

非视距条件下基于特征融合的UWB到达角估计方法

曾文敏¹, 郑柏烽¹, 刘晋廷^{1,2}, 鲍亚川³, 尹继凯⁴, 李建佳³, 张霆廷¹

(1. 哈尔滨工业大学(深圳)空天网络与智能感知重点实验室, 广东 深圳 518000; 2. 香港科技大学(广州)物联网学域, 广东 广州 511453; 3. 中国电子科技集团公司第五十四研究所 综合时空网络与装备技术全国重点实验室, 河北 石家庄 050081; 4. 中国电子科技集团公司第五十四研究所, 河北 石家庄 050081)

摘要: 超宽带(UWB, ultra-wideband)技术能够提供高精度的定位信息, 在室内定位中具有显著优势。到达角(AOA, angle of arrival)估计作为UWB定位的关键技术之一, 对提高定位精度至关重要。然而, 在实际应用中, UWB AOA估计面临着诸多挑战, 尤其是在非视距(NLOS, non-line-of-sight)、天线硬件损伤、环境变化情况复杂情况下, 这些因素会造成信号失真和测量偏差, 从而降低估计的精度, 而传统的建模方法往往难以有效处理这些非线性问题。因此, 设计了一种基于特征融合的UWB AOA估计方法。该方法融合了CIR数据和双天线接收信号特征, 并引入Transformer编码器对复杂信号进行深度挖掘, 以提升AOA估计的精度。实验结果表明, 所提方法在NLOS条件下可以实现高精度的AOA估计。

关键词: 超宽带信号; 到达角估计; 深度学习; 特征融合; 非视距

中图分类号: TN925

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2025.00495

Feature fusion method for UWB angle of arrival estimation under non-line-of-sight conditions

ZENG Wenmin¹, ZHENG Bofeng¹, LIU Jinting^{1,2}, BAO Yachuan³, YIN Jikai⁴, LI Jianjia³,
ZHANG Tingting¹

1. Guangdong Provincial Key Laboratory of Space-Aerial Networking and Intelligent Sensing, Harbin Institute of Technology(Shenzhen), Shenzhen 518000, China

2. IOT Thrust, The Hong Kong University of Science and Technology(Guangzhou), Guangzhou 511453, China

3. State Key Laboratory of Comprehensive PNT Network and Equipment Technology, The 54th Research Institute of China Electronics Technology Group Corporation, Shijiazhuang 050081, China

4. The 54th Research Institute of China Electronics Technology Group Corporation, Shijiazhuang 050081, China

Abstract: Ultra-wideband (UWB) technology is recognized for its ability to provide high-precision positioning information, offering significant advantages in indoor positioning. Angle of arrival (AOA) estimation, as one of the key technologies in UWB positioning, is considered crucial for improving positioning accuracy. However, in practical applications, UWB AOA

收稿日期: 2025-03-05; 修回日期: 2025-06-10

通信作者: 张霆廷, zhangtt@hit.edu.cn

基金项目: 国家自然科学基金面上项目(No. 62171160); 广东省重点实验室项目(2024)(No. 2024KSYS023); 深圳市重点实验室项目(No. ZDSYS20210623091808025); 鹏城实验室重大重点项目(No. PCL2024A01); 卫星导航系统与装备技术国家重点实验室开放基金资助项目(No. CEPNT2022A03); 中国电子科技集团公司第五十四研究所技术开发(委托)项目(No. HX20210106)

Foundation Items: The Natural Science Foundation of China (No. 62171160), Guangdong Provincial Key Laboratory (2024) (No. 2024KSYS023), Shenzhen Key Laboratories (No. ZDSYS20210623091808025), Major Key Project of PCL (No. PCL2024A01), The Open Fund of the State Key Laboratory of Satellite Navigation System and Equipment Technology (No. CEPNT2022A03), The Technology Development (Commissioned) Project of the 54th Research Institute of China Electronics Technology Group Corporation (No. HX20210106)

estimation is faced with numerous challenges, particularly in complex environments such as non-line-of-sight (NLOS) conditions, antenna hardware impairments and environmental variations. These factors are known to cause signal distortion and measurement deviations, thereby reducing estimation accuracy. Traditional modeling methods are often found inadequate in effectively addressing these nonlinear issues. Therefore, a feature fusion-based UWB AOA estimation method was designed. This approach integrated channel impulse response (CIR) data and dual-antenna received signal features, while a Transformer encoder was introduced to deeply analyze complex signals, thereby enhancing AOA estimation accuracy. Experimental results demonstrated that the proposed method could achieve high-precision AOA estimation under NLOS conditions.

Key words: UWB signal, AOA estimation, deep learning, feature fusion, NLOS

0 引言

超宽带 (UWB, ultra-wideband) 技术凭借其高精度定位能力、强穿透性、抗干扰性以及低系统复杂度, 在室内定位领域扮演着越来越重要的角色^[1-4]。UWB 技术能够实现厘米级的定位精度, 适用于多种应用场景, 如矿井人员定位^[5-7]、贵重物品仓储管理^[8-9]和机器人运动跟踪^[10-13]等。基于单基站天线阵列的到达角度 (AOA, angle of arrival) 估计方法进一步提升了定位精度, 降低了系统成本和部署难度, 同时提高了系统的鲁棒性。这些优势使得 UWB 技术在室内定位领域, 尤其是对定位精度要求较高的场景中, 展现出显著的应用价值。

然而, 在空间结构复杂、多径效应明显的室内环境中, UWB 信号在基站端的 AOA 估计面临着多种挑战。首先, UWB 定位模组存在的硬件损伤 (如天线耦合), 导致基站接收信号不一致, 在边缘区域出现 AOA 估计值严重失真的情况, 影响 AOA 估计结果的准确性。其次, 非视距 (NLOS, non-line-of-sight) 传播环境对 UWB 系统的影响尤为显著。室内复杂的空间分布易造成信号的衍射、散射、反射以及其他不规则损耗, 在直达径缺失的情况下, 受多个反射径叠加的影响, UWB 信号可能发生不可预知的变化, 造成 UWB 系统的定位精度出现严重失真, 从而降低整个 UWB 定位系统的性能^[14-16]。另外, UWB 定位系统开发还存在技术难度高、跨平台兼容性较差和部署成本较高等技术难点, 这对 UWB 定位系统中信号 AOA 估计的精度和效率提出了更高的要求。因此, 有效补偿 UWB 定位芯片模组的硬件损伤, 准确识别并抑制 NLOS 环境对 AOA 估计精度的影响, 提高 AOA 估计的准确性, 已成为 UWB 技术在室内定位领域需要解决的关键问题。

近年来, 研究者借助机器学习 (ML, machine learning)、信道模型仿真等手段, 在基于 UWB 信

号的单站 AOA 估计、UWB 定位系统 LOS 和 NLOS 识别等领域取得了显著的研究成果。文献[17]提出了一种单天线 AOA 估计方法, 通过在单天线标签上接收来自双天线锚点的同步 UWB 信号进行 AOA 估计, 实现了与双天线 AOA 估计相近的性能, 同时降低了设计复杂性和部署成本。文献[18]使用大型阵列对 3.1~10.6 GHz 的超宽带频率范围内的 AOA 进行了研究, 采用二维 Unitary ESPRIT 算法高分辨率估计包括方位角和仰角在内的多径分量 AOA。在机器学习领域, 基于 ML 的 UWB AOA 估计方法表现出了超越传统规则方法的性能, 尤其是在训练和评估环境相同时。笔者前期的研究提出了一种基于支持向量回归 (SVR, support vector regression) 的 AOA 估计方法, 以应对硬件不完善带来的影响。该方法选取从接收信号中提取的一组高相关特征作为输入, 这组高相关特征包括基于相位差到达 (PDOA, phase-difference-of-arrival) 估计得到的 AOA、双天线信道脉冲响应 (CIR, channel impulse response) 相关系数的实部等, 并使用鼠群优化器 (RSO, rat swarm optimizer) 对 SVR 超参数进行寻优。实验测量结果表明, 与传统的基于 PDOA 的 AOA 估计方法相比, 在多径效应影响明显的情况下, 该方法具有明显的性能优势^[19]。文献[20]探讨了使用机器学习进行 UWB 非视距和视距信道分类的方法。这一方法对于提高 UWB 定位系统的鲁棒性和准确性至关重要, 因为 NLOS 条件下的信号传播会引入较大的误差。文献[21]利用信道脉冲响应的多个静态和时变特征, 结合功率角谱进行训练, 实验证明其分类性能优于多种传统机器学习算法。文献[22]通过生成高斯脉冲作为 UWB 信号, 并采用长短期记忆网络 (LSTM, long short-term memory) 处理复杂的室内环境, 分析到达时间 (TOA, time of arrival) 距离模型和使用 LSTM 网络预测用户位置, 进一步提高了 UWB 室内定位的精

度, 展现了深度学习在UWB定位中的应用潜力。文献[23]提出了一种基于深度卷积神经网络(DCNN, deep convolutional neural network)的多天线UWB系统AOA估计方法, 实现了出色的99百分位误差性能, 印证了机器学习在AOA估计中的有效性。文献[24]对复数CIR包络的单次测量加窗处理, 并将幅值和相位馈送到神经网络的输入层, 实现对UWB信号到达角度的估计。文献[25]在复杂室内UWB环境中引入了一种基于残差网络(ResNet, residual network)的AOA估计方法, 通过回归任务有效降低了复杂环境对AOA估计的干扰, 实现了95%的估计误差低于15.27°的效果。文献[26]将双天线的PDOA、到达时间差(TDOA, time difference of arrival)和CIR测量数据、双向测距距离估计, 以及由总功率与第一路径功率之比构成的评分特征共同输入CNN, 最终在训练集和测试集上分别达到2.03°和19.35°的均方误差。近年来, Transformer架构凭借其强大的特征提取能力和对长距离依赖关系的建模优势, 在信号处理领域受到广泛关注。该结构不仅能够有效处理复杂的信号特征, 还能在多路径和NLOS环境中提取关键信息, 从而显著提升模型性能^[27-28]。

针对NLOS环境下UWB到达角估计问题, 现有研究多采用传统的深度学习网络架构, 如CNN、LSTM等。这些方法在特征提取上存在一定的局限, 未能充分挖掘CIR和天线数据的全局关联性。同时, 它们对NLOS场景下复杂信号特征的处理能力有限, 难以准确捕捉信号间的关键依赖关系。为此, 本文提出一种全新的基于特征融合的AOA估计模型。该方法通过充分融合CIR特征与双天线信号特征, 学习到信道CIR数据与AOA之间的复杂映射关系, 克服了传统模型在硬件损伤和恶劣传播环境下的局限性, 实现了更精确的AOA估计。本文的主要贡献如下:

1) 提出一种特征融合网络结构, 充分利用CIR特征和双天线特征所提供的互补信息。其中, CIR特征涵盖信道传播环境的丰富细节, 而双天线特征提供对信号源方向的直接指示。该网络结构分别对CIR数据和双天线接收信号进行特征提取, 并在融合层实现有效整合, 从而在复杂传播环境下实现高精度的AOA估计。

2) 引入了Transformer编码器模型, 对复杂信号特征进行深度挖掘。通过与LSTM和残差网络

(ResNet)的对比实验, 证明了所提方法在NLOS条件下估计AOA的优越性。

3) 在多种NLOS环境中开展了大规模数据采集工作, 并基于所采集数据集对所提方法进行了全面的性能评估, 验证了其有效性与鲁棒性。

1 测角原理与问题描述

AOA估计是通信、定位、雷达等领域中的重要技术, 其核心挑战之一是如何精确测量信号到达天线阵列中各天线的的时间差异。

在天线阵列中, 由于信号传播路径的差异, 各天线接收到的信号存在微小的时间延迟, 这种时间差与信号的到达角度直接相关, 构成了AOA估计算法的基础。在UWB信号的AOA估计中, 最常用的方法是PDOA。PDOA方法通过测量阵列中各天线接收到信号的相位差, 而不是依赖绝对时间延迟, 来实现角度估计。相比传统的时延估计方法, PDOA方法能够有效抵抗信号时延抖动和调度不确定性, 因而具有更强的稳定性。

在二维平面内, 以单发射天线和双接收天线为例, 假设信号满足远场条件。其示意图如图1所示。




图1 一发双收示意图

假设天线1和天线2接收到的相位分别为 ϕ_1 和 ϕ_2 。此时, 双天线阵列获得的相位差可表示为:

$$\phi = \phi_2 - \phi_1 = 2\pi \frac{d}{\lambda} \sin \theta \quad (1)$$

可以解得:

$$\theta = \arcsin \left(\frac{\phi \lambda}{2\pi d} \right) \quad (2)$$

信号的相位是周期性的, 其范围通常被限定为 $[-\pi, \pi]$ 。如果天线间距 $d \geq \lambda/2$, 则可能会导致同一个 ϕ 对应多个 θ , 即发生相位缠绕^[9]。为了避免这种情况, 需要满足天线间距 $d < \lambda/2$ 。

理论上, 利用PDOA估计AOA能取得不错的

精度。在NLOS环境中，由于信号会受到障碍物反射和多径效应的干扰，该方法往往难以实现准确的AOA估计。NLOS下PDOA估计的AOA如图2所示。尽管在NLOS环境下，基于PDOA的AOA估计在 -60° 至 40° 区间内整体呈线性变化，但其精度和稳定性较差，存在明显偏差；而在其他角度范围内，误差的非线性表现更加显著。




图2 NLOS下PDOA估计的AOA

这主要是由以下两个因素造成：一是硬件损伤。设备的相位噪声、收发机时钟漂移、阵列中天线元件间的相互耦合、未知元件响应、阵列元件位移以及功率放大器的非线性等问题，都可能造成信号失真，从而使基于模型的定位算法无法准确推断目标位置^[29]。二是环境因素。受障碍物遮挡影响，信号直达径产生严重衰减，接收到的信号通常是多径叠加的结果，导致PDOA的测量结果存在较大偏差。因此，仅仅依靠PDOA方法难以满足高精度定位的需求，且在复杂环境中，PDOA的适用性受到显著

限制。为克服上述挑战，亟须引入更先进的技术。

2 基于特征融合的AOA估计方法

2.1 模型介绍

本文提出了一种基于特征融合的AOA估计方法，旨在综合利用不同特征的优势，实现更加精准的AOA估计。该方法充分利用了CIR数据和双天线接收信号特征所提供的互补信息，CIR数据涵盖了信道传播环境的丰富细节，而双天线接收信号特征直接反映信号源的方向信息。通过构建特征融合网络，本文分别对CIR和双天线信号特征进行提取，并在网络的融合层实现了多特征融合，从而在复杂传播环境下实现高精度和高鲁棒性的AOA估计，算法流程如图3所示。

2.2 CIR特征提取模块

CIR特征提取模块由CNN和Transformer编码器组成。CNN模块通过卷积层和池化层提取信号的时空特征，从而生成深层次的表示，用于后续的分析。卷积层通过滑动窗口操作进行局部特征提取，能够有效捕捉CIR信号中的局部模式。池化层则在降低计算量的同时，确保了关键信息的完整性，进一步提升了模型的泛化能力。

CNN的参数设置见表1。由于超宽带信号为一维数据，因此本文采用一维卷积神经网络进行处理。CNN的核心组成部分是卷积层，卷积运算用于特征提取。一维卷积运算涉及原始信号与卷积核的相互作用。以下是一维卷积运算的详细解释和计算过程：原始输入数据是一个向量，大小为 N 。

卷积核是一个向量 w ，大小为 M ，其中 $N \leq M$ 。输出向量 y ，用于存储卷积运算的结果，其表达

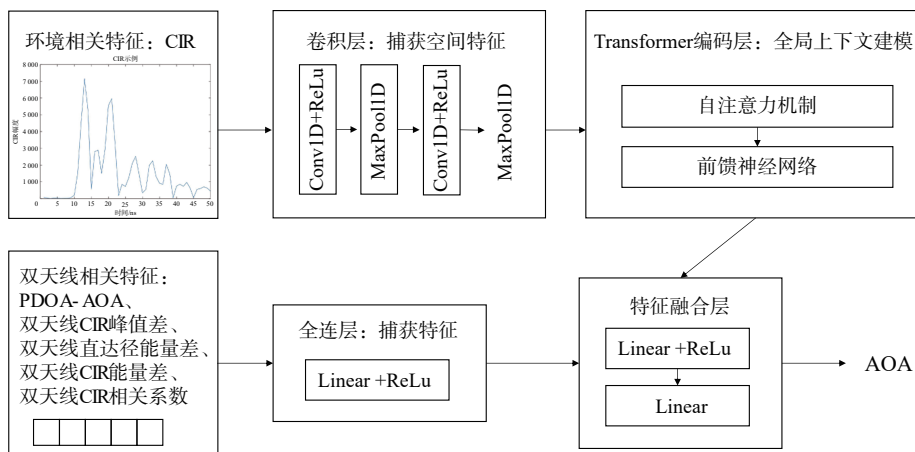


图3 基于特征融合的AOA估计算法流程

表1 CNN参数设置

类型	输入通道	输出通道	核大小	步长	输出形状	神经元丢弃概率
Input	—	—	—	—	batch_size×2×50	0.00
Cov1	2	64	3	1	batch_size×64×50	0.00
ReLu1	—	—	—	—	batch_size×64×50	0.00
MaxPool1	64	64	2	2	batch_size×64×25	0.20
Cov2	64	128	3	1	batch_size×128×25	0.00
ReLu2	—	—	—	—	batch_size×128×25	0.00
MaxPool2	128	128	2	2	batch_size×128×12	0.20

如式(3):

$$y = x \otimes w \quad (3)$$

$$y[i] = \sum_{m=1}^{k=0} x[i+m-k]w[k] \quad (4)$$

经过卷积层的一维卷积运算后，数据通常会流入激活层。激活层的主要职能是引入非线性，通过对卷积层输出的数据进行非线性变换，使网络能够学习和模拟更加复杂的函数和模式。非线性映射允许网络从简单的线性关系中抽象出来，捕捉更深层次的特征和数据内在的复杂结构。网络选择的激活函数为ReLU，具体而言：

$$\text{ReLU}(x) = \max(0, x) \quad (5)$$

数据在输入后续网络层之前，往往需要经过池化层的处理。池化层的主要作用是对特征数据进行降维和筛选，通过过滤多余信息，使网络能够更加突出地捕捉到原始数据中的关键特征。常见的池化方式包括最大池化和平均池化，本文所述网络采用最大池化方法。

在CNN模块后，引入Transformer编码器，以增强时序特征的捕获能力。Transformer编码器采用自注意力机制，能够动态评估输入数据中各部分的权重，从而引导网络聚焦于信号中的关键特征，提升对AOA估计的准确性。自注意力机制的使用使模型能够捕捉全局上下文信息，进而增强输出的鲁棒性和准确性。Transformer编码器的流程如图4所示。

Transformer编码器的核心组件之一是自注意力机制，该机制在信息建模与特征提取中具有关键作用。自注意力机制允许模型在处理序列数据时，直接捕捉序列中任意两个位置之间的依赖关系，而不需要依赖固定的上下文信息。自注意力机制的流程如图5所示。

它的输入通常包含3个部分，分别称为查询向量(Q)、键向量(K)和值向量(V)。对于给定的输入矩阵X，每一部分都会通过一个线性变换层进




图4 Transformer编码器的流程

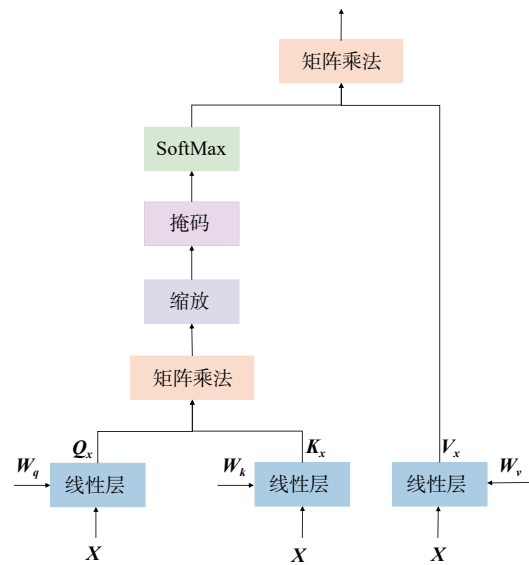


图5 自注意力机制流程

行映射，以生成对应的 Q_x 、 K_x 和 V_x 。

这一过程可以用式(6)、式(7)、式(8)来表示：

$$Q_x = W_q X \quad (6)$$

$$K_x = W_k X \quad (7)$$

$$V_x = W_v X \quad (8)$$

在矩阵乘法之后，通常会对结果进行缩放操

作。这是在自注意力机制中， \mathbf{Q}_x 和 \mathbf{K}_x 的维度通常较大，直接计算得到的注意力分数可能数值过大，容易导致梯度消失或梯度爆炸问题^[30]。缩放通常是将注意力分数除以一个常数 \sqrt{D} ，其中 D 是 \mathbf{K}_x 的维度，以此稳定梯度。掩码层是可选的，主要用于屏蔽某些位置的注意力分数。之后，注意力分数通过SoftMax函数转换为概率分布，使得所有位置的注意力权重之和为1。每个位置的输出都是一个权重值，反映了该位置对最终输出的贡献程度。最后，将SoftMax输出的注意力权重与值向量 \mathbf{V}_x 进行矩阵乘法运算。这一步得到的是加权的值向量，即自注意力机制的最终输出。该输出综合了所有输入位置的信息，但各位置的权重由注意力机制动态决定。自注意力机制的输出值为：

$$\text{Attention}(\mathbf{Q}_x, \mathbf{K}_x, \mathbf{V}_x) = \text{SoftMax}\left(\frac{\mathbf{Q}_x \mathbf{K}_x^T}{\sqrt{D}}\right) \mathbf{V}_x \quad (9)$$

Transformer编码器用到了多自注意力机制，它是自注意力机制的扩展，通过并行处理多个注意力分布，增强了模型的表达和泛化能力。每个注意力头的输出 head_i 如式(10)所示：

$$\text{head}_i = \text{Attention}(\mathbf{Q}_x \mathbf{W}_i^Q, \mathbf{K}_x \mathbf{W}_i^K, \mathbf{V}_x \mathbf{W}_i^V) \quad (10)$$

多头的输出是将各个 head_i 进行拼接，并乘以 \mathbf{W}^O ，如式(11)所示：

$$\text{MultiHeadAttention}(\mathbf{Q}_x, \mathbf{K}_x, \mathbf{V}_x) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) \mathbf{W}^O \quad (11)$$

其中， h 是多头自注意力的“头”数， \mathbf{W}^O 的形状是 $hd_v \times d_{\text{model}}$ ， d_v 为每个注意力“头”输出的维度， d_{model} 为嵌入维度，且 $d_v = d_{\text{model}}/h$ 。

模型中Transformer编码器的关键参数的设置见表2，包括嵌入维度、注意力头数、前馈层维度、编码器层数等。

表2 Transformer编码器参数设置

参数名称	参数值
嵌入维度	128
注意力头数	4
前馈层维度	128
编码器层数	2

2.3 双天线特征提取模块

双天线特征提取模块主要由全连接层构成，旨在提取双天线之间的差异性特征。通过引入双天线接收信号的峰值差异和相位差等额外特征，该模块能够更全面地捕捉天线间的空间信息。该模块使用

多层感知器（MLP, multi-layer perceptron），通过非线性变换增强了特征的表达能力，从而提高了模型对复杂环境的适应性和预测性能。

该模块的输入聚焦于双天线接收信号的差异，选取了以下特征作为输入：

- PDOA-AOA：

$$F_1 = \arcsin\left(\frac{\phi\lambda}{2\pi d}\right) \quad (12)$$

- 直达径峰值差：

$$F_2 = a_1 - a_2 \quad (13)$$

- 信号直达径功率差：

$$F_3 = \bar{p}_1 - \bar{p}_2 \quad (14)$$

- 信号功率差：

$$F_4 = p_1 - p_2 \quad (15)$$

- 两天线 CIR 的相关系数的实部： $F_5 = \text{Corr}(\text{CIR}_1, \text{CIR}_2)$ ，计算如下：

$$\text{Corr}(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}} \quad (16)$$

其中， a_1 、 a_2 为两天线接收信号的直达径峰值， \bar{p}_1 、 \bar{p}_2 为两天线接收信号的直达径功率， p_1 、 p_2 为两天线接收信号的总功率。

3 实验结果与分析

实验所用数据集由DW3000系列设备采集，硬件示意图如图6所示，数据集已上传至广东省空天网络与智能感知重点实验室官方网站。该设备由一发两收天线构成。为了避免相位缠绕，双天线间距设置需要小于 $\lambda/2$ ，这里设置天线间距 d 为2 cm，采用CH5，中心频率为6 489.6 MHz，获得相位差后，AOA可以被估计为：

$$\theta = \arcsin\frac{1.1555\phi}{\pi} \quad (17)$$

在不同实验场景下采集，如图7所示，均为NLOS场景，存在明显的遮挡。实验的主要目的是评估特征融合策略在复杂NLOS环境中的AOA估计性能。为此，实验采用了真实采集的UWB数据集，其中包含CIR和PDOA等关键信息。

本实验共采集了16 790组数据，按60%、20%和20%的比例划分为训练集、验证集和测试集。训练集用于模型学习，验证集用于超参数调整与模型选择，测试集则用于最终评估模型性能，确保结果可靠。在数据采集过程中，将锚点固定在一个稳定的架子上，通过精确控制平台旋转角度，逐步改变




图6 硬件示意图

AOA，以获取不同条件下的样本数据。实验所采用的深度学习模型基于PyTorch框架构建，批次大小设为32，使用Adam优化器进行参数更新。为了确保模型的训练效果，将最大训练周期设定为200次，并引入了早停机制（early stopping）。

具体的软件环境配置信息见表3。

表3 软件环境配置信息

参数名称	版本号
Python	3.9.16
PyTorch	1.12.1
NumPy	1.23.5
Pandas	1.5.3

本实验采用的主要评价指标包括平均绝对误差（MAE, mean absolute error）、均方根误差（RMSE, root mean square error）、标准差（STD, standard deviation）和成功率（Accuracy）。其中，MAE反映了模型预测的准确性，值越小表示模型性能越好。RMSE对较大误差更为敏感，在评价模型时能够反映更严峻的误差情况。标准差可以表示多次测量的离散程度。成功率是指在一定的误差范围内的测量

结果占总测量数的比例，此指标常用来评估算法在实际应用中的可靠性。

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (18)$$

其中， y_i 是真实值， \hat{y}_i 是预测值， N 是样本数量。

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

$$\text{STD} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2} \quad (20)$$

其中， \bar{y} 表示样本均值。

$$\text{Accuracy} = N_{\text{success}}/N_{\text{total}} \times 100\% \quad (21)$$

其中， N_{success} 是符合一定误差范围的样本数量， N_{total} 是总样本数量。


针对所提出模型的超参数选择，在CNN部分，实验分别尝试了卷积层设置为2、3、4，并探索了卷积核大小为2、3、4的不同配置。在Transformer编码器部分，隐藏维度设置为64、128、256，同时调整了多头注意力机制的头数为4、8、16。通过综合评估验证集上的性能表现，最终确定了效果最优的超参数组合。

在NLOS场景下，基于特征融合网络的AOA估计结果如图8所示。由图8可知，大多数估计点分布在参考线附近，表明该模型在多径效应和复杂NLOS环境中仍能保持较高且可靠的预测精度。与传统PDOA方法相比，所提出的特征融合模型在AOA估计方面具有显著优势，能够有效克服PDOA估计中明显的边缘失真问题，并缓解由环境因素引起的精度下降，从而提升预测准确性。

为评估所提方法的优越性，本文对多种AOA估计方法在NLOS场景下的性能表现进行了详细分析。实验重点关注MAE、STD，以及在 $\pm 3^\circ$ 和 $\pm 5^\circ$ 范围内的AOA估计成功率。这些指标能够全面反映各种方法的估计精度和稳定性。所对比的方法包括：



(a) 遮挡物为锡箔纸盒



(b) 遮挡物为墙壁



(c) 遮挡物为墙壁，但添加了人体作为反射体

图7 不同实验场景

表 4 不同模型在训练集和验证集的性能指标均值对比

模型	MAE/°		RMSE/°		STD/°	
	训练集	验证集	训练集	验证集	训练集	验证集
基于 CNN 的特征融合模型	2.812 2	3.753 4	4.326 9	6.501 1	4.270 5	6.450 5
本文所提模型(CNN+Transformer)	2.145 3	2.702 6	4.325 2	5.219 5	4.308 7	5.202 2
基于 CNN+ LSTM 的特征融合模型	4.367 0	6.350 8	9.323 6	14.828 4	9.219 7	14.748 0
基于 ResNet 的特征融合模型	4.556 2	5.646 4	8.451 7	10.972 1	8.362 6	10.900 1
双天线特征全连接模型	9.618 6	9.838 3	19.606 9	20.311 9	19.539 5	20.242 1

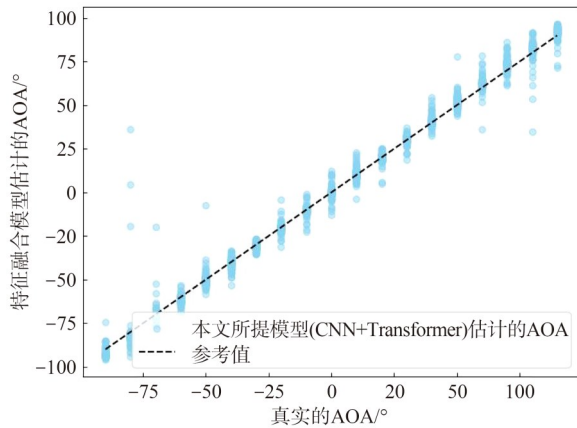


图 8 本文所提模型(CNN+Transformer)的 AOA 估计结果

1) 单一 PDOA^[31]方法：作为一种经典的 AOA 估计技术，该方法基于测量信号的相位差进行角度估算，计算流程较为简单，在理想条件下能够实现较为准确的 AOA 估计。

2) 基于 LSTM^[32]的特征融合模型：LSTM 是一种用于处理时序数据的深度学习模型，能够有效捕捉信号的时间依赖性。在 NLOS 环境下，LSTM 模型能够从时序信号中提取潜在的时序模式，为 AOA 估计提供支持。

3) 基于 ResNet^[33]的特征融合模型：通过引入残差连接缓解梯度消失问题，ResNet 具备较强的深层特征提取能力，在 AOA 估计任务中有助于提高定位精度。

4) 双天线特征全连接模型：该方法提取双天线接收信号的特征，并通过全连接网络进行融合，结合双天线的信息共同实现 AOA 估计。

接下来，对训练集和验证集上的性能进行分析。共进行了 4 次实验，每次对训练集和验证集进行随机划分，并以各项指标的平均值作为最终评估结果。不同模型在训练集和验证集的性能指标均值对比见表 4。表 4 结果显示，本文所提模型在训练集和验证集的 MAE 均为最低，分别为 2.145 3°和

2.702 6°，表明其预测精度高且泛化能力强。同时，标准差 STD 也相对较小，训练集为 4.308 7°，验证集为 5.202 2°，说明结果较为稳定。基于 CNN + Transformer 编码器的特征融合模型和基于 ResNet 的特征融合模型表现较差，尤其在精度上；基于 CNN+ LSTM 的特征融合模型在验证集上的 MAE 和 RMSE 都显著偏高。相比之下，本文所提模型在训练集和验证集上的表现都优于其他模型。

同时还对训练集的±3°准确度和±5°准确度进行了对比，如表 5 和图 9 所示。实验结果表明，本文提出的特征融合模型即 CNN + Transformer 编码器在精度上明显优于其他模型。总体而言，本文提出的特征融合模型在准确度和鲁棒性方面的综合表现最佳。

表 5 不同模型在训练集的±3°和±5°准确度对比

模型	±3°准确度	±5°准确度
基于 CNN 的特征融合模型	66.79%	82.69%
本文所提模型(CNN+Transformer)	76.87%	93.89%
基于 CNN+LSTM 的特征融合模型	56.32%	75.85%
基于 ResNet 的特征融合模型	53.65%	71.99%
双天线特征全连接模型	41.48%	56.21%




图 9 训练集各模型±3°准确度和±5°准确度对比

不同模型在测试集的性能指标均值对比见表6，测试集各模型 $\pm 3^\circ$ 准确度和 $\pm 5^\circ$ 准确度对比如图10所示。结果表明，本文所提模型表现优异，凭借MAE为2.982 $^\circ$ 和 $\pm 5^\circ$ 准确度高达87.11%的优势，显著领先于其他模型。同时，其较低的误差指标和较高的准确度充分证明了其在复杂NLOS环境下的优越性。相比之下，基于CNN+LSTM的特征融合模型和基于ResNet的特征融合模型在误差和准确度方面均较逊色，而传统PDOA方法受多径干扰影响，误差较高，适用性受到严重限制。




图10 测试集各模型 $\pm 3^\circ$ 准确度和 $\pm 5^\circ$ 准确度对比

为进一步验证模型的泛化效果，本文在图7(c)所示场景进行了数据采集，并作为测试集，对各个模型进行测试。不同模型在新场景测试集的性能对比见表7，新场景测试集各模型 $\pm 3^\circ$ 准确度和 $\pm 5^\circ$ 准确度对比如图11所示。由测试结果可知，由于实

验场景的变化，模型的各项性能指标与同环境相比出现明显下降，但与基于CNN+LSTM的特征融合模型、基于ResNet的特征融合模型和双天线特征全连接等模型相比，本文所提模型在各项性能指标和准确度上均有较大优势。




图11 新场景测试集各模型 $\pm 3^\circ$ 准确度和 $\pm 5^\circ$ 准确度对比

4 结束语

针对NLOS条件下多径效应导致的AOA估计精度下降问题，本文提出了一种基于特征融合的AOA估计算法，以提升估计精度。首先，介绍了信道模型和实验硬件平台，明确了关键问题和技术挑战。随后，详细阐述了所提出的特征融合算法。该算法将CIR数据特征与双天线接收信号特征相结合，并充分利用Transformer编码器在深度特征提取方面的优势，从而大幅提升了NLOS条件下AOA的

表6 不同模型在测试集的性能指标均值对比

模型	MAE	RMSE	STD	$\pm 3^\circ$ 准确度	$\pm 5^\circ$ 准确度
基于CNN的特征融合模型	3.835 2	6.961 4	6.933 4	61.59%	77.66%
本文所提模型(CNN+Transformer)	2.982 1	6.405 1	6.387 6	68.52%	87.11%
基于CNN+LSTM的特征融合模型	6.070 4	13.285 2	13.200 1	49.20%	68.78%
基于ResNet的特征融合模型	5.838 1	11.674 1	11.612 6	49.29%	67.31%
双天线特征全连接模型	9.763 4	19.914 1	19.824 5	41.23%	55.75%
PDOA	29.618 3	57.039 6	48.747 0	39.51%	52.62%

表7 不同模型在新场景测试集的性能对比

模型	MAE	RMSE	STD	$\pm 3^\circ$ 准确度	$\pm 5^\circ$ 准确度
基于CNN的特征融合模型	11.5994	26.6933	24.9418	42.68%	60.75%
本文所提模型(CNN+Transformer)	9.4497	23.3318	23.0702	48.09%	66.62%
基于CNN+LSTM的特征融合模型	13.5905	27.8918	27.8878	30.08%	44.51%
基于ResNet的特征融合模型	12.3949	26.8070	25.5204	30.21%	46.64%
双天线特征全连接模型	16.6440	38.8925	38.7618	32.08%	48.54%

估计精度。实验结果表明,所提算法在NLOS条件下表现出显著的优越性,对比传统方法和多种深度学习模型,在复杂环境中展现出更好的估计性能。需要指出的是,目前该算法的泛化性还有待提高,未来可以考虑进一步优化模型结构或扩大数据集,以增强其在不同场景下的适应性与鲁棒性。

参考文献:

- [1] DABOVE P, DI PIETRA V, PIRAS M, et al. Indoor positioning using ultra-wide band (UWB) technologies: positioning accuracies and sensors' performances[C]//Proceedings of the 2018 IEEE/ION Position, Location and Navigation Symposium (PLANS). Piscataway: IEEE Press, 2018: 175-184.
- [2] GAO Y K, POSTOLACHE O, YANG Y S, et al. UWB system and algorithms for indoor positioning[C]//Proceedings of the 2021 Telecoms Conference (ConfTELE). Piscataway: IEEE Press, 2021: 1-6.
- [3] TIAN D D, XIANG Q. Research on indoor positioning system based on UWB technology[C]//Proceedings of the 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference (ITOEC). Piscataway: IEEE Press, 2020: 662-665.
- [4] MAJEED A, ARSAT R, BAHARUDIN M A, et al. Indoor positioning based ranging: a review and literature survey of UWB and Li-fi technologies[J]. ELEKTRIKA- Journal of Electrical Engineering, 2024, 23(1): 18-30.
- [5] CAO B, WANG S B, GE S R, et al. Improving positioning accuracy of UWB in complicated underground NLOS scenario using calibration, VBUKF, and WCA[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 8501013.
- [6] CAO B, JIANG C X, FAN S M, et al. Improving the localization accuracy and robustness of a UWB system using VB-CSRUKF and RTS in harsh underground NLOS environments[J]. IEEE Internet of Things Journal, 2024, 11(12): 22790-22802.
- [7] 贾宇涛, 李冠华, 潘红光, 等. 基于UWB与PDR的井下人员融合定位方法[J]. 工矿自动化, 2024, 50(6): 96-102, 135.
JIA Y T, LI G H, PAN H G, et al. A fusion positioning method for underground personnel based on UWB and PDR[J]. Journal of Mine Automation, 2024, 50(6): 96-102, 135.
- [8] ZHAO K, ZHU M H, XIAO B, et al. Joint RFID and UWB technologies in intelligent warehousing management system[J]. IEEE Internet of Things Journal, 2020, 7(12): 11640-11655.
- [9] 刘斌, 陈刚, 袁浩, 等. 基于UWB的危化品智能仓储管理系统研究[J]. 工业安全与环保, 2022, 48(10): 32-36, 41.
LIU B, CHEN G, YUAN H, et al. Research on intelligent warehouse management system of hazardous chemicals based on UWB technology[J]. Industrial Safety and Environmental Protection, 2022, 48(10): 32-36, 41.
- [10] FENG T, YU Y, WU L, et al. A human-tracking robot using ultra wideband technology[J]. IEEE Access, 2018, 6: 42541-42550.
- [11] CHEOK K C, RADOVNIKOVICH M, VEMPATY P, et al. UWB tracking of mobile robots[C]//Proceedings of the 21st Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications. Piscataway: IEEE Press, 2010: 2615-2620.
- [12] WANG Y, WU S H, LEI C J, et al. A review on wireless networked control system: the communication perspective[J]. IEEE Internet of Things Journal, 2024, 11(5): 7499-7524.
- [13] RUZAIJ AL-OKBY M F, RODDELKOPF T, BURGDORF S J, et al. Multi-tag UWB-based indoor positioning system for objects tracking[C]//Proceedings of the 2024 IEEE 22nd Jubilee International Symposium on Intelligent Systems and Informatics (SISY). Piscataway: IEEE Press, 2024: 415-422.
- [14] NKROW R E, SILVA B, BOSHOFF D, et al. NLOS identification and mitigation for time-based indoor localization systems: survey and future research directions[J]. ACM Computing Surveys, 2024, 56(12): 1-41.
- [15] SU C, ZHANG F S, JIN B H, et al. UWBLoc: NLoS mitigation for practical UWB localization[C]//Proceedings of the 2023 IEEE Smart World Congress (SWC). Piscataway: IEEE Press, 2024: 1-8.
- [16] 程雪聪, 杨俊雅, 张益鹏. UWB非视距误差抑制算法研究[J]. 科技与创新, 2024(12): 1-6.
CHENG X C, YANG J Y, ZHANG Y P. Research on UWB NLOS error suppression algorithm[J]. Science and Technology & Innovation, 2024(12): 1-6.
- [17] SMAOUI N, HEYDARIAAN M, GNAWAIL O. Single-antenna AoA estimation with UWB radios[C]//Proceedings of the 2021 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2021: 1-7.
- [18] ZHANG Y W, BROWN A K, MALIK W Q, et al. High resolution 3-D angle of arrival determination for indoor UWB multipath propagation[J]. IEEE Transactions on Wireless Communications, 2008, 7(8): 3047-3055.
- [19] ZENG W M, ZHANG J L, ZHANG T T. A robust machine learning based UWB AOA estimation method[C]//Proceedings of the 2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring). Piscataway: IEEE Press, 2024: 1-5.
- [20] MUQAIBEL A H, ALAWSH S A, BINMAKHASHEN G M. Under-sampled UWB NLOS/LOS channel classification using machine learning[J]. Arabian Journal for Science and Engineering, 2025, 50(8): 6095-6108.
- [21] HUANG C, MOLISCH A F, HE R S, et al. Machine learning-enabled LOS/NLOS identification for MIMO systems in dynamic environments[J]. IEEE Transactions on Wireless Communications, 2020, 19(6): 3643-3657.
- [22] POULOSE A, HAN D S. UWB indoor localization using deep learning LSTM networks[J]. Applied Sciences, 2020, 10(18): 6290.
- [23] NASERI M, SHAHID A, GORDEBEKE G J, et al. Machine learning-based angle of arrival estimation for ultra-wide band radios[J]. IEEE Communications Letters, 2022, 26(6): 1273-1277.
- [24] LEDERGERBER A, HAMER M, D'ANDREA R. Angle of arrival

estimation based on channel impulse response measurements[C]// Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway: IEEE Press, 2020: 6686-6692.

- [25] WANG T Y, MAN Y L, SHEN Y. A deep learning based AoA estimation method in NLOS environments[C]//Proceedings of the 2021 IEEE Globecom Workshops (GC Wkshps). Piscataway: IEEE Press, 2022: 1-6.
- [26] MARGIANI T, CORTESI S, KELLER M, et al. Angle of arrival and centimeter distance estimation on a smart UWB sensor node[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 9508110.
- [27] YANG H C, WANG Y J, SEOW C, et al. UWB NLOS identification and mitigation based on bidirectional encoder representations from transformer (BERT) deep learning[C]//Proceedings of the 2024 14th International Conference on Indoor Positioning and Indoor Navigation (IPIN). Piscataway: IEEE Press, 2024: 1-6.
- [28] TOMOVIĆ S, BREGAR K, JAVORNIK T, et al. Transformer-based NLoS detection in UWB localization systems[C]//Proceedings of the 2022 30th Telecommunications Forum (TELFOR). Piscataway: IEEE Press, 2022: 1-4.
- [29] CERRO G, FERRIGNO L, LARACCA M, et al. UWB-based indoor localization: how to optimally design the operating setup?[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 9509012.
- [30] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017). New York: Curran Associates, 2017: 6000-6010.
- [31] DOTLIC I, CONNELL A, MA H, et al. Angle of arrival estimation using decawave DW1000 integrated circuits[C]//Proceedings of the 2017 14th Workshop on Positioning, Navigation and Communications (WPNC). Piscataway: IEEE Press, 2017: 1-6.
- [32] WANG H C, WANG X X, XUE Y, et al. UWB-based indoor localization using a hybrid WKNN-LSTM algorithm[C]//Proceedings of the 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Piscataway: IEEE Press, 2020: 1720-1725.
- [33] WANG Z G, YAN W Z, OATES T. Time series classification from scratch with deep neural networks: a strong baseline[C]//Proceedings of the 2017 International Joint Conference on Neural Networks (IJCNN). Piscataway: IEEE Press, 2017: 1578-1585.

[作者简介]



曾文敏(2001-),女,哈尔滨工业大学(深圳)硕士生,主要研究方向为超宽带定位。



郑柏烽(2003-),男,哈尔滨工业大学(深圳)在读,主要研究方向为超宽带定位、多传感器融合定位。



刘晋廷(1999-),男,香港科技大学(广州)硕士生,主要研究方向为无线传感器网络。



鲍亚川(1985-),男,博士,中国电子科技集团公司第五十四研究所研究员,主要研究方向为卫星导航、室内地下导航。



尹继凯(1972-),男,硕士,中国电子科技集团公司第五十四研究所研究员,主要研究方向为卫星导航。



李建佳(1997-),男,中国电子科技集团公司第五十四研究所综合时空网络与装备技术全国重点实验室博士生,研究方向为阵列式高精度测角定位技术。



张霆廷(1980-),男,哈尔滨工业大学(深圳)教授、博士生导师,信息科学与技术学院院长,主要研究方向为无线定位理论、脉冲超宽带技术、通信感知一体化、车联网。