

## 基于双流时空特征提取与DETR的穿墙雷达目标定位方法

熊壮<sup>①</sup> 郭世盛<sup>\*①②</sup> 唐珑吟<sup>①</sup> 周楚宜<sup>①</sup> 姚禹<sup>①</sup> 崔国龙<sup>①②</sup>

<sup>①</sup>(电子科技大学信息与通信工程学院 成都 611731)

<sup>②</sup>(电子科技大学天府绛溪实验室 成都 641419)

**摘要:** 穿墙人体目标定位在目标感知及救援等领域具有广泛的应用前景。然而超宽带穿墙雷达系统受到墙体杂波干扰导致目标回波特征模糊,传统方法难以在复杂环境下实现稳定的检测与高精度的定位。尽管基于深度学习的目标定位方法在复杂环境下表现出更优异的性能,但现有方案常依赖于分布式雷达布局,导致系统部署困难、算法实现复杂度高。为解决上述挑战,本研究基于单视角小孔径2发4收超宽带穿墙雷达,提出一种双流时空(DSTS)特征提取与DEtection TRansformer的深度学习网络结构以实现对面后人体目标位置的确定。该网络以复数距离像作为输入,对其进行时空特征提取并从中构建双流分支:相位域分支提取目标空间角度信息,而幅度域分支反映目标径向距离,从而充分挖掘回波中的目标距离与方位特征。随后,双流分支分别经过多尺度降采样,并引入通道注意力机制进行加权融合,以得到低维特征。最终,将所得低维特征加入位置编码,输入DETR网络中,利用其集合预测特性得到可靠目标定位结果。在实测数据上验证表明,所提方法在多目标且准确定位阈值设为0.7 m时平均精度可达0.79,性能优于四种现有方案。

**关键词:** 超宽带穿墙雷达; 目标定位; 深度学习; 双流特征处理; DETR

**中图分类号:** TN972

**文献标识码:** A

**文章编号:** 2095-283X(2026)x-0001-14

**DOI:** 10.12000/JR26053

**CSTR:** 32380.14.JR26053

**引用格式:** 熊壮, 郭世盛, 唐珑吟, 等. 基于双流时空特征提取与DETR的穿墙雷达目标定位方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26053.

**Reference format:** XIONG Zhuang, GUO Shisheng, TANG Longzhen, *et al.* Through-Wall radar target localization method based on dual-stream temporal spatial feature extraction and DETR[J]. *Journal of Radars*, in press. doi: 10.12000/JR26053.

## Through-Wall Radar Target Localization Method Based on Dual-Stream Temporal Spatial Feature Extraction and DETR

XIONG Zhuang<sup>①</sup> GUO Shisheng<sup>\*①②</sup> TANG Longzhen<sup>①</sup> ZHOU Chuyi<sup>①</sup>  
YAO Yu<sup>①</sup> CUI Guolong<sup>①②</sup>

<sup>①</sup>(School of Information and Communicatino Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

<sup>②</sup>(Tianfu Jiangxi Laboratory, Chengdu 641419, China)

**Abstract:** Through-wall human target localization has broad application prospects in fields such as target perception and rescue. However, ultra-wideband through-wall radar systems suffer from wall clutter interference, which distorts target echo features and complicates the ability of traditional methods to achieve

收稿日期: 2026-03-04; 改回日期: ; 网络出版: 2026-xx-xx

\*通信作者: 郭世盛 [ssguo@uestc.edu.cn](mailto:ssguo@uestc.edu.cn) \*Corresponding Author: GUO ShiSheng, [ssguo@uestc.edu.cn](mailto:ssguo@uestc.edu.cn)

基金项目: 国家自然科学基金(62371110), 四川省自然科学基金(2025ZNSFSC0467)

Foundation Items: The National Natural Science Foundation of China (62371110), Natural Science Foundation of Sichuan Province (2025ZNSFSC0467)

责任编辑: 丁一鹏 Corresponding Editor: DING Yipeng

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License

(<https://creativecommons.org/licenses/by/4.0/>)

stable detection and high-precision localization in complex environments. Although deep learning-based localization methods have shown superior performance in these environments, they often rely on distributed radar layouts, leading to difficulties in system deployment and increased algorithm complexity. To address these challenges, this study introduces a deep learning network framework that utilizes a single-view small-aperture dual-transmitter quad-receiver ultra-wideband through-wall radar. This framework combines dual-stream temporal spatial (DSTS) feature extraction with a detection transformer (DETR) to accurately locate human targets behind walls. The network processes complex-range images as input, extracts spatiotemporal features, and constructs dual streams. The phase branch captures the target's spatial angular information, and the amplitude branch reflects the target's radial distance, thereby fully exploiting the distance and azimuth features in the echoes. The dual streams then undergo multi-scale downsampling, and a channel attention mechanism is employed for weighted fusion, yielding low-dimensional features. These features are then enhanced with positional encoding and fed into the DETR network, which utilizes its set-prediction capabilities to deliver reliable target localization results. Validation on measured data demonstrates that the proposed method achieves an average precision of 0.79, with a threshold for accurate multi-object localization set at 0.7 m, thus outperforming several existing solutions.

**Key words:** Through-wall radar; Target localization; Deep learning; Dual-stream feature process; DEtection TRansformer

## 1 引言

目标定位技术通过分析、处理传感器数据,实现对待测目标空间位置的准确估计,已成为目标信息感知的核心环节,并且在军事侦查、灾难救援等领域扮演着不可或缺的角色<sup>[1,2]</sup>。

目前,基于RGB相机、Wi-Fi、蓝牙、激光雷达、毫米波雷达等传感器的目标定位技术飞速发展<sup>[3-6]</sup>。RGB相机能够提供目标丰富的纹理轮廓,在光照良好视野开阔的场景下表现优异,但其光照依赖性与隐私泄露问题限制了其应用场景<sup>[7-9]</sup>。目前常用的室内定位技术,如Wi-Fi定位<sup>[5]</sup>、蓝牙定位<sup>[6]</sup>等,这类方法往往需要事先在室内场景中布置路由器等信号基站或信标网络,将显著增加部署成本和提高系统实现复杂性。虽然激光雷达、毫米波雷达等雷达技术能够避免个人隐私泄露的问题,但其高工作频段的电磁波难以穿透混凝土墙壁,使其在遮蔽条件下难堪重任。然而,穿墙雷达能够克服上述缺点,其低频电磁波能够穿过墙壁获取墙后目标的距离、速度以及微动信息,在复杂环境中展现出更强适用性<sup>[10,11]</sup>。

传统雷达目标定位方法通过信号处理从包含噪声干扰的回波信号中提取目标位置与运动状态的物理参数。得益于阵列信号处理理论发展,现已有诸多方法能够有效估计信号到达角<sup>[12-15]</sup>,为高精度目标定位提供了重要的角度信息。Zhang等人<sup>[16]</sup>提出一种基于内核极限学习机(Kernel Extreme Learning Machine, KELM)的方法实现了穿墙目标实时定位任务,并与支持向量机和最小二乘支持向量机进行对比实验,在精度几乎一致的情况下取得更快

的计算速度。刘新等人<sup>[17]</sup>基于分布式单发单收穿墙雷达,利用列文伯格-马夸尔特(Levenberg-Marquardt, L-M)最优化算法实现了雷达位置自估计和运动人体定位,定位精度达到0.62 m。柳景斌等人<sup>[18]</sup>使用毫米波雷达基于密度的空间聚类算法(Density-Based Spatial Clustering of Applications with Noise, DBSCAN)以及L-M方法提取质心特征,并构造非线性优化函数完成室内低成本自定位,平均定位误差可达0.82 cm。上述方法常通过参数估计直接推演目标位置,另外一类定位方法则是依托于成像技术,通过重建场景实现目标定位<sup>[19,20]</sup>。Li等人<sup>[21]</sup>基于多视角穿墙雷达成像,利用顺序滤波估计人体目标轨迹,并提出一种重影缓解方法。Brehier等人<sup>[22]</sup>则将穿墙雷达成像问题重新表述为一种Kronecker结构的鲁棒主成分分析(Robust Principal Component Analysis, RPCA)优化问题,在复杂室内场景下针对静态目标取得了更好的成像、检测及目标位置恢复性能。

随着近年来计算机技术大幅精进,深度学习方法凭借其强大特征建模能力在计算机视觉、自然语言处理等领域取得革命性突破,在此影响下,深度学习已成为基于各类传感器的目标定位技术中提升定位精度与鲁棒性的有效方法<sup>[23,24]</sup>。例如, Lee等人<sup>[25]</sup>和Stephan等人<sup>[26]</sup>使用线性调频雷达分别基于1维卷积神经网络(1D-Convolutional Neural Network, 1D-CNN)和U-Net网络结构,已在人体目标定位、姿态估计及探测等任务中取得了优于传统方法的性能。

然而,与其他各类传感器相比,穿墙雷达回波

信号信噪比低且富含墙体杂波，导致目标信息难以被有效挖掘，这使得深度学习方法在穿墙雷达领域的应用面临更大挑战。Fardin等人在5种不同介质的遮蔽墙体条件下使用多层感知机(MultiLayer Perceptron, MLP)，基于仿真数据对1~3个人体目标完成定位<sup>[27]</sup>、墙体参数估计<sup>[28]</sup>等任务，其中单人情况下取得了非常高的定位精度。然而，以上工作所提方案在应对多目标情形时，既没有采用统一的网络输出结构也没有考虑预测与标签的二分匹配问题，导致该方法无法有效应对目标数目不定的情形。赵肖思等人<sup>[29]</sup>基于Faster-RCNN网络结构实现静止多目标检测，虽然取得较高的检测率但是未能实现对目标二维位置的精准映射。而Zhu等人<sup>[30]</sup>和渠晓东等人<sup>[31]</sup>分别提出基于多维特征融合和结合RPCA与YOLO的检测方案，利用雷达图像实现目标定位与识别，虽然上述方法能够应对不确定目标数目的情形，但其不仅引入繁琐的迭代优化或预处理步骤，而且缺乏对全局特征建模，难以有效提取目标信息，导致其在小孔径穿墙雷达复杂场景应用中性能受到制约。

综上所述，现有基于深度学习的穿墙雷达目标定位方法往往受限于预设输出维度的固化结构或依赖于局部特征聚合的网络架构，在应对穿墙雷达杂波干扰时，难以充分提取全局目标特征，导致其小孔径雷达探测及未知目标数量场景下的泛化性与鲁棒性不足。为此，本文引入DEtectionTRansformer，利用其全局注意力机制深入挖掘回波特征，直接建立从雷达复数距离像到目标二维坐标的精准映射。

本文工作贡献总结如下：

(1) 提出了一种基于全局特征建模与集合预测的穿墙雷达多目标定位框架。针对小孔径雷达在杂波干扰下，难以仅通过局部特征充分表征目标信息的问题，将复数雷达距离像作为输入，利用DETR的注意力机制充分挖掘回波中全局目标特征，同时结合其集合预测特性，实现对未知目标数量的合理估计与高精度定位。

(2) 设计了一种双流时空特征提取(Dual Stream Temporal Spatial, DSTS)模块，实现局部特征与全局特征关联互补。针对雷达复数距离像特性，分别处理幅度域、相位域两分支，并结合通道注意力机制进行信息融合，能充分挖掘雷达回波数据中目标时空信息，为后续全局特征建模提供信息表征基础。

(3) 实验结果表明，本文所提方案在单目标及多目标情形下平均精度可达0.95和0.79，召回率可

达0.97和0.86，定位误差仅为0.20 m和0.23 m，性能优于几种现有方法，为单视角小孔径穿墙雷达目标定位提供了一种有效的方案。

## 2 信号模型

步进频超宽带穿墙雷达可以发射低频电磁波穿透墙体，并接收来自墙后目标的反射回波，进而实现穿墙目标探测。

系统工作时，在预设频带内以固定的频率步进，依次发射持续一段时间的单频脉冲信号。数学上可以将一个周期内的步进频信号表示为

$$x(t) = A \cdot \sum_{n=0}^{N_f-1} \text{rect} \left( \frac{t - \frac{T}{2} - nT}{T} \right) \cdot \exp \{j(\omega_0 + n\Delta\omega)t\} \quad (1)$$

其中， $A$ 为信号幅值， $T$ 为每个频率脉冲信号持续时间； $N_f$ 表示总频点数； $\omega_0$ 为起始角频率， $\Delta\omega$ 是步进角频率量； $\text{rect}(\cdot)$ 表示矩形窗函数。

如图1所示为穿墙雷达目标探测示意图，设一墙后目标与雷达距离为 $R$ ，接收信号可建模为

$$x(t) = A\sigma \cdot \sum_{n=0}^{N_f-1} \text{rect} \left( \frac{t - \frac{T}{2} - nT}{T} \right) \cdot \exp \left\{ j(\omega_0 + n\Delta\omega) \left( t - \frac{2R}{c} \right) \right\} \quad (2)$$

其中， $\sigma$ 为衰减因子， $c$ 为光速。对接收信号进行混频后采样所得基带序列记为

$$\tilde{x}_r = A\sigma \left[ e^{-j\omega_0 \frac{2R}{c}} e^{-j(\omega_0 + \Delta\omega) \frac{2R}{c}} \dots e^{-j(\omega_0 + (N_f-1)\Delta\omega) \frac{2R}{c}} \right]^T + \mathbf{s}_w + \mathbf{s}_n \quad (3)$$

其中， $\mathbf{s}_w$ ， $\mathbf{s}_n$ 分别代表墙体和噪声经过采样后的向




图 1 穿墙雷达目标探测示意图

Fig. 1 Diagram of through-wall radar target detection

量。随后采用均值对消抑制墙体静态杂波<sup>[32]</sup>。记第*i*个慢时间周期的基带信号为 $\tilde{\mathbf{x}}_r^{(i)}$ ，利用前*K*个周期的历史数据进行对消处理，得到第*i*个周期去噪信号 $\mathbf{x}^{(i)}$ ，可表示为

$$\mathbf{x}^{(i)} = \tilde{\mathbf{x}}_r^{(i)} - \frac{1}{K} \sum_{k=1}^K \tilde{\mathbf{x}}_r^{(i-k)} \quad (4)$$

最终沿着频点维度做快速傅里叶逆变换(Inverse Fast Fourier Transform, IFFT)可得慢时间周期内的一维距离像 $\mathbf{x}_{rp}^i$ 。对一段持续*L*个慢时间周期的回波信号，最终形成距离像平面记作：

$$\widetilde{\mathbf{X}}_{rp} = [\mathbf{x}_{rp}^1 \mathbf{x}_{rp}^2 \cdots \mathbf{x}_{rp}^L]^T \quad (5)$$

距离像平面能够直观反映墙后目标与雷达之间的径向距离，为后续目标定位任务提供关键的数据基础。

### 3 双流时空特征提取与 DETR 网络结构

#### 3.1 网络总体架构

雷达距离像数据天然反映目标与雷达之间的径向距离信息，但其对于目标定位至关重要的方位信息则隐含在不同接收通道的雷达数据相位之中。为了充分挖掘雷达回波中各通道幅度域、相位域及时序信息，本文提出一种名为双流时空特征提取

(Dual Stream Temporal Spatial, DSTS)与DETR的网络结构。

如图2所示是系统实现框图。该网络结构由DSTS特征提取模块和DETR定位模块两部分组成。本网络包含两个明确的阶段：首先，利用DSTS模块提取高维局部时空特征并完成信息融合。进而，将DSTS模块输出的特征向量加上位置编码输入DETR网络。该设计能够利用全局注意力机制建立长距离依赖关系，并在提取高质量特征的基础上借助DETR查询竞争机制<sup>[33]</sup>，抑制异常干扰，优化定位结果。

#### 3.2 双流时空特征提取模块

如图3所示是DSTS特征提取模块网络结构，具体参数见表1。鉴于实际采集情形中待测场地后方仍有无关人员影响，我们首先提取感兴趣的距离像范围，将每10个慢时间周期(0.24 s)复数数据作为一个待检测定位的样本，将其实部虚部拆分为(10, 8, 89)形状的两部分，其中8为通道数，89为截取的目标运动最大径向距离范围(约6.5 m对应89个距离单元)。随即对时间维和距离维度进行卷积操作以捕获慢时间周期内动态变化模式。与直接平均化时间维度或者只取最后一个时间步特征策略相比，本文方法能够充分挖掘慢时间周期内时序关系。在充




图2 系统实现总框图

Fig. 2 Block diagram of system implementation




图3 双流时空特征提取模块

Fig. 3 Dual stream temporal spatial feature extraction module

表 1 DSTS特征提取模块网络结构参数详情  
Tab. 1 Details of the network structure parameters of the DSTS feature extraction module

模块阶段	操作层	参数配置 (k:kernel,s:stride,p:padding)	输出尺寸 $C \times H \times W$
输入	复数雷达距离像	-	$8 \times 89 \times 10$
时空特征提取	ST-Conv (实部)	$k = 3 \times 10, s = 1, p = (1, 0)$	$89 \times 89 \times 1$
	ST-Conv (虚部)		
维度重塑	维度变换(Reshape)	Squeeze(3) $\rightarrow$ Unsqueeze(1)	$1 \times 89 \times 89$
幅/相特征映射	2DCNN(幅度域分支)	$k = 3 \times 10, s = 1, p = 1$	$8 \times 89 \times 89$
	2D CNN (相位域分支)		
双流特征处理	2D CNN	$C_{in} = 8, C_{out} = 16, k = 3 \times 3, s = 2, p = 1$	$16 \times 45 \times 45$
	2D CNN	$C_{in} = 16, C_{out} = 32, k = 3 \times 3, s = 2, p = 1$	$32 \times 23 \times 23$
	2D CNN	$C_{in} = 32, C_{out} = 64, k = 3 \times 3, s = 2, p = 1$	$64 \times 12 \times 12$
	2D CNN	$C_{in} = 64, C_{out} = 128, k = 3 \times 3, s = 2, p = 1$	$128 \times 6 \times 6$
特征融合	通道注意力融合	Concat + SEAttention + Conv	$128 \times 6 \times 6$

分提取时序信息后，进一步对其进行特征映射，生成融合了目标空间分布信息的尺寸为 $(8, 89, 89)$ 的特征图。随后将该特征图的实部与虚部计算为幅度域与相位域两分支进行深层次特征提取。两分支各自得到 $(128, 6, 6)$ 的特征向量，最终经由式(6)的通道注意力进行拼接加权融合，在自适应强化有效目标特征并实现信息互补后，得到DSTS特征提取模块输出结果。

$$\begin{aligned} \mathbf{F}_{cat} &= \text{Concat}(\mathbf{F}_{amp}, \mathbf{F}_{pha}) \in \mathbb{R}^{2C \times H \times W} \\ \mathbf{W}_{SE} &= \phi(\mathbf{W}_2 \delta(\mathbf{W}_1 \text{AvgPool}(\mathbf{F}_{cat}))) \\ \mathbf{F}_{out} &= \text{Conv}_{1 \times 1}(\mathbf{F}_{cat} \odot \mathbf{W}_{SE}) \in \mathbb{R}^{C \times H \times W} \end{aligned} \quad (6)$$

其中， $\mathbf{F}_{amp}$ 和 $\mathbf{F}_{pha}$ 分别代表幅度域与相位域特征；Concat( $\cdot$ )表示拼接操作；AvgPool( $\cdot$ )为全局平均池化； $\mathbf{W}_1$ 和 $\mathbf{W}_2$ 为全连接层权重； $\delta$ 和 $\phi$ 分别表示ReLU和Sigmoid激活函数； $\odot$ 表示按元素相乘；Conv $_{1 \times 1}$ 表示用于降维的 $1 \times 1$ 卷积操作。

### 3.3 DETR定位模块

DETR作为Transformer架构在检测任务上的创新变体，它将目标检测视为集合预测问题，这一创新机制能为雷达多目标定位带来显著优势。在训练过程中，通过匈牙利匹配进行预测与真值的最小代价匹配，并基于此计算损失。在实际推理时，模型将直接输出固定数目的预测结果，通过置信度阈值筛选即可同时实现对目标数目及位置的判断。更重要的是DETR继承Transformer架构强大的全局上下文建模能力，这对于处理多目标复杂遮挡等场景至关重要。

如图4所示是DETR架构。DETR中每层编码器的Encoder层与标准Transformer完全相同，主

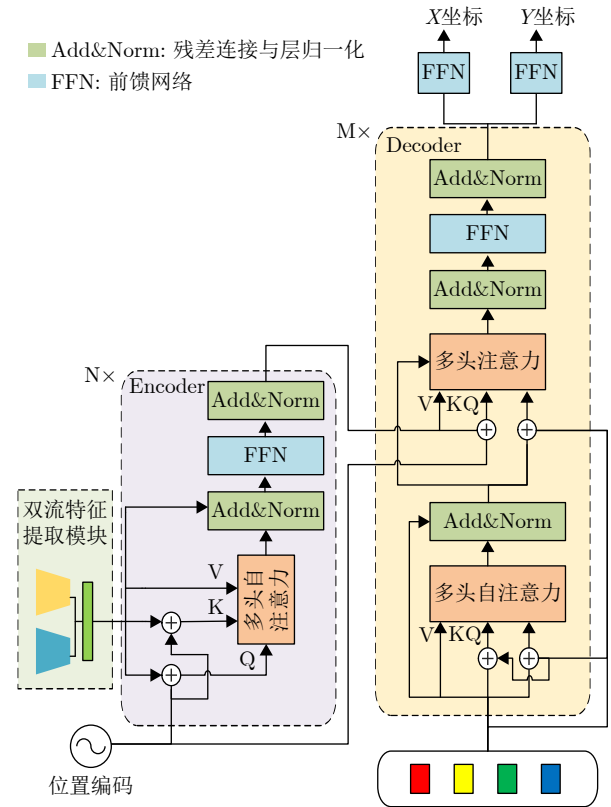


图 4 DETR架构

Fig. 4 DETR Architecture

要由捕捉特征向量中全局依赖的多头自注意力机制<sup>[34]</sup>、缓解梯度消失的残差连接Add<sup>[35]</sup>和稳定训练的层归一化Norm<sup>[36]</sup> 3个组件构成。而译码器Decoder则是DETR架构的创新所在，它首先初始化一组可学习的目标查询向量输入译码器，初始查询向量的个数要远多于真实目标数目，每个译码器Decoder层中查询向量通过自注意力交互，随后与Encoder层输出进行交叉注意力交互以提取全局信

息, 最终经多层次迭代输出与初始查询向量数量相同的预测集合。

具体而言, 将DSTS特征提取模块所得的(128, 6, 6)的特征图展平为通道数为128的特征序列(128, 36), 为保留空间结构特性, 引入位置编码, 与上述特征序列相加送入DETR定位模块以建模全局上下文信息。其中DETR定位模块的Encoder层数4层、Decoder层数3层, 并配以置信度头与回归头进行预测输出。

### 3.4 损失函数

为了实现训练过程中预测与真值的对应, 本研究沿用与文献[33]中相同的匈牙利匹配方法, 寻找最小匹配代价的排列方式。

由于网络输出中, 背景输出占很大比例, 若对背景部分赋予过高权重容易导致训练不稳定, 而过低权重则会在推理时产生大量高置信度虚假目标。匹配部分负责计算预测与真实值之间的回归损失与置信度损失; 未匹配部分则通过对未匹配查询施加加权惩罚, 促使网络抑制无效预测。匹配部分和未匹配部分均由回归损失和置信度损失组成, 其中, 回归损失量化预测位置与真实坐标的位置偏差, 置信度损失负责判别当前查询向量表征真实目标的概率。

设 $N_{gt}$ 为真实目标数量,  $N_q$ 为初始查询向量数量, 则匹配部分损失可记为

$$\mathcal{L}_{ma} = \frac{1}{N_{gt}} \sum_{i=1}^{N_{gt}} [\mathcal{L}_{SL1}(\hat{p}_i, p_i) + \mathcal{L}_{CE}(\hat{c}_i, c_i)] \quad (7)$$

其中,  $\hat{p}_i$ 与 $p_i$ 分别表示第 $i$ 个匹配预测的坐标与其真实坐标,  $\hat{c}_i$ 与 $c_i$ 分别表示第 $i$ 个预测置信度与其真实

标签,  $\mathcal{L}_{SL1}(\cdot)$ 为回归损失, 采用对异常值不敏感且更稳定的SmoothL1Loss<sup>[37]</sup>, 其计算公式如式(8)。

$$\mathcal{L}_{SL1}(\hat{x}_i, x_i) = \begin{cases} 0.5\delta^2 & |\delta| < 1 \\ |\delta| - 0.5 & \text{其他} \end{cases}, \delta = \hat{x}_i - x_i \quad (8)$$

而 $\mathcal{L}_{CE}(\cdot)$ 表示置信度损失, 采用交叉熵损失, 用于判别输出查询向量属于目标或背景, 其计算公式如式(9)所示。

$$\mathcal{L}_{CE}(\hat{c}_i, c_i) = \frac{-1}{N_{gt}} \sum_{i=1}^{N_{gt}} [c_i \log \hat{c}_i + (1 - c_i) \log(1 - \hat{c}_i)] \quad (9)$$

未匹配部分损失如式(10)所示。

$$\mathcal{L}_{unma} = \frac{1}{N_q - N_{gt}} \sum_{j=1}^{N_q - N_{gt}} [\mathcal{L}_{SL1}(\hat{p}_j, \mathbf{0}) + \mathcal{L}_{CE}(\hat{c}_j, \mathbf{0})] \quad (10)$$

其中,  $\mathbf{0}$ 表示未匹配查询所对应的零向量惩罚项, 最终, 总损失如式(11)所示。

$$\mathcal{L}_{total} = \mathcal{L}_{ma} + \lambda_{unma} \cdot \mathcal{L}_{unma} \quad (11)$$

其中,  $\lambda_{unma}$ 表示未匹配查询损失部分的权重, 为避免训练初期背景主导模型学习方向, 其将在10个训练周期内从0.1逐步增长至1并在之后的训练中保持。此范围设计不仅能在训练初期鼓励模型探索正样本预测, 还能随着模型特征提取能力提升, 以与正样本相同的权重对虚假目标输出进行抑制, 提升定位精度。

## 4 实验结果与分析

### 4.1 实验数据集与训练配置

实验场景如图5所示, 人体目标在墙后4.8 m ×

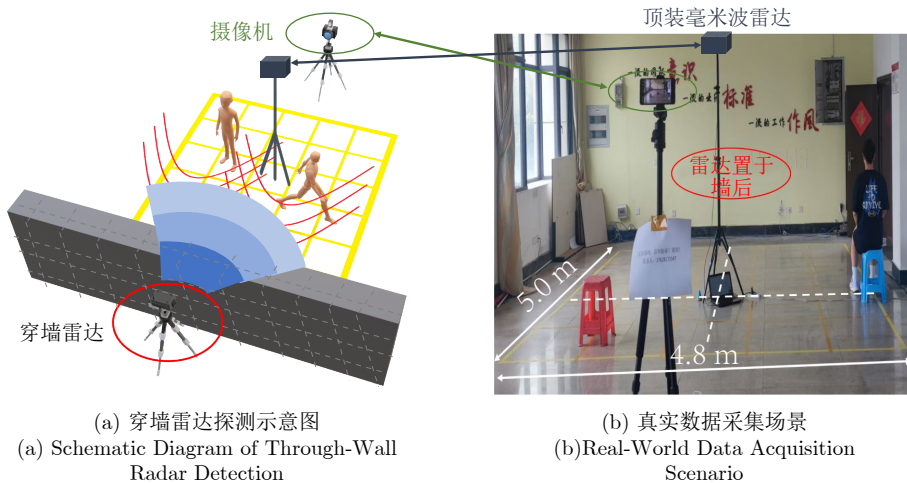


图5 数据采集场景

Fig. 5 Scene of data collection

5.0 m范围内任意走动, 本研究所使用的2发4收超宽带穿墙雷达起始频率1.6 GHz、终止频率2.2 GHz、步进频率2 MHz, 慢时间周期24 ms, 进行1024点 IFFT 获取雷达距离像。除穿墙雷达之外, 还在目标活动场地后方布置摄像机, 在场地中央布置顶装毫米波雷达用于获取目标标签。数据采集时, 所有设备均基于统一的时间戳, 但由于各设备硬件处理响应速度可能存在差异, 我们将所得视频数据、定位标签以及穿墙雷达回波数据进行手动微调对齐。

实验共邀请10名志愿者参与数据采集, 共获得38条雷达回波数据, 总时长达340分钟, 为避免随机划分导致同一序列的相邻数据段同时进入训练集和测试集, 从而引入较强相关性并使测试结果偏高, 本文按完整回波序列进行划分。最终, 训练集和测试集分别包含68252个和17260个样本。需要说明的是, 由于部分志愿者同时参与了训练集和测试集对应序列的采集, 因此实验结果仅反映序列级独立划分条件下的模型性能, 而非严格意义上的完全跨志愿者泛化能力。

训练测试在配备NVIDIA RTX 1660super GPU和Intel I5-12400F处理器的个人计算机上进行。批量大小为32, 训练轮数为40, 优化器为AdamW, 初始学习率 $1 \times 10^{-4}$ , 余弦退火调度器使得学习率在20周期内衰减至 $1 \times 10^{-5}$ 。

## 4.2 评价指标

在模型性能评估阶段, 我们采用一套完整的评价体系。首先对每个样本的真实标签与模型推理过程中高于置信度阈值的预测输出进行匈牙利匹配, 计算匹配对之间的欧氏距离差并记录。随后设定回归阈值, 将匹配后距离差低于该阈值的目标判定为

正确检测(True Positive, TP), 距离差超过阈值的匹配对视为定位不准确, 不纳入TP统计。未匹配的真实目标标记为漏检(False Negative, FN), 未匹配的预测目标标记为虚警(False Positive, FP)。在此基础上统计正确检测目标与所对应预测的平均距离差。

基于TP, FN, FP的统计结果, 我们进一步计算F1分数、平均精度(Average Precision, AP)与召回率(Recall, R)。为全面评估模型在不同定位精度要求下的表现, 我们在多个回归阈值下分别计算AP与R值, 以此形成全面的评估体系。这种多阈值评估方法能够更细致地反映模型在严格和宽松定位要求下的性能变化, 为模型优化提供明确方向。

## 4.3 实验结果

本部分将所提方案和文献[25,30]中网络结构及传统后向投影成像<sup>[38]</sup>方法进行了对比实验, 结果见表2。图6展示了本文所提方案与对比实验方案的结果, 第1行为不同样本视频记录截图, 第2行为对应样本YOLOv8输出的目标框结果, 第3行为文献[30]输出热图, 最后一行则是本文所提方案与文献[25]中所提1D-CNN网络结构输出的定位结果。

本文所提方案在单目标且准确定位阈值设为0.5 m和0.7 m条件下, F1分数达到0.88和0.93, 平均精度分别达到了0.87和0.95, 召回率达到0.92和0.97。多目标情形下平均精度分别达到了0.67和0.79, 召回率达到0.76和0.86, 显著超过其他几种方法的性能。此外, 所提方案在两种目标情形下的平均定位误差均为最低, 尤其在多目标场景中, 其0.23 m和0.20 m的定位精度远优于其他方法, 这印证了该方案在复杂环境中实现精确定位的潜力。

针对文献[25]中的网络结构, 我们调整输入维度并为其配以置信度输出, 便于进行指标统计。如

表 2 实验评估结果对比

Tab. 2 Comparison of Experimental Evaluation Results

模型配置	目标情形	阈值=0.7 m				阈值=0.5 m				GFLOPS
		Err(m)	F1	AP	R	Err(m)	F1	AP	R	
文献[25]所提方案	单目标	0.37	0.75	0.76	0.81	0.30	0.63	0.62	0.68	0.24
	多目标	0.41	0.46	0.44	0.49	0.44	0.43	0.41	0.47	
成像[38]+CA-CFAR	单目标	0.35	-	-	0.78	0.31	-	-	0.63	-
	多目标	0.39	-	-	0.75	0.32	-	-	0.61	
成像[38]+YOLOv8	单目标	0.21	0.85	0.86	0.84	0.20	0.83	0.85	0.81	8.20
	多目标	0.24	0.69	0.72	0.68	0.21	0.65	0.67	0.62	
文献[30]所提方案	单目标	0.22	0.86	0.72	0.87	0.19	0.82	0.72	0.82	0.15
	多目标	0.24	0.72	0.73	0.74	0.21	0.66	0.61	0.67	
本文方案	单目标	0.29	0.93	0.95	0.97	0.19	0.88	0.87	0.92	12.16
	多目标	0.23	0.85	0.79	0.86	0.20	0.77	0.67	0.76	

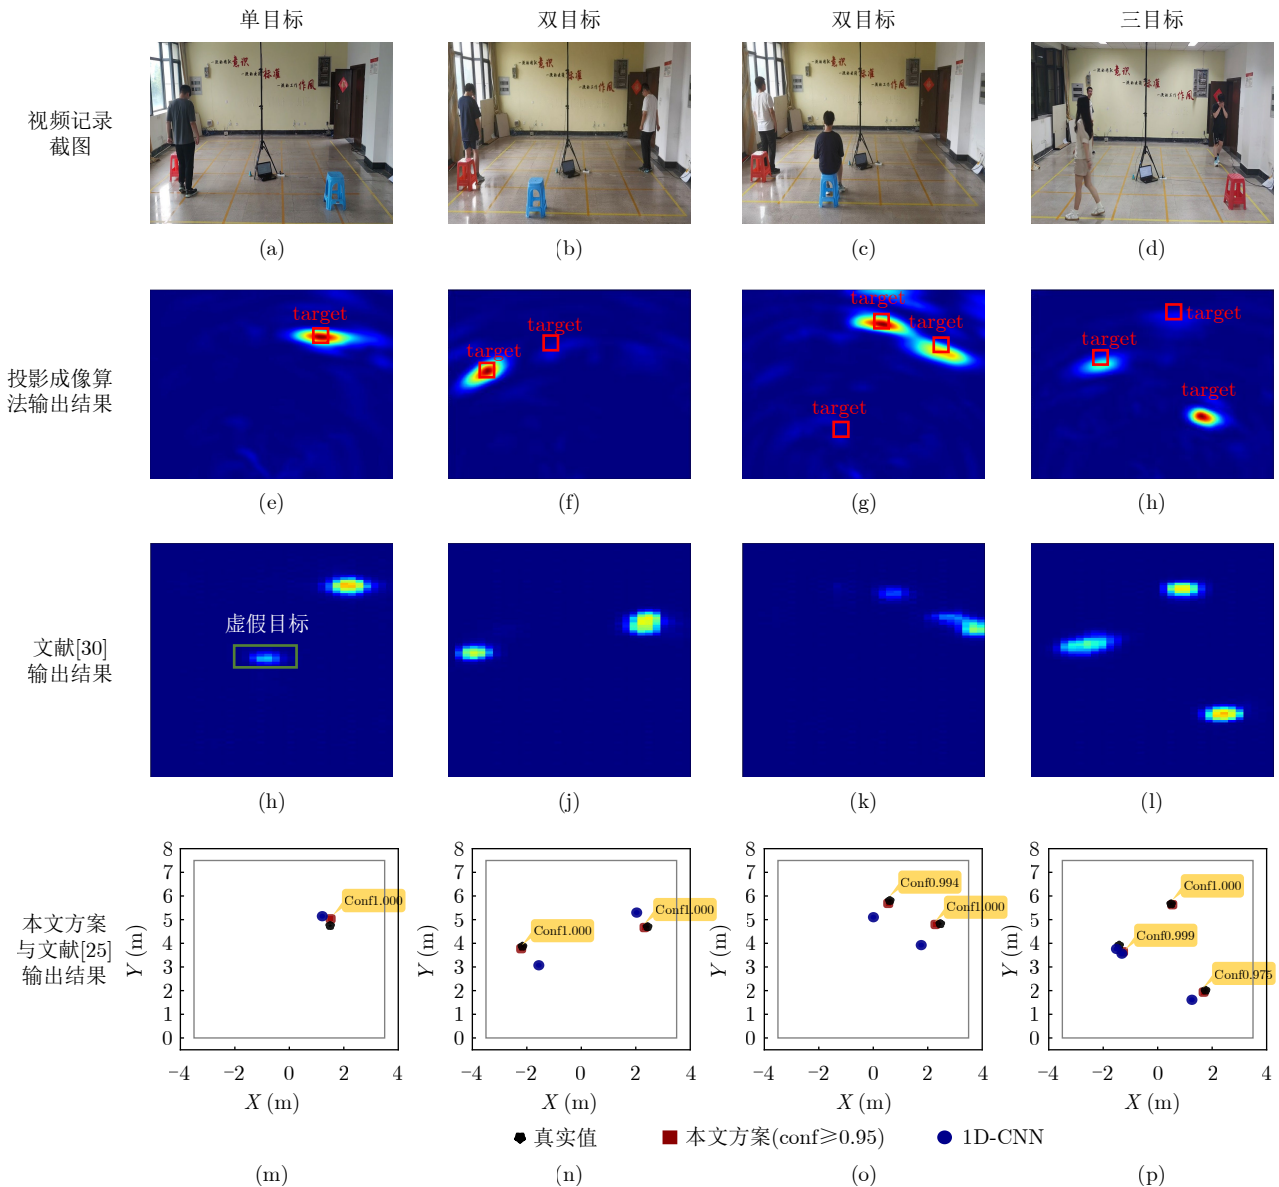


图6 所提方案定位结果对比图：第一排为视频记录截图；第二排为对应样本的成像算法输出结果；第三排为文献[30]输出结果；第四排为本文所提方案与文献[25]输出结果

Fig. 6 Comparison of localization results of the proposed method. The first row shows video-recorded screenshots; the second row presents the imaging algorithm outputs of the corresponding samples; the third row presents the outputs of [30]; and the fourth row presents the outputs of the proposed method and the literature [25]

图6所示，在单目标情形下，文献[25]中所提网络结构能够实现较为精准的目标位置预测。而在多目标情形下，文献[25]中所提网络结构输出定位结果精度显著下降，且容易出现漏检的情况。具体而言，本文方法在两种准确定位阈值条件的多目标情形下提升了0.26和0.35的平均精度以及0.29和0.37召回率。文献[25]中所提网络结构难以从富含杂波干扰的雷达距离像数据中有效提取目标空间位置的信息，另外缺乏对数据标签排列顺序对网络训练严重影响的考虑，导致其虽然在单目标情形下尚可，但在多目标情形下鲁棒性大大降低。而本文方案集合预测输

出特性能轻松应对此类问题。如图6第二行所示，我们开展了基于后向投影成像<sup>[38]</sup>的对比实验。在实验中，我们沿用了与所提方案相同的样本分割策略，并将10个周期内的成像结果进行叠加与归一化，在此基础上，进一步采用CA-CFAR和YOLOv8两种算法完成了对成像结果的目标检测与定位。

CA-CFAR中设置保护单元数12、虚警率 $1 \times 10^{-4}$ ，由于其无法提供置信度评分难以直接计算平均精度和F1分数，因此我们仅比较召回率。其检测结果显示，在单目标场景中，当准确定位阈值设为0.5 m和0.7 m时，召回率达到0.63和0.78。

而在多目标两种阈值条件下，0.61和0.75的召回率显著低于本文所提方案。对于YOLOv8方法，虽然在单目标场景下的召回率提升至0.81和0.84且定位结果相比CA-CFAR更加精准，但在多目标情形下召回率显著下降。相比之下，本文方案得益于全局特征建模与集合预测机制，在复杂条件下各项指标同样表现更加优异。

如图6第三行所示，文献[30]方法的输出形式为目标运动场景热图。由于仅关注目标定位任务，因此对比实验中不启用其行为识别分支，并按原文解码方式将热图转换为目标坐标。实验结果表明，该方案在召回率和F1分数方面优于前述几种对比方案，由于其主要依赖局部特征进行检测，缺乏对场景中杂波干扰的判别，导致其容易出现如图6中所示的虚假目标，而体现出弱于本文所提方案的性能表现。

图7展示了在准确定位阈值为0.7 m时，模型的性能趋势。图7(a)显示，随目标增多性能略有下降但仍维持高水平。如图7(b)所示，在径向距离分

析中，各统计区间样本量分布在494~3453之间，保证了评估结果的全面性，而模型在各个距离区间中表现稳定。这证实了该方法在不同空间位置具备可靠的探测能力与优异的场景适应性。

虽然各指标可以综合反映模型性能，但为了衡量网络查询向量的输出情况，图8直观展示了真实目标数与网络实际推理输出高于设定阈值的目标个数的关系。其中每一行代表样本真实目标数，每一列代表网络推理输出中高于置信度阈值的预测个数，每一个单元格内展示了比例及样本数目。结果表明，所提方案对单目标样本的检测结果较可靠，而双目标和三目标样本之间较容易混淆，这是由穿墙多目标环境下目标视野遮挡、距离像重叠所致。尽管如此，考虑到所提方案每10个慢时间周期(0.24 s)即可完成一次推理，当前性能在实际应用场景下已具备良好的实用价值。

在模型实际推理过程中，直接依据置信度阈值筛选可靠的目标查询输出。图9展示了模型在准确

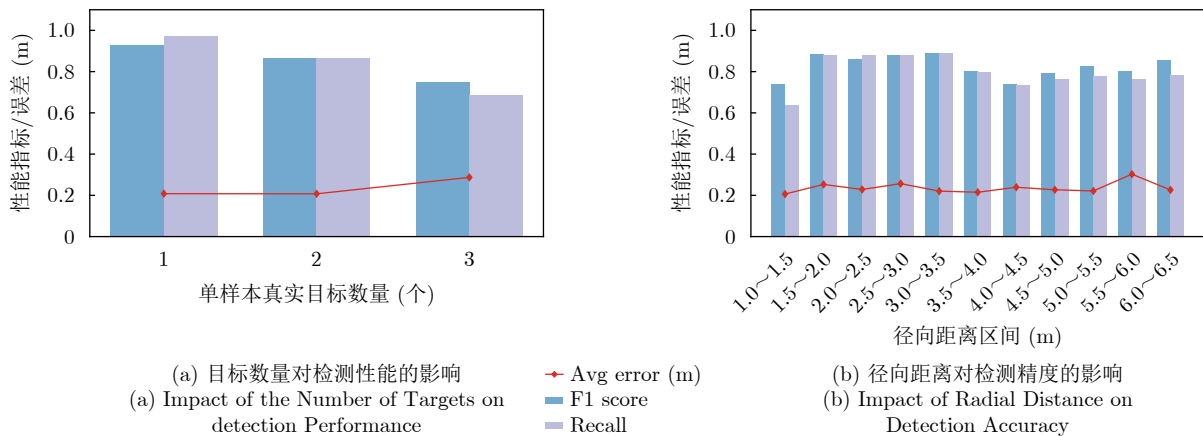


图 7 0.7 m 阈值下不同目标数目及不同径向距离下模型性能变化统计

Fig. 7 Statistics of model performance changes under different numbers of targets and various radial distances under 0.7 m threshold




图 8 多目标情形下真实目标数目与预测目标数

Fig. 8 Statistics of predicted target numbers versus ground-truth target numbers in multi-target cases.

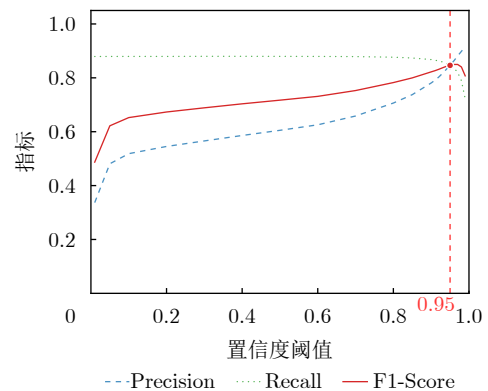


图 9 不同置信度阈值下模型性能表现

Fig. 9 Model performance at different confidence thresholds

定位阈值设为0.7 m时,不同置信度阈值下的模型性能表现变化。随着置信度阈值的提升,模型的精度呈现稳步上升趋势,而召回率则下降缓慢,始终处于较高水平。这一现象表明,经训练后的模型对正样本具有良好的判别能力,能够以高置信度输出大部分真实目标,而非模棱两可的低置信度预测。虽然F1分数在更高置信度阈值下略有提升,但为了在实际应用中能够维持较高性能的同时,降低漏检风险,选择0.95作为推理阶段筛选阈值。

同时需要说明的是,本文实验数据中已经包含目标视角遮挡以及距离较近等复杂情况。相关实验结果表明,所提方法在此类更具挑战性的场景下仍具有一定检测能力,但其性能相较常规场景存在一定下降。综上所述,在采用统一置信度阈值的简单策略下,本文所提方案因置信度阈值设定相对保守而导致少量误检,但整体检测精度可观。从表2可以看出,本文方法的网络推理计算量为12.16 GFLOPS。尽管其网络计算量高于部分对比方法,但本文方案无需额外的成像处理,也不依赖YOLOv8及文献[30]中所需的后处理步骤,整体处理链路更为简洁,并在此基础上取得了更优的单目标与多目标定位性能。

#### 4.4 消融实验

为了验证所提方案中各模块的有效性,我们基于实测数据集对DSTS特征提取以及DETR定位模块进行消融实验。消融实验结果如表3所示。

首先,DSTS特征提取与DETR定位模块均对模型性能具有重要贡献。当两模块均未启用时(采用一个并行双流Bi-GRU+标准Transformer网络结构代替),模型在单目标且准确定位阈值设为0.7 m情形下表现尚可,平均精度达0.76,但在多目标场景下平均精度下降至0.41,说明基础结构对复杂多

目标场景建模能力有限,且由于缺乏对标签排序不变性的考虑导致模型泛化性能较差。引入DETR定位模块后(第二组配置),模型在多目标情形下的性能得到显著增强,准确定位阈值设为0.7 m时平均精度从0.41提升至0.59,这验证了DETR在处理多目标任务时通过全局注意力机制和集合预测所带来的优势。而在单目标场景下,其准确定位阈值设为0.7 m时平均精度也提升了0.03,说明DETR定位模块也具备良好的特征建模能力。其次,当仅启用DSTS特征提取模块时(第三组配置),模型在单目标任务上表现出稳定的性能提升,体现了该结构特征提取能力。然而,其在多目标场景下的性能仍弱于第二组配置模型,说明单一提升特征提取能力难以应对多目标任务。

表4展示了双流特征处理的消融实验结果。由于单一模态缺乏幅度域与相位域信息的互补优势,难以构建完整的目标位置特征表达,导致单独依赖其中某一分支均会导致定位与检测性能的下降。相比之下,当采用本文完整方案时,模型在单目标与多目标场景下均取得最优性能。

上述消融实验结果证明所提网络结构中各模块有效性。双流特征设计提供了高效信息利用和提取基础,时空特征提取能融合目标空间特性,而DETR则是实现系统性能突破的关键。

#### 4.5 模型结构参数分析

为了进一步探讨所提方案的性能上限,本节将研究模型内部关键结构参数对模型性能的影响。

DETR模型设计借鉴Transformer架构,可以依赖于编码器Encoder全局特征提取能力和解码器Decoder的信息转化能力进行集合预测输出。编码器Encoder和解码器Decoder层数增加时,理论上会增强模型建模能力,提高网络鲁棒性,然而过深的

表3 消融实验结果补充表注  
Tab. 3 Ablation study results

组件配置		目标情形	阈值=0.7m				阈值=0.5m			
DSTS	DETR		Err(m)	F1	AP	R	Err(m)	F1	AP	R
-	-	单目标	0.47	0.72	0.76	0.81	0.39	0.65	0.69	0.76
-	-	多目标	0.53	0.41	0.41	0.45	0.42	0.39	0.38	0.42
-	√	单目标	0.42	0.81	0.82	0.89	0.35	0.68	0.63	0.71
-	√	多目标	0.47	0.61	0.59	0.67	0.45	0.54	0.51	0.60
√	-	单目标	0.38	0.78	0.82	0.83	0.29	0.65	0.70	0.73
√	-	多目标	0.50	0.39	0.39	0.43	0.48	0.36	0.37	0.43
√	√	单目标	0.20	0.93	0.95	0.97	0.19	0.88	0.87	0.92
√	√	多目标	0.23	0.85	0.79	0.86	0.20	0.77	0.67	0.76

表 4 双流特征处理消融实验结果补充表注  
Tab. 4 Ablation study results of dual-stream features processing

组件配置		目标情形	阈值=0.7m				阈值=0.5m			
幅度域分支	相位域分支		Err(m)	F1	AP	R	Err(m)	F1	AP	R
-	-	单目标	0.24	0.79	0.88	0.90	0.22	0.74	0.70	0.86
		多目标	0.27	0.78	0.71	0.79	0.23	0.69	0.57	0.69
√	-	单目标	0.23	0.81	0.88	0.91	0.20	0.73	0.73	0.87
		多目标	0.25	0.76	0.75	0.81	0.24	0.71	0.61	0.72
-	√	单目标	0.22	0.84	0.90	0.91	0.23	0.78	0.81	0.87
		多目标	0.26	0.79	0.74	0.81	0.24	0.71	0.60	0.71
√	√	单目标	0.20	0.93	0.95	0.97	0.19	0.88	0.87	0.92
		多目标	0.23	0.85	0.79	0.86	0.20	0.77	0.67	0.76

层数会导致模型计算量提升、训练不稳定且优化困难。为平衡性能与复杂度，我们预先通过实验将Decoder层数固定为3层，以确保网络具备较好性能与训练稳定性。

表5展示了在Decoder层数为3层的结构下，不同编码器Encoder层数和初始查询向量个数在多目标情形下的实验结果。可以得出如下结论，首先，当Encoder层数为4且初始查询向量个数为50时，模型在测试集上取得了最优性能。其次，对于不同Encoder层数，使用50个查询向量的性能均稳定优于100个，这证明查询向量过多会产生大量冗余输出，不仅显著增加了匈牙利匹配的计算复杂度，也导致了正负样本设计的失衡，从而使网络训练困难。最终，我们选择Encoder层数为4、Decoder层数为3、查询向量数量为50的配置作为最优方案。

## 5 结语

本文提出一种双流特征提取与DETR定位的深度神经网络结构，该网络接收从原始回波得来的距

离像数据作为输入，综合处理其幅度域与相位域信息，在双流特征处理和通道注意力机制共同作用下提取目标时空特征。为了充分利用上述特征，采用DETR定位输出，得到优于现有方案的定位结果。除此之外，我们还对网络结构及参数做了研究分析。

尽管本文所提方法在评价指标上表现尚可，但是在处理极端场景时仍面临一定的挑战。具体而言，受限于单视角小孔径雷达系统性能，在多目标间距过近以及视角遮挡情形下容易出现目标混淆、遗漏，导致定位精度以及召回率下降。同时，当前模型在推理阶段采用固定置信度阈值筛选策略，在面对未知场景时，难以始终维持虚警率与漏检的最优平衡。因此，未来工作一方面将针对性开展深层次特征挖掘工作以及长时序信息融合研究，利用目标运动特性缓解上述问题，另一方面探索自适应动态置信度阈值机制，进一步提升模型泛化性能。

**利益冲突** 所有作者均声明不存在利益冲突

**Conflict of Interests** The authors declare that there is no conflict of interests

## 参考文献

- [1] 王增福, 邵毅, 祁登亮, 等. 一种基于一致性的分布式天基雷达组网空中目标高度估计与定位方法[J]. 雷达学报, 2023, 12(6): 1249–1262. doi: [10.12000/JR23157](https://doi.org/10.12000/JR23157).  
WANG Zengfu, SHAO Yi, QI Dengliang, et al. Consistency-based air target height estimation and location in distributed space-based radar network[J]. *Journal of Radars*, 2023, 12(6): 1249–1262. doi: [10.12000/JR23157](https://doi.org/10.12000/JR23157).
- [2] 朱丹, 徐威远, 陈文娟, 等. 基于光波复用网络的分布式多目标定位系统[J]. 雷达学报, 2019, 8(2): 171–177. doi: [10.12000/JR19028](https://doi.org/10.12000/JR19028).  
ZHU Dan, XU Weiyuan, CHEN Wenjuan, et al. Distributed multi-target localization system based on optical wavelength

表 5 Encoder 层数与查询数量消融实验结果补充表注

Tab. 5 Ablation study results on the number of encoder layers and query numbers.

Encoder 层数	查询数量	阈值=0.7m		阈值=0.5m	
		AP	R	AP	R
3层	100	0.62	0.72	0.41	0.53
	50	0.71	0.78	0.55	0.68
4层	100	0.63	0.71	0.54	0.67
	50	0.79	0.86	0.67	0.76
5层	100	0.44	0.52	0.31	0.42
	50	0.72	0.78	0.56	0.67
6层	100	0.43	0.53	0.32	0.47
	50	0.73	0.79	0.54	0.66

- division multiplexing network[J]. *Journal of Radars*, 2019, 8(2): 171–177. doi: [10.12000/JR19028](https://doi.org/10.12000/JR19028).
- [3] 蒋留兵, 张泽, 车俐, 等. 基于合成双基地毫米波雷达的非视距目标定位方法[J]. *火力与指挥控制*, 2025, 50(7): 120–124,132. doi: [10.3969/j.issn.1002-0640.2025.07.016](https://doi.org/10.3969/j.issn.1002-0640.2025.07.016).
- JIANG Liubing, ZHANG Ze, CHE Li, *et al.* A non-line-of-sight target localization method based on synthetic dual-base millimeter-wave radar[J]. *Fire Control & Command Control*, 2025, 50(7): 120–124,132. doi: [10.3969/j.issn.1002-0640.2025.07.016](https://doi.org/10.3969/j.issn.1002-0640.2025.07.016).
- [4] 郭紫玮, 张红娟, 赵智博, 等. 基于路侧激光雷达的车辆目标跟踪与定位[J]. *测绘通报*, 2024(12): 84–89. doi: [10.13474/j.cnki.11-2246.2024.1213](https://doi.org/10.13474/j.cnki.11-2246.2024.1213).
- GUO Ziyi, ZHANG Hongjuan, ZHAO Zhibo, *et al.* Vehicle target tracking and positioning based on roadside LiDAR[J]. *Bulletin of Surveying and Mapping*, 2024(12): 84–89. doi: [10.13474/j.cnki.11-2246.2024.1213](https://doi.org/10.13474/j.cnki.11-2246.2024.1213).
- [5] 陈锐志, 叶锋. 基于Wi-Fi信道状态信息的室内定位技术现状综述[J]. *武汉大学学报(信息科学版)*, 2018, 43(12): 2064–2070. doi: [10.13203/j.whugis20180176](https://doi.org/10.13203/j.whugis20180176).
- CHEN Ruizhi and YE Feng. An overview of indoor positioning technology based on Wi-Fi channel state information[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(12): 2064–2070. doi: [10.13203/j.whugis20180176](https://doi.org/10.13203/j.whugis20180176).
- [6] 毛东方, 蒋国平. 基于UKF的蓝牙-PDR多传感器融合室内定位算法[J]. *计算机科学*, 2025, 52(S2): 250100083. doi: [10.11896/jsjcx.250100083](https://doi.org/10.11896/jsjcx.250100083).
- MAO Dongfang and JIANG Guoping. Bluetooth-PDR multi-sensor fusion indoor positioning method based on UKF[J]. *Computer Science*, 2025, 52(S2): 250100083. doi: [10.11896/jsjcx.250100083](https://doi.org/10.11896/jsjcx.250100083).
- [7] SEYFIOĞLU M S, GÜRBÜZ S Z, ÖZBAYOĞLU A M, *et al.* Deep learning of micro-Doppler features for aided and unaided gait recognition[C]. 2017 IEEE Radar Conference (RadarConf), Seattle, USA, 2017: 1125–1130. DOI: [10.1109/RADAR.2017.7944373](https://doi.org/10.1109/RADAR.2017.7944373).
- [8] 夏正欢, 张群英, 叶盛波, 等. 一种便携式伪随机编码超宽带人体感知雷达设计[J]. *雷达学报*, 2015, 4(5): 527–537. doi: [10.12000/JR15027](https://doi.org/10.12000/JR15027).
- XIA Zhenghuan, ZHANG Qunying, YE Shengbo, *et al.* Design of a handheld pseudo random coded UWB radar for human sensing[J]. *Journal of Radars*, 2015, 4(5): 527–537. doi: [10.12000/JR15027](https://doi.org/10.12000/JR15027).
- [9] 金添, 宋勇平. 超宽带雷达建筑物结构稀疏成像[J]. *雷达学报*, 2018, 7(3): 275–284. doi: [10.12000/JR18031](https://doi.org/10.12000/JR18031).
- JIN Tian and SONG Yongping. Sparse imaging of building layouts in ultra-wideband radar[J]. *Journal of Radars*, 2018, 7(3): 275–284. doi: [10.12000/JR18031](https://doi.org/10.12000/JR18031).
- [10] FARWELL M, ROSS J, LUTTRELL R, *et al.* Sense through the wall system development and design considerations[J]. *Journal of the Franklin Institute*, 2008, 345(6): 570–591. doi: [10.1016/j.jfranklin.2008.01.004](https://doi.org/10.1016/j.jfranklin.2008.01.004).
- [11] HARIKESH, CHAUHAN S S, BASU A, *et al.* Through the wall human subject localization and respiration rate detection using multichannel Doppler radar[J]. *IEEE Sensors Journal*, 2021, 21(2): 1510–1518. doi: [10.1109/JSEN.2020.3016755](https://doi.org/10.1109/JSEN.2020.3016755).
- [12] PRASAD M S and PANIGRAHI T. Distributed maximum likelihood DOA estimation algorithm for correlated signals in wireless sensor network[J]. *Wireless Personal Communications*, 2019, 105(4): 1527–1544. doi: [10.1007/s11277-019-06158-8](https://doi.org/10.1007/s11277-019-06158-8).
- [13] KUNDU D. Modified MUSIC algorithm for estimating DOA of signals[J]. *Signal Processing*, 1996, 48(1): 85–90. doi: [10.1016/0165-1684\(95\)00126-3](https://doi.org/10.1016/0165-1684(95)00126-3).
- [14] ZHU Zhihao, GUO Shisheng, CHEN Jiahui, *et al.* Non-line-of-sight targets localization algorithm via joint estimation of DoD and DoA[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 8506311. doi: [10.1109/TIM.2023.3323003](https://doi.org/10.1109/TIM.2023.3323003).
- [15] ZHANG Ying and NG B P. MUSIC-like DOA estimation without estimating the number of sources[J]. *IEEE Transactions on Signal Processing*, 2010, 58(3): 1668–1676. doi: [10.1109/TSP.2009.2037074](https://doi.org/10.1109/TSP.2009.2037074).
- [16] ZHANG Huamei, ZHOU Sheng, XU Cheng, *et al.* A real-time automatic method for target locating under unknown wall characteristics in through-wall imaging[J]. *Progress in Electromagnetics Research M*, 2020, 89: 189–197. doi: [10.2528/PIERM19111101](https://doi.org/10.2528/PIERM19111101).
- [17] 刘新, 朱海滨, 刘宗强, 等. 分布式无线组网超宽带穿墙雷达系统设计与联合定位[J]. *雷达学报(中英文)*, 2024, 13(4): 747–760. doi: [10.12000/JR23239](https://doi.org/10.12000/JR23239).
- LIU Xin, ZHU Haibin, LIU Zongqiang, *et al.* The design and joint positioning method of an ultra-wideband through-wall radar system for distributed wireless networking[J]. *Journal of Radars*, 2024, 13(4): 747–760. doi: [10.12000/JR23239](https://doi.org/10.12000/JR23239).
- [18] 柳景斌, 王泽民, 吕轩凡, 等. 低成本毫米波雷达的室内自定位方法[J]. *武汉大学学报(信息科学版)*, 2023, 48(9): 1399–1408. doi: [10.13203/j.whugis20210593](https://doi.org/10.13203/j.whugis20210593).
- LIU Jingbin, WANG Zemin, LÜ Xuanfan, *et al.* Indoor ego-localization method for low cost millimeter wave radar[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(9): 1399–1408. doi: [10.13203/j.whugis20210593](https://doi.org/10.13203/j.whugis20210593).
- [19] LEIGSNERING M, AMIN M, AHMAD F, *et al.* Multipath exploitation and suppression for SAR imaging of building interiors: An overview of recent advances[J]. *IEEE Signal Processing Magazine*, 2014, 31(4): 110–119. doi: [10.1109/MSP.2014.2312203](https://doi.org/10.1109/MSP.2014.2312203).

- [20] SOLIMENE R, CATAPANO I, GENNARELLI G, *et al.* SAR imaging algorithms and some unconventional applications: A unified mathematical overview[J]. *IEEE Signal Processing Magazine*, 2014, 31(4): 90–98. doi: [10.1109/MSP.2014.2311271](https://doi.org/10.1109/MSP.2014.2311271).
- [21] LI Huquan, CUI Guolong, GUO Shisheng, *et al.* Target tracking and ghost mitigation based on multi-view through-the-wall radar imaging[C]. 2020 IEEE Radar Conference (RadarConf20), Florence, Italy, 2020: 1–5. DOI: [10.1109/RadarConf2043947.2020.9266680](https://doi.org/10.1109/RadarConf2043947.2020.9266680).
- [22] BREHIER H, BRELOY A, REN Chengfang, *et al.* Through the wall radar imaging via Kronecker-structured Huber-type RPCA[J]. *Signal Processing*, 2024, 214: 109228. doi: [10.1016/j.sigpro.2023.109228](https://doi.org/10.1016/j.sigpro.2023.109228).
- [23] 汤寓麟, 李厚朴, 张卫东, 等. 侧扫声纳检测沉船目标的轻量化 DETR-YOLO法[J]. *系统工程与电子技术*, 2022, 44(8): 2427–2436. doi: [10.12305/j.issn.1001-506X.2022.08.06](https://doi.org/10.12305/j.issn.1001-506X.2022.08.06).  
TANG Yulin, LI Houpu, ZHANG Weidong, *et al.* Lightweight DETR-YOLO method for detecting shipwreck target in side-scan sonar[J]. *Systems Engineering and Electronics*, 2022, 44(8): 2427–2436. doi: [10.12305/j.issn.1001-506X.2022.08.06](https://doi.org/10.12305/j.issn.1001-506X.2022.08.06).
- [24] 皮任东. 基于路侧激光雷达和摄像头融合的目标轨迹追踪方法研究[D]. 济南: 山东大学, 2022. DOI: [10.27272/d.cnki.gshdu.2022.005895](https://doi.org/10.27272/d.cnki.gshdu.2022.005895).  
PI Rendong. Research on object tracking method based on fusion of roadside LiDAR and camera[D]. Jinan: Shandong University, 2022. DOI: [10.27272/d.cnki.gshdu.2022.005895](https://doi.org/10.27272/d.cnki.gshdu.2022.005895).
- [25] LEE J, PARK K, and KIM Y. Deep learning-based device-free localization scheme for simultaneous estimation of indoor location and posture using FMCW radars[J]. *Sensors*, 2022, 22(12): 4447. doi: [10.3390/s22124447](https://doi.org/10.3390/s22124447).
- [26] STEPHAN M, SANTRA A, and FISCHER G. Human target detection and localization with radars using deep learning[M]. WANI M A, KHOSHGOFTAAR T M, and PALADE V. *Deep Learning Applications*. Singapore: Springer, 2020: 173–197. DOI: [10.1007/978-981-15-6759-9\\_8](https://doi.org/10.1007/978-981-15-6759-9_8).
- [27] GHORBANI F and SOLEIMANI H. Through-the-wall radar under electromagnetic complex wall: A deep learning approach[J]. *Results in Applied Mathematics*, 2023, 17: 100354. doi: [10.1016/j.rinam.2022.100354](https://doi.org/10.1016/j.rinam.2022.100354).
- [28] GHORBANI F and SOLEIMANI H. Simultaneous estimation of wall and object parameters in TWR using deep neural network[J]. *International Journal of Antennas and Propagation*, 2022, 2022: 7810213. doi: [10.1155/2022/7810213](https://doi.org/10.1155/2022/7810213).
- [29] 赵思肖, 梁步阁, 杨德贵, 等. 基于Faster RCNN的IR-UWB穿墙雷达邻近多目标检测算法[J]. *无线电工程*, 2023, 53(1): 80–86. doi: [10.3969/j.issn.1003-3106.2023.01.011](https://doi.org/10.3969/j.issn.1003-3106.2023.01.011).  
ZHAO Sixiao, LIANG Buge, YANG Degui, *et al.* Multiple adjacent targets detection algorithm for IR-UWB through-wall radar based on Faster-RCNN[J]. *Radio Engineering*, 2023, 53(1): 80–86. doi: [10.3969/j.issn.1003-3106.2023.01.011](https://doi.org/10.3969/j.issn.1003-3106.2023.01.011).
- [30] ZHU Dongsheng, WANG Changlong, HAN Chong, *et al.* TWLBR: Multi-human through-wall localization and behavior recognition based on MIMO radar[C]. GLOBECOM 2022- 2022 IEEE Global Communications Conference, Rio de Janeiro, Brazil, 2022: 3186–3191. DOI: [10.1109/GLOBECOM48099.2022.10001129](https://doi.org/10.1109/GLOBECOM48099.2022.10001129).
- [31] 渠晓东, 王文远, 孟昊宇, 等. 基于鲁棒主成分分析及YOLOv8的穿墙雷达运动人员检测方法[J]. *信号处理*, 2025, 41(8): 1390–1403. doi: [10.12466/xhcl.2025.08.008](https://doi.org/10.12466/xhcl.2025.08.008).  
QU Xiaodong, WANG Wenyuan, MENG Haoyu, *et al.* Moving human detection method in through-the-wall radar based on robust principal component analysis and YOLOv8[J]. *Journal of Signal Processing*, 2025, 41(8): 1390–1403. doi: [10.12466/xhcl.2025.08.008](https://doi.org/10.12466/xhcl.2025.08.008).
- [32] 王明阳. 穿墙雷达人体行为识别方法研究[D]. 成都: 电子科技大学, 2019.  
WANG Mingyang. Research on human action recognition exploiting through-wall radar[D]. Chengdu: University of Electronic Science and Technology of China, 2019.
- [33] CARION N, MASSA F, SYNNAEVE G, *et al.* End-to-end object detection with transformers[C]. The 16th European Conference on Computer Vision, Glasgow, UK, 2020: 213–229. DOI: [10.1007/978-3-030-58452-8\\_13](https://doi.org/10.1007/978-3-030-58452-8_13).
- [34] VASWANI A, SHAZEER N, PARMAR N, *et al.* Attention is all you need[C]. The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017: 6000–6010.
- [35] HE Kaiming, ZAHNG Xiangyu, REN Shaoqing, *et al.* Deep residual learning for image recognition[C]. The IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, 2016: 770–778. DOI: [10.1109/CVPR.2016.90](https://doi.org/10.1109/CVPR.2016.90).
- [36] BA J L, KIROUS J R, HINTON G E. Layer normalization[EB/OL]. arXiv:1607.06450, 2016. DOI: [10.48550/arXiv.1607.06450](https://doi.org/10.48550/arXiv.1607.06450).
- [37] GIRSHICK R. Fast R-CNN[C]. The IEEE International Conference on Computer Vision, Santiago, Chile, 2015: 1440–1448. DOI: [10.1109/ICCV.2015.169](https://doi.org/10.1109/ICCV.2015.169).
- [38] CUI Guolong, KONG Lingjiang, and YANG Jianyu. A back-projection algorithm to stepped-frequency synthetic aperture through-the-wall radar imaging[C]. The 1st Asian and Pacific Conference on Synthetic Aperture Radar, Huangshan, China, 2007: 123–126. DOI: [10.1109/APSAR.2007.4418570](https://doi.org/10.1109/APSAR.2007.4418570).

## 作者简介

熊 壮, 男, 电子科技大学信息与通信工程学院硕士研究生, 研究方向为穿墙雷达目标定位与跟踪。

郭世盛, 男, 电子科技大学研究员, 硕士生导师, 研究方向为城市环境遮蔽目标探测、基于雷达的人体行为识别。

唐珑吟, 女, 电子科技大学信息与通信工程学院博士研究生, 研究方向为雷达信号处理、人体行为识别。

周楚宜, 男, 电子科技大学信息与通信工程学院硕士研究生, 研究方向为毫米波雷达视觉传感器融合。

姚 禹, 男, 电子科技大学信息与通信工程学院博士研究生, 研究方向分布式雷达目标探测。

崔国龙, 男, 电子科技大学教授, 青年长江学者, 博士生导师。研究方向为最优化理论和算法、雷达目标检测理论、波形多样性以及城市环境目标探测等。

(责任编辑: 于青)