{g,p}^i(m,n) \mathbf{X}_{m,n}^f \quad (7)$$

将所有子载波和 OFDM 符号的信道写为一个矩阵，即：

$$\hat{\mathbf{H}}_{g,p}^i = \begin{bmatrix} \hat{H}_{g,p}^i(1,1) & \cdots & \hat{H}_{g,p}^i(1,N) \\ \vdots & \ddots & \vdots \\ \hat{H}_{g,p}^i(M,1) & \cdots & \hat{H}_{g,p}^i(M,N) \end{bmatrix} \quad (8)$$

### 2.1.1 MUSIC 算法估计时延

观察式 (6) 可知，传播时延沿着  $N$  个子载波引入了线性相移，因此可以使用多信号分类 (multiple signal classification, MUSIC) 算法估计时延。首先，计算协方差矩阵  $\hat{\mathbf{R}}_{g,n}^i$ <sup>[11]</sup>，过程如下：

$$\mathbf{H}_{g,p,\text{delay}}^i(n_{\text{rx}}, n_{\text{tx}}) = \hat{\mathbf{H}}_{g,p}^i \begin{vmatrix} \mathbf{a}_{\text{rx},g,p}(\phi_{g,p}) = e^{jn_{\text{rx}}2\pi\left(\frac{d_t}{\lambda}\right)\sin(\phi_{g,p})}, & \mathbf{a}_{\text{tx},g,i}(\theta_{g,i}) = e^{jn_{\text{tx}}2\pi\left(\frac{d_t}{\lambda}\right)\sin(\theta_{g,i})} \end{vmatrix} \quad (9)$$

$$\hat{\mathbf{R}}_{g,n}^i = \frac{1}{N_{\text{rx}} N_{\text{tx}}} \sum_{n_{\text{rx}}=1}^{N_{\text{rx}}} \sum_{n_{\text{tx}}=1}^{N_{\text{tx}}} \mathbf{H}_{g,p,\text{delay}}^i(n_{\text{rx}}, n_{\text{tx}}) \left( \mathbf{H}_{g,p,\text{delay}}^i(n_{\text{rx}}, n_{\text{tx}}) \right)^H \in \mathbb{C}^{M \times N} \quad (10)$$

然后，将协方差矩阵  $\hat{\mathbf{R}}_{g,n}^i$  进行特征值分解，

得到：

$$\text{eig}\left(\hat{\mathbf{R}}_{g,n}^i\right) = \mathbf{E}_s \mathbf{D}_s \mathbf{E}_s^H + \mathbf{E}_n \mathbf{D}_n \mathbf{E}_n^H \quad (11)$$

其中， $\mathbf{D}_s$  和  $\mathbf{D}_n$  分别表示信号子空间和噪声子空间的特征值对角矩阵， $\mathbf{E}_s$  和  $\mathbf{E}_n$  分别表示对应的特征向量矩阵。

接着，构造二维 MUSIC 谱函数  $f_{2\text{D-MUSIC}}(\tau, \sim)$ ，其表达式如下：

$$f_{2\text{D-MUSIC}}(\tau, \sim) = \frac{1}{[\boldsymbol{\mu} \otimes \mathbf{v}]^H \mathbf{E}_n \mathbf{E}_n^H [\boldsymbol{\mu} \otimes \mathbf{v}]} \quad (12)$$

$$\boldsymbol{\mu} = \left[ e^{-j2\pi\Delta f \tau}, e^{-j4\pi\Delta f \tau}, \dots, e^{-j2\pi N \Delta f \tau} \right]^T \quad (13)$$

$$\mathbf{v} = \left[ e^{j2\pi T f}, e^{j4\pi T f}, \dots, e^{j2\pi M T f} \right]^T \quad (14)$$

最后，搜索谱函数  $f_{2\text{D-MUSIC}}(\tau, \sim)$  的峰值，得到对应时延的坐标，即时延的估计结果。

### 2.1.2 信噪比计算

接收 AP 的 SNR 可以写为如下形式<sup>[12]</sup>：

$$\text{SNR}_{g,p}^i = \frac{1}{N_{\text{rx}} N_{\text{tx}}} \sum_{n_{\text{rx}}=1}^{N_{\text{rx}}} \sum_{n_{\text{tx}}=1}^{N_{\text{tx}}} \left\| \mathbf{H}_{g,p,\text{delay}}^i(n_{\text{rx}}, n_{\text{tx}}) \right\|^2 \quad (15)$$

$$MN\sigma^2$$

所有接收 AP 进行同样的处理，最后将时延的估计值和 SNR 上传至相应的 EDU。接下来将继续介绍 EDU 的可靠性筛选和基于神经网络的局部融合定位。

## 2.2 EDU 级处理

在集中式架构中，AP 将原始信号或提取的参数统一上传至 CPU 进行融合定位。这种方式能够充分利用全局信息，但在实际系统运行中往往面临着许多问题：其一，将所有原始信号或完整参数直接上传至 CPU，会带来极大的通信开销与处理延迟；其二，CPU 需要在大规模异构数据中直接进行筛选与融合，难以有效抑制低质量测量结果的影响；其三，此类“单级处理”模式使系统计算负荷集中在 CPU，限制了其扩展性与实时性。为此，本文提出一种多级融合定位架构，增设 EDU 作为中间处理层级。EDU 在局部范围内

利用神经网络和GDOP筛选可靠的时延参数并完成初步定位，再将定位结果与可靠参数上传至CPU。该设计有效缓解了集中式架构的通信与计算压力，同时通过逐级筛选保证了参数质量，为CPU实现全局精确定位提供了更准确的输入。下面将详细介绍EDU级的筛选机制和融合定位方法。

### 2.2.1 基于遗传算法训练神经网络的权重优化方法

在基于时延参数的定位方法中，传统的最大似然估计和加权最小二乘等方法通常依赖于时延估计误差的统计分布已知这一前提<sup>[13]</sup>。然而，在实际场景中，时延估计误差的分布往往难以建模或准确获取，导致难以设置合适的权重以提升定位精度。针对这一问题，本文提出一种基于遗传算法训练神经网络的权重优化算法，见算法1。该方法无须事先假设误差分布，即可自适应地建立SNR与权重之间的映射关系，从而有效克服传统方法的局限，显著提升定位性能。

**算法1** 基于遗传算法训练神经网络的权重优化算法

**输入** 训练数据（若干组时延估计值、SNR、真实位置）、种群规模、最大迭代次数

**输出** 优化后的神经网络参数 $\Theta$

**初始化阶段：**

初始化神经网络、种群（每个个体代表一组神经网络参数）、交叉率、变异率；

**进化阶段：**

神经网络预测：遍历所有个体，构建神经网络，输入归一化SNR，输出预测的定位权重；

定位计算：利用预测的权重和时延参数进行加权最小二乘定位，得到估计位置；

适应度评估：计算所有组的定位误差之和 $f_j = \sum_j \|\hat{\mathbf{p}}_j - \mathbf{p}_{\text{true}}\|$ ，并取负作为适应度；

遗传操作：根据适应度进行选择、交叉、变异；

**终止阶段：**

若满足收敛条件或达到最大迭代次数，输出适应度最优的个体作为神经网络的最终参数。

由第2.1节可知，EDU获得了AP上传的时延估计值及相应的SNR。SNR在一定程度上反映了时延估计的误差大小，但是其与融合定位的最佳权重之间的关系是未知的，而融合权重本质体现了不同时延参数之间的相对可靠性，因此将所有时延参数对应的SNR归一化后，再进行神经网络训练，这样就能够使该神经网络具有更好的普适性，即便是不同大小的SNR归一化后输入神经网络，都能得到更优的融合权重。因此，使用神经网络代替二者之间映射关系的方案是合理且可行的。

考虑遗传算法具有全局搜索能力强、鲁棒性高等特点，将其用于神经网络参数的训练，以便找到更优的神经网络参数，最大限度接近SNR和最佳融合定位权重之间的映射关系。在算法1中，首先初始化神经网络结构和遗传算法参数（包括种群规模、交叉率、变异率），每个个体表示一组神经网络参数；在进化过程中，神经网络以SNR作为输入预测融合定位权重，再结合时延参数通过最小二乘方法计算目标位置，并以定位误差为适应度评价个体优劣；然后，通过选择、交叉和变异不断进化种群；最终，当满足收敛条件或者达到迭代上限时，定位误差最小的个体即最终的神经网络参数。

(1) 参数传递量分析

在本算法中，参数传递主要包括以下两类。

神经网络参数传递，每个个体的基因编码即神经网络参数，包括各层权重和偏置项。设神经网络输入层、隐藏层和输出层的节点数分别为 $N_{\text{in}}$ 、 $N_{\text{h}}$ 、 $N_{\text{out}}$ ，则每个个体需传递的参数量为：

$$N_{\text{param}} = N_{\text{in}} \times N_{\text{h}} + N_{\text{h}} + N_{\text{h}} \times N_{\text{out}} + N_{\text{out}} \quad (16)$$

因此，整个种群的参数传递总量为：

$$N_{\text{pop}} \times N_{\text{param}} \quad (17)$$



其中,  $N_{\text{pop}}$  为种群规模。该参数量决定了每次迭代中神经网络的构建与更新开销。

定位参数传递, 每次神经网络预测权重后, 需要在EDU侧或CPU侧进行加权最小二乘定位。此过程中传递的主要参数包括时延估计值、SNR以及对应的权重向量, 参数规模为  $O(M_{\text{path}})$ , 其中  $M_{\text{path}}$  表示AP对(或路径)数量。

### (2) 误差传递分析

在定位过程中, 误差主要来源于两部分: 时延估计误差的传递和神经网络预测误差的传递。

① 时延估计误差的传递: 时延估计误差  $\Delta\tau_i$  会通过定位方程传递到位置误差中。对于加权最小二乘估计, 其误差传递可表示为:

$$\Delta p \approx (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W} \Delta \tau \quad (18)$$

其中,  $\mathbf{H}$  为时延关于位置的雅可比矩阵,  $\mathbf{W}$  为神经网络预测得到的权重矩阵。

可见,  $\mathbf{W}$  的合理性直接决定了误差传播的放大或抑制效果。

② 神经网络预测误差的传递: 若神经网络预测权重与真实最优权重存在偏差  $\Delta \mathbf{W}$ , 则其对定位误差的传递可近似为:

$$\Delta p_w \approx -(\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \Delta \mathbf{W} \mathbf{H} (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W} \Delta \tau \quad (19)$$

这表明, 若神经网络预测精度较高, 误差传递将得到显著抑制。遗传算法通过全局搜索优化神经网络参数, 有助于降低该传递链路中的累计误差, 从而提高整体定位精度和鲁棒性。

### (3) 复杂度分析

算法总体复杂度由以下3个部分组成: 神经网络前向计算复杂度、定位计算复杂度和遗传进化复杂度。

① 神经网络前向计算复杂度: 对于单个个体, 神经网络的前向计算复杂度约为  $O(N_{\text{in}} N_{\text{h}} + N_{\text{h}} N_{\text{out}})$ 。种群规模为  $N_{\text{pop}}$  时, 总计算复杂度为

$O(N_{\text{pop}} N_{\text{in}} N_{\text{h}} + N_{\text{pop}} N_{\text{h}} N_{\text{out}})$ 。

② 定位计算复杂度: 每次前向预测后须进行一次加权最小二乘定位, 若路径数为  $M_{\text{path}}$ , 则矩阵运算复杂度约为  $O(M_{\text{path}}^3)$ 。

③ 遗传进化复杂度: 遗传算法每代包括选择、交叉和变异操作, 复杂度分别为  $O(N_{\text{pop}})$  和  $O(N_{\text{pop}})$ , 整体为  $O(N_{\text{pop}})$ 。

综上, 设最大进化代数为  $N_{\text{max}}^{\text{GA}}$ , 则总体复杂度为:

$$O\left(N_{\text{max}}^{\text{GA}} \left[ N_{\text{pop}} \left( N_{\text{in}} N_{\text{h}} + N_{\text{h}} N_{\text{out}} + M_{\text{path}}^3 \right) \right] \right) \quad (20)$$

### 2.2.2 基于GDOP的AP筛选方法

现有研究在对AP的利用上, 多采用集中式架构直接处理所有AP上报的时延数据, 未考虑AP地理分布差异带来的影响。当大量AP广泛部署时, 不同位置的AP与目标间信号传播特性存在显著差异, 部分AP因为距离过远、遮挡严重等因素, 其估计的时延误差较大。若将这些低质量时延数据直接用于融合定位, 将引入较大噪声, 从而降低整体定位精度<sup>[14]</sup>。为有效提升定位精度, 本文引入GDOP作为AP筛选指标。GDOP能够综合评估AP的空间分布情况, 优先选取几何分布较优且测量可靠的AP组合, 从而降低几何结构引起的误差对定位结果的影响<sup>[15]</sup>。在多级融合定位架构中, EDU在局部范围内基于GDOP指标, 选取能够最大化定位精度的AP组合进行初步定位与参数筛选。该策略充分利用了EDU本地化处理的优点, 在为CPU全局精确定位提供高质量输入的同时, 也有效减轻了CPU的计算负担。

由第1节可知, 信号的传播距离  $r_{g,p}^i = r_s^{g,i} + r_{g,p}^s$ 。设第  $g$  个EDU内发射AP  $g,i$ 、接收AP  $g,p$  和目标  $s$  的位置分别为  $\mathbf{o}_{g,i}$ 、 $\mathbf{o}_{g,p}$  和  $\mathbf{x}_s \in \mathbb{R}^{2 \times 1}$ , 则信号传播距离的测量值可以写为:

$$\hat{r}_{g,p}^i = \|\mathbf{x}_s - \mathbf{o}_{g,i}\| + \|\mathbf{x}_s - \mathbf{o}_{g,p}\| + n_{g,p}^i \quad (21)$$

其中,  $n_{g,p}^i$  是测量误差。

将式 (21) 进行一阶截断泰勒级数展开<sup>[16]</sup>, 得到传播距离误差为:

$$\Delta r_{g,p}^i \approx \left( \frac{\partial r_{g,p}^i}{\partial \mathbf{x}_s} \right)^T \mathbf{x}_s \quad (22)$$

$$\frac{\partial r_{g,p}^i}{\partial \mathbf{x}_s} = \frac{\mathbf{x}_s - \mathbf{o}_{g,i}}{\|\mathbf{x}_s - \mathbf{o}_{g,i}\|} + \frac{\mathbf{x}_s - \mathbf{o}_{g,p}}{\|\mathbf{x}_s - \mathbf{o}_{g,p}\|} \quad (23)$$

从误差传播的角度来看, 式 (23) 描述了传播距离误差关于目标、发射 AP 和接收 AP 的变化关系, 因此将式 (23) 定义为方向矢量  $\mathbf{l}_{g,p}^i = (\nabla_{\mathbf{x}_s} r_{g,p}^i)^T \in \mathbb{R}^{1 \times 2}$ 。由于融合定位需要多对发射 AP、接收 AP 的时延, 现在考虑在 EDU  $g$  内的  $L$  个发射 AP 和  $R$  个接收 AP ( $L \leq I, R \leq P$ ), 则一共有  $L \times R$  个方向矢量, 可以写为方向矢量矩阵  $\mathbf{A}$ 。其表达式如下:

$$\mathbf{A} = [\mathbf{l}_{g,1}^1, \mathbf{l}_{g,2}^1, \dots, \mathbf{l}_{g,R}^L]^T \in \mathbb{R}^{LR \times 2} \quad (24)$$

关于  $L$  个发射 AP 和  $R$  个接收 AP 的 GDOP 为:

$$\text{GDOP}_{L,R} = \sqrt{\text{trace}\left(\left(\mathbf{A}^T \mathbf{W} \mathbf{A}\right)^{-1}\right)} \quad (25)$$

其中,  $\mathbf{W} = \text{net}(\text{SNR})$  是权重系数矩阵, 由对应  $L \times R$  条路径的 SNR 经过神经网络预测得到。

(1) 误差传递分析。由 AP 位置或目标估计误差造成的方向矢量矩阵扰动  $\hat{\mathbf{A}} = \mathbf{A} + \Delta \mathbf{A}$ , 以及权重矩阵的扰动  $\hat{\mathbf{W}} = \mathbf{W} + \Delta \mathbf{W}$ , 对 GDOP 进行一阶展开, 则计算的 GDOP 偏差为:

$$\Delta \text{GDOP} \approx -\frac{1}{2\text{GDOP}} \text{trace}\left(\mathbf{Q}^{-1} \Delta \mathbf{Q} \mathbf{Q}^{-1}\right) \quad (26)$$

$$\mathbf{Q} \triangleq \mathbf{A}^T \mathbf{W} \mathbf{A} \quad (27)$$

$$\Delta \mathbf{Q} = \mathbf{A}^T \Delta \mathbf{W} \mathbf{A} + \mathbf{A}^T \mathbf{W} \Delta \mathbf{A} + (\Delta \mathbf{A})^T \mathbf{W} \mathbf{A} \quad (28)$$

考虑计算 GDOP 需要先预估目标位置, 因此在 EDU 级可以先选择 SNR 较大的几个 AP 对, 进行初步的最小二乘融合定位, 得到目标位置的初步估计值。接着, 设置 EDU 级所需的最大可靠路径数量。最后, EDU 就能通过贪婪算法依次选择对应数量的可靠 AP 对 (或路径), 具体算法见

算法 2。

**算法 2** 基于贪婪算法的 GDOP 最优路径选择算法

**输入** 发射 AP 集合、接收 AP 集合、SNR 矩阵、神经网络、目标位置、最大路径数

**输出** 选中的 AP 对集合

**初始化:**

构建所有可能的发射-接收 AP 对集合;

初始化已选路径集合和 GDOP 列表;

**贪婪选择路径:**

遍历候选 AP 集合, 使用式 (25) 计算加入当前已选路径后的 GDOP 大小;

将 GDOP 值最小的 AP 对加入已选路径集合;

**更新可用路径:**

从候选 AP 集合中移除已选路径;

将该已选路径的 GDOP 值记录至列表;

继续迭代, 直至已选路径数达到最大路径数。

设基于 GDOP 选择的 AP 对数量为  $U$ , 神经网络预测的权重系数为  $\mathbf{W}$ , 则 EDU 可以用加权最小二乘算法定位目标, 目标函数可以表示为<sup>[17]</sup>:

$$\min_{\hat{\mathbf{x}}_s} J(\hat{\mathbf{x}}_s) = \mathbf{e}(\hat{\mathbf{x}}_s)^T \mathbf{W} \mathbf{e}(\hat{\mathbf{x}}_s) \quad (29)$$

其中,  $\mathbf{W} = \text{diag}(w_1, w_2, \dots, w_U)$ ;  $\mathbf{e}(\hat{\mathbf{x}}_s) = [e_1(\hat{\mathbf{x}}_s), e_2(\hat{\mathbf{x}}_s), \dots, e_U(\hat{\mathbf{x}}_s)]^T$  是时延误差矢量, 其表达式如下:

$$e_u(\hat{\mathbf{x}}_s) = \left| \frac{\|\hat{\mathbf{x}}_s - \mathbf{o}_{g,i}\| + \|\hat{\mathbf{x}}_s - \mathbf{o}_{g,p}\|}{c} - \hat{\tau}_{g,u} \right| \quad (30)$$

其中,  $c$  是光速,  $u$  表示第  $u$  个时延误差。

(2) 复杂度分析。由算法 2 可知, 该贪婪算法的总复杂度可近似写为:

$$\sum_{d=1}^D (S-d+1) O(d^2) \approx O(S \cdot D^3) \quad (31)$$

其中,  $S$  是候选集合的路径总数,  $D$  是需要选择的路径数量。

EDU 在融合定位后, 继续将定位结果和相关



的可靠时延参数、SNR等上传至CPU进行进一步处理。

### 2.3 CPU级处理

尽管EDU能够在局部范围内完成初步的参数筛选与融合定位，但其结果仍然受到局部观测范围和参数质量的限制，尤其在EDU覆盖边缘区域或存在障碍物遮挡等复杂场景下，难以从全局视角确保定位性能最优。为进一步提升系统精度与鲁棒性，本研究在CPU级引入了全局视角的融合机制。CPU不再直接处理所有原始观测数据，而是基于EDU上传的可靠感知参数（包括时延估计值和SNR）进行二次筛选与全局优化。这种设计使得CPU的处理更加聚焦于全局定位性能的优化，而非数据层面的集中处理，从而在提升精度的同时，也增强了系统的可扩展性。

#### 2.3.1 CPU二次筛选与全局优化定位

具体而言，EDU级的处理以单个EDU为中心，融合其下属所有AP的观测信息，生成初步的定位结果及可靠参数。CPU在接收到来自各EDU的可靠感知参数后，能够从全局视角重新构建优化过程：首先，根据SNR，基于神经网络模型预测各路径的加权系数，以提高参数加权的准确性；其次，使用基于贪婪算法的GDOP最优路径选择策略，进一步筛选出一组最优的AP对集合；最后，结合式(29)所定义的加权最小二乘方法，计算出全局优化的定位结果。

从实现机制上看，该过程等效于以目标为中心重新对全局AP进行动态分簇，确保在全局范围内最大化定位精度。相比于传统的集中式CPU

融合方案，本文所提的多级融合架构不仅减少了CPU的数据处理负担，而且具备更强的鲁棒性与适应性。即使部分EDU在局部融合阶段的定位性能不佳，CPU仍能够通过全局参数优化实现更高的定位精度与稳定性。

#### 2.3.2 多级融合架构的复杂度分析

为全面评估所提的多级融合架构与传统CPU集中式处理的效率差异，本文分别对比了两种架构的上传数据量与计算复杂度。两种架构的复杂度对比见表1。其中， $K$ 表示路径总数； $G$ 表示EDU的数量； $d_{NN}$ 表示神经网络单次预测权重的开销； $\gamma$ 、 $\beta$ 分别表示单个EDU级、CPU级的路径筛选数量。

在传统CPU集中式处理框架中，所有AP的处理结果需要上传至CPU，其上传数据量为 $O(K)$ 。CPU需要对所有路径进行神经网络预测权重和加权最小二乘定位，计算复杂度约为 $O(Kd_{NN}+K^3)$ 。

在多级融合架构中，处理被分为EDU和CPU两级进行。在EDU级，各个EDU先对接入的AP数据进行神经网络预测权重，并利用贪婪GDOP算法进行路径筛选及加权最小二乘定位，其复杂度可以写为 $O(Kd_{NN}+K(\gamma G)^3+(\gamma G)^3)$ ，AP上传至EDU的数据量为 $O(K)$ ；在CPU级，EDU上传至CPU的数据量为 $O(\gamma G)$ 。CPU需要对这些数据重新进行神经网络预测、二次筛选和融合定位，其计算复杂度为 $O(\gamma Gd_{NN}+\gamma G\beta^3+\beta^3)$ 。

表1 CPU集中式处理和多级融合架构的复杂度对比

对比项	CPU集中式处理	多级融合架构	
		CPU级	EDU级
上传数据量	$O(K)$	$O(\gamma G)$	$O(K)$
计算量	$O(Kd_{NN}+K^3)$	$O(\gamma Gd_{NN}+\gamma G\beta^3+\beta^3)$	$O(Kd_{NN}+K(\gamma G)^3+(\gamma G)^3)$
总和	$O(K+Kd_{NN}+K^3)$	$O(\gamma G+\gamma Gd_{NN}+\gamma G\beta^3+\beta^3+K+Kd_{NN}+K(\gamma G)^3+(\gamma G)^3)$	

从通信开销的角度来看，CPU 集中式处理与多级融合架构在 EDU 端接收的观测数据量均与系统总感知路径数成正比。然而，在多级融合架构中，CPU 仅接收各 EDU 上传的数据，其数据量取决于 EDU 的数量及单个 EDU 保留的路径数。因此，多级融合架构将部分通信负担下发至 EDU 端，从而显著降低了 CPU 前传链路的通信压力。

从计算开销的角度来看，CPU 集中式处理的计算复杂度与路径总数的三次方成正比。当 AP 数量增加时，CPU 的计算压力急剧上升，难以适应大规模系统的扩展需求。相比之下，多级融合架构通过逐级筛选和分布式处理，将全局计算任务分解至 EDU 层和 CPU 层协同完成。由于每一级所保留的可靠路径数量基本稳定，该架构的整体计算复杂度近似随着总路径数线性增长，从而保证了系统的可扩展性。

### 3 仿真分析

本节仿真分析了无蜂窝 ISAC 多级融合定位系统中基于神经网络预测权重的定位性能、基于 GDOP 的路径选择策略和 CPU 的全局动态筛选的定位性能。简单起见，该多级融合定位系统的仿真在二维平面进行，仿真的定位误差使用均方根误差 (root mean square error, RMSE) 来表示，仿真结果由 4 000 次蒙特卡罗模拟得到，关键的仿真参数设置见表 2。

在使用遗传算法训练神经网络时，适应度随训练轮次的变化情况，即基于遗传算法训练神经网络收敛图如图 4 所示。从图 4 可以看出，适应度在初始阶段随着训练轮次迅速增加，表明遗传算法能够在全局搜索中快速淘汰不良个体。在随后的进化过程中，适应度曲线上升速度逐渐减缓，直至趋于平稳，说明种群逐步收敛至较优解。这种收敛趋势验证了训练神经网络的有效性，表明该神经网络能够很好地代替 SNR 与最佳权重之间的映射关系。

表 2 仿真参数设置

参数	值
EDU 数量	4
发射、接收 AP 数量 (单个 EDU 内)	4
AP 的天线数	8
目标数量	1
EDU 范围	半径为 200 m 的圆
SNR	-6 ~ 6 dB
OFDM 子载波数	32
OFDM 符号数	16
载波频率	10 GHz
子载波间隔	60 kHz




图 4 基于遗传算法训练神经网络收敛图

为验证本文提出的基于神经网络预测权重与 GDOP 筛选机制的有效性，在 EDU 级进行不同算法的定位性能对比分析，如图 5 所示。对比算法包括以下 4 种。(1) SNR-EDU，文献[18]中假设信号传播距离测量误差服从高斯分布，推导出距离估计的克拉美罗界与 SNR 成反比，此时加权最小二乘的最佳权重正比于 SNR。本算法中，EDU 采用正比于 SNR 的权重进行加权最小二乘定位。(2) NN-EDU，EDU 只使用神经网络预测权重进行加权最小二乘定位。(3) GDOP-EDU，EDU 只使用 GDOP 筛选机制进行最小二乘定位，无权重优化。(4) GDOP+NN-EDU，EDU 使用神经网络预测权重和基于 GDOP 筛选机制进行加权最小二乘定位。



图5显示，“NN-EDU”曲线位于“SNR-EDU”曲线左侧，表明本文采用遗传算法训练的神经网络能够更准确地拟合SNR与最优权重间的关系。由于距离估计误差服从高斯分布的假设在实际场景中往往不成立，因此基于SNR正比权重的性能低于基于神经网络预测权重的方案。“GDOP-EDU”曲线同样位于“SNR-EDU”的左侧，说明EDU基于GDOP筛选AP能够充分考虑AP的几何分布特性，筛选出具有更优几何构型和更可靠感知参数的AP，从而提高定位精度。当SNR较低（即定位误差较大）时，“GDOP-EDU”曲线性能优于“NN-EDU”曲线，这是因为GDOP筛选机制可有效剔除误差较大的异常路径，降低极端误差对整体定位结果的影响。相反，在信噪比较高时，大部分路径参数误差较小，GDOP筛选机制带来的性能提升有限，此时基于神经网络预测权重的方案能够更充分地利用高质量路径的信息，因而表现出更优的性能。最后，“GDOP+NN-EDU”曲线的定位误差最小，其累积分布函数（cumulative distribution function, CDF）曲线最靠左，表明在EDU级同时结合GDOP筛选机制与神经网络预测权重的加权最小二乘方法，能够兼顾路径筛选的可靠性与权重分配的精确性，显著提升EDU级的定位精度。

为验证所提多级融合定位框架的有效性，本文对EDU级与CPU级的定位性能进行了仿真对比。EDU级采用GDOP+NN-EDU方法，即结合GDOP筛选机制和神经网络预测权重进行加权最小二乘定位。CPU级采用New Cluster-CPU方法，该方法采用二次动态筛选：先由各EDU基于神经网络预测权重、GDOP路径筛选以及加权最小二乘完成初步定位，再由CPU从全局视角对EDU上传的可靠感知数据再次执行相同流程。在感知覆盖区域内，仿真得到了二者的定位误差空间分布热力图，如图6所示，图6中白色五角星代表EDU的位置。此外，还得到了EDU级和CPU级

的定位误差累积分布对比，如图7所示。




图5 EDU级不同算法定位性能对比

图6表明，在感知的中心区域，即EDU的覆盖核心区域，EDU级能够实现较好的定位性能；而在EDU覆盖范围的边缘部分，定位误差相对较大，反映出了EDU仅依赖局部观测的局限性。相比之下，基于二次动态筛选的CPU级方案（New Cluster-CPU）在不同空间位置上均表现出更高的稳定性和准确性。在感知中心区域，CPU级的定位误差低于EDU级。尤其在边缘区域，CPU级能够显著降低定位误差，有效改善了EDU在边缘定位性能差的问题。

图7进一步展示了EDU级与CPU级的定位误差CDF对比。可以看出，“New Cluster-CPU”曲线整体明显居左，说明其定位误差分布更为集中，定位性能明显优于EDU级。这是因为EDU级的处理主要依赖于局部感知数据与参数筛选，这虽然降低了通信与计算开销，并保证了一定的参数可靠性，但仍受限于局部AP的覆盖范围和数据质量。CPU级则在汇聚各EDU上传的可靠感知参数后，通过神经网络预测权重、GDOP路径筛选及加权最小二乘方法，实现了全局AP范围的二次定位优化，能够在全局尺度上动态调整AP选择与权重分配，从而有效抑制了局部融合




图6 EDU级与CPU级定位误差空间分布热力图

阶段的误差累积，有效提升了多级融合架构的鲁棒性和定位精度。

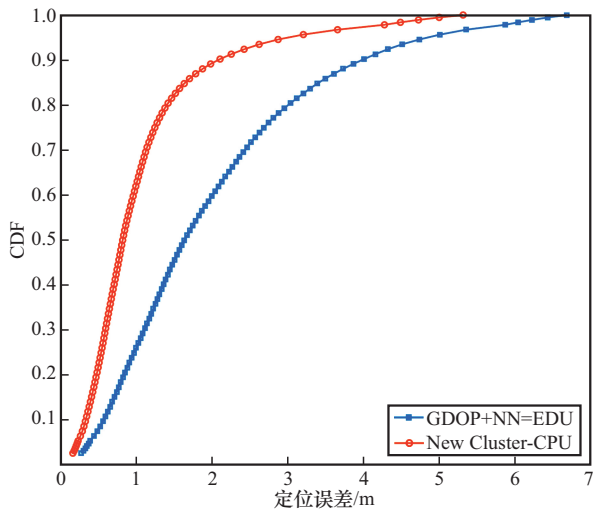


图7 EDU级与CPU级的定位误差累计分布对比

### 4 结束语

针对无蜂窝ISAC系统中高精度定位面临的通信开销大、参数不可靠及中心处理单元负担过重等问题，本文提出了一种多级融合的定位架构。该架构通过AP级参数提取、EDU级基于神经网络的权重映射与局部筛选加权融合定位，以及

CPU级全局二次筛选与融合定位，实现了参数质量的逐级提升和结果的全局优化。理论分析和仿真结果均表明，该多级融合定位架构在有效降低集中式处理通信与计算开销的同时，显著提升了系统的定位精度与鲁棒性，展现出良好的可扩展性。

### 参考文献：

- [1] Kaushik A, Singh R, Dayarathna S, et al. Toward integrated sensing and communications for 6G: key enabling technologies, standardization, and challenges[J]. IEEE Communications Standards Magazine, 2024, 8(2): 52-59.
- [2] Zhang Z K, Ren H, Pan C H, et al. Target localization in cooperative ISAC systems: a scheme based on 5G NR OFDM signals[J]. IEEE Transactions on Communications, 2025, 73(5): 3562-3578.
- [3] Li M L, Chen X M. Exploiting cell-free massive MIMO for computational imaging[C]//Proceedings of the 2022 14th International Conference on Wireless Communications and Signal Processing (WCSP). Piscataway: IEEE Press, 2023: 432-437.
- [4] Cheng G Y, Fang Y, Xu J, et al. Optimal coordinated transmit beamforming for networked integrated sensing and communications[J]. IEEE Transactions on Wireless Communications, 2024, 23(8): 8200-8214.
- [5] Sun X Y, Li J M, Zhu P C, et al. Spectral efficiency and scalability analysis for multi-level cooperative cell-free networks[J]. IEEE Transactions on Vehicular Technology, 2023, 72(12): 16911-16916.



- [6] Guo Y X, Wang D M, Xia X J, et al. Stochastic geometry analysis of scalable cell-free RAN with dynamic association and deployment[J]. IEEE Journal of Selected Topics in Signal Processing, 2025, 19(2): 398-411.
- [7] Wei Z Q, Xu R Z, Feng Z Y, et al. Symbol-level integrated sensing and communication enabled multiple base stations cooperative sensing[J]. IEEE Transactions on Vehicular Technology, 2024, 73(1): 724-738.
- [8] Wei Z Q, Liu H T, Li H J, et al. Integrated sensing and communication enabled cooperative passive sensing using mobile communication system[J]. IEEE Transactions on Mobile Computing, 2025, 24(9): 7805-7821.
- [9] Rahman M L, Zhang J A, Huang X J, et al. Framework for a perceptive mobile network using joint communication and radar sensing[J]. IEEE Transactions on Aerospace and Electronic Systems, 2020, 56(3): 1926-1941.
- [10] Liu F, Cui Y H, Masouros C, et al. Integrated sensing and communications: toward dual-functional wireless networks for 6G and beyond[J]. IEEE Journal on Selected Areas in Communications, 2022, 40(6): 1728-1767.
- [11] Wan L T, Han G J, Jiang J F, et al. DOA estimation for coherently distributed sources considering circular and noncircular signals in massive MIMO systems[J]. IEEE Systems Journal, 2017, 11(1): 41-49.
- [12] Demirhan U, Alkhateeb A. Cell-free ISAC MIMO systems: joint sensing and communication beamforming[J]. IEEE Transactions on Communications, 2025, 73(6): 4454-4468.
- [13] Xiao Z Q, Zeng Y. An overview on integrated localization and communication towards 6G[J]. Science China Information Sciences, 2021, 65(3): 131301.
- [14] Wei Z Q, Jiang W J, Feng Z Y, et al. Integrated sensing and communication enabled multiple base stations cooperative sensing towards 6G[J]. IEEE Network, 2024, 38(4): 207-215.
- [15] Ko K, Kabir M H, Kim J, et al. GDOP-based low-complexity LEO satellite subset selection for positioning[J]. IEEE Systems Journal, 2024, 18(2): 989-996.
- [16] Sharp I, Yu K G, Guo Y J. GDOP analysis for positioning system design[J]. IEEE Transactions on Vehicular Technology, 2009, 58(7): 3371-3382.
- [17] Noroozi A, Nayebi M M, Amiri R. Iterative constrained weighted least squares solution for target localization in distributed MIMO radar[C]//Proceedings of the 2019 27th Iranian Conference on Electrical Engineering (ICEE). Piscataway: IEEE Press, 2019: 1710-1714.
- [18] Sakhnini A, Guenach M, Bourdoux A, et al. A Cramér-Rao lower bound for analyzing the localization performance of a multistatic joint radar-communication system[C]//Proceedings of the 2021 1st IEEE International Online Symposium on Joint Communications & Sensing (JC&S). Piscataway: IEEE Press, 2021: 1-5.

#### [作者简介]



裴荣康 (2002-), 男, 东南大学信息科学与工程学院硕士生, 主要研究方向为通感一体化、多站协同感知。



王洁 (1998-), 女, 东南大学信息科学与工程学院博士生, 主要研究方向为无蜂窝大规模MIMO、通感一体化等。



李佳珉 (1983-), 男, 东南大学信息科学与工程学院教授, 主要研究方向为6G无蜂窝智能无线接入网、海量终端高可靠低时延通信、多站协同通感一体化、6G极致连接(空时互换理论、空时二维编码)、未来移动通信综合试验平台。



王东明 (1977-), 男, 东南大学信息科学与工程学院教授, 主要研究方向为无线通信信号处理、大规模分布式MIMO系统(无蜂窝大规模MIMO)等。



朱鹏程 (1978-), 男, 东南大学信息科学与工程学院教授, 主要研究方向为无线通信和移动网络, 涵盖5G/6G移动通信系统、大规模MIMO、超可靠低时延通信 (URLLC) 和毫米波通信等。