

基于层级交叉注意力网络的无人机被动感知方法

白静¹, 肖竹², 何佳成¹, 张卓¹

(1. 西安电子科技大学人工智能学院, 陕西 西安 710126; 2. 湖南大学信息科学与工程学院, 湖南 长沙 410082)

摘要: 针对数字地面多媒体广播 (DTMB) 外辐射源感知无人机 (UAV) 中弱回波淹没及多径干扰问题, 提出一种基于层级交叉注意力网络 (HCANet) 的无人机被动感知方法。该方法构建时域多尺度卷积与频域幅相联合编码的双分支结构, 分别捕捉目标时序依赖与微多普勒细节; 引入层级交叉注意力模块, 在特征空间对异构时频信息进行自适应对齐与融合。实验结果表明, 该方法在 $-10\sim 10$ dB 信噪比范围内保持鲁棒性, 当信噪比为 10 dB 时, 加性白高斯噪声、莱斯及瑞利信道检测准确率分别达 95.75%、99.50% 和 71.25%, 城市复杂环境实测准确率达 99.65%, 验证了该方法在低信噪比与强散射场景下的有效性。

关键词: 无人机被动感知; DTMB 外辐射源; 层级交叉注意力; 弱目标检测; 时频特征融合

中图分类号: TN929.5

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026039

UAV passive sensing method based on hierarchical cross-attention network

Bai Jing¹, Xiao Zhu², He Jiacheng¹, Zhang Zhuo¹

1. School of Artificial Intelligence, Xidian University, Xi'an 710126, China

2. College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China

Abstract: To address weak echo submersion and multipath interference in digital terrestrial multimedia broadcast (DTMB) external illuminator, a UAV passive sensing method based on hierarchical cross-attention network (HCANet) was proposed. A dual-branch architecture was constructed to extract temporal dependencies via time-domain multi-scale convolution and micro-Doppler features via frequency-domain amplitude-phase joint encoding. Hierarchical cross-attention modules were utilized to adaptively align and fuse time-frequency features in the feature space. Experimental results show that the method maintains robustness within -10 to 10 dB signal-to-noise ratios. The detection accuracy under 10 dB additive white Gaussian noise, Rician, and Rayleigh channels reaches 95.75%, 99.50%, and 71.25%, respectively, and the accuracy of measured data in complex urban environments reaches 99.65%. These results validate the effectiveness in low signal-to-noise ratio and strong-scattering environments.

Keywords: UAV passive sensing, DTMB external illuminator, hierarchical cross-attention, weak target detection, time-frequency feature fusion

0 引言

近年来, 无人机在物流运输、应急救援及基础设施巡检等领域广泛应用, 有力推动了低空经济的

蓬勃发展^[1], 但随之而来的“黑飞”入侵、航线干扰及非法航拍等安全隐患日益严峻^[2], 需要有效的无人机检测方法保障空域安全。现有无人机监测技

收稿日期: 2025-11-30; 修回日期: 2026-02-01

通信作者: 肖竹, zhxiao@hnu.edu.cn

基金项目: 国家自然科学基金资助项目(No.62276206)

Foundation Item: The National Natural Science Foundation of China (No.62276206)

术主要分为被动与主动两类。其中,声学、光学及无线电侦测等被动手段受限于噪声、气象或目标通信状态,难以实现全天候的有效检测覆盖^[3]。有源雷达作为主动探测手段,探测精度高,但长期占用频谱资源且存在电磁干扰风险,一定程度上限制了其在复杂环境下的部署^[3]。相比之下,基于机会辐射源的被动式雷达利用第三方信号进行探测,不需要专用频谱且隐蔽性好^[3]。然而,此类技术传统上依赖于相干积累处理回波,在面对无人机目标时,由于旋翼多普勒效应弱且特征复杂,检测效能受限^[4]。针对这一问题,本文尝试从数据驱动的角度切入,旨在解决传统相干积累方法的局限,通过深度特征挖掘实现对无人机目标的高效检测。

外辐射源无人机被动感知系统架构如图 1 所示。在实际探测中,接收机在获取微弱的目标散射回波时,会受到强直达波与多径杂波的干扰。这种非协作探测环境导致回波信噪比低,使现有的外辐射源被动检测技术面临以下两大挑战。

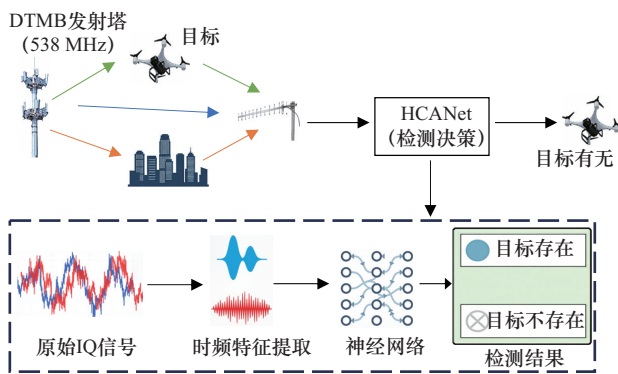


图1 外辐射源无人机被动感知系统架构

首先,低信噪比下有效目标回波的特征提取面临挑战。由于无人机雷达散射截面小,回波功率远低于直达波与背景环境噪声。在缺乏纯净参考信号辅助干扰对消的情况下,微弱的目标时域信号与干扰信号耦合,导致传统能量检测与匹配滤波算法有效性受限^[5]。近年来,已有学者尝试利用深度学习提取特征进行分类^[6],或利用循环神经网络进行杂波抑制,但这些方法大多依赖于较高的信噪比或特定的先验假设,难以适应此类微弱信号实际的盲测场景。

其次,多径环境存在目标多普勒特征模糊的问题。无人机旋翼叶片的透波性强且反射面积有限,所产生的微多普勒效应在频谱上表现的能量发散且

幅度低。加之多径效应会引发频谱弥散,使接收信号中的目标频域特征易受畸变与混叠影响。通用的基础网络架构难以在特征空间中有效解耦目标微动与环境多径,导致目标在特征空间的显著性不足,进而限制了其在非平稳信道下的检测鲁棒性与泛化能力^[7-10]。

针对上述难点,本文面向数字地面多媒体广播(digital terrestrial multimedia broadcast, DTMB)作为外辐射源的探测场景,提出了一种基于层级交叉注意力网络(hierarchical cross-attention network, HCANet)的无人机被动感知方法。该方法基于数据驱动的微弱特征挖掘机理,其核心逻辑在于将直达波与回波的区别问题转化为复杂背景下的非线性特征提取问题。不同于传统相干抵消技术,数据驱动方式通过大规模样本学习,建立了强直达波背景与携带微多普勒调制的回波在特征空间中的映射关系,从而在单通道观测下实现两者的分离,通过结合时域结构与频域信息提升特征提取能力。时域分支利用层级多尺度卷积扩展感受野,以捕捉目标引起的信号瞬态变化及其与直达波稳态背景分布的差异;频域分支则基于幅度谱与相位谱输入提取频域特征,旨在从强直达波频谱中剥离出由无人机旋翼引起的非平稳微多普勒特征。在此基础上,引入层级交叉注意力模块,用于跨域对齐与重加权,利用直达波在时频域表现的平稳特征,而目标回波则呈现出跨域耦合的非平稳调制特性。通过计算时频特征的交互权重,网络能够自适应地聚焦于携带目标信息的特征分量,从而在不参考信号的情况下准确区分强直达波背景与微弱目标信号,以期提升模型在非平稳信道与低信噪比环境下的检测性能。本文的主要工作包括以下 3 个方面。

1) 采用数据驱动的单通道检测策略。针对传统被动雷达依赖相干积累与参考通道导致检测灵敏度受限的问题,本文采用深度学习挖掘信号特征。在不需要先验发射波形信息与独立参考通道的情况下,利用数据驱动方式实现了对微弱无人机回波的有效检测,规避了传统信号处理对信号纯净度的高要求。

2) 设计基于层级交叉的注意力网络。针对弱目标特征提取难的问题,构建了时域多尺度卷积与频域特征层级化通道分流的双分支结构,分别捕捉信号的长短时序依赖与微多普勒精细特征;引入层

级交叉注意力模块,在特征空间对时频异构信息进行加权与深度融合,通过增强微弱目标在特征空间的显著性,从而在非平稳信道下实现了检测鲁棒性的显著提升。

3) 分别构建全数字仿真数据集与实测场景数据集。基于DTMB标准协议生成了覆盖加性白高斯噪声、莱斯及瑞利3种典型衰落信道的仿真数据,同时搭建了基于通用软件无线电外设(universal software radio peripheral, USRP)的信号采集平台,获取了城市复杂电磁环境下的真实目标回波数据。通过在两类数据集上分别进行独立验证,结果表明,所提方法在理论信道与真实场景下均具备优异的检测性能。

1 问题建模

本文考虑的是基于DTMB外辐射源的单通道被动感知场景。在该场景下,接收机在缺乏独立参考通道及先验发射波形信息的情况下工作,其截获的监视信号是直达波泄漏、动态多径杂波、目标散射回波及加性噪声的线性叠加连续时间下的基带接收信号 $r(t)$,可建模为

$$r(t) = s_d(t) + \sum_{k=1}^K \alpha_k s(t - \tau_k) + \sum_{m=1}^M \beta_m s(t - \tau_m) e^{j2\pi f_{D,m} t} + n(t) \quad (1)$$

其中, $s(t)$ 为DTMB发射基带信号, $s_d(t)$ 表示由天线旁瓣泄漏或近场耦合形成的等效直达波分量, α_k 和 τ_k 分别为第 k 条环境多径的复幅度和时延, K 为多径条数, β_m 和 τ_m 为第 m 个无人机目标回波的复幅度和时延, β_m 与目标雷达散射截面积及姿态等特征密切相关, M 为目标数量, $f_{D,m}$ 为第 m 个目标的多普勒频移, $n(t)$ 为加性白高斯噪声,方差为 σ_n^2 。对于第 m 个目标而言,其时延 τ_m 由双基地几何关系给出。

$$\tau_m = \frac{R_{T,m} + R_{R,m}}{c} \quad (2)$$

其中, $R_{T,m}$ 、 $R_{R,m}$ 分别为目标到发射塔、接收端的距离, c 为光速。对应的多普勒频移为

$$f_{D,m} = \frac{v_{r,m}}{\lambda} = \frac{v_{r,m} f_c}{c} \quad (3)$$

其中, $v_{r,m}$ 为目标相对于等效双基地路径的径向速度, f_c 为DTMB信号载频, λ 为载波波长。

对于旋翼无人机,旋翼叶片的周期性运动会会在目标回波上叠加显著的微多普勒调制。在简化情形下,可将该效应建模为对基带回波的相位调制。

$$s_{md}(t) = s(t - \tau_m) \exp[jA_{md} \sin(2\pi f_{rot} t)] \quad (4)$$

其中, A_{md} 为微多普勒调制幅度, f_{rot} 与旋翼转速相关。该调制在频域上表现为围绕主多普勒频移的谱线展宽与旁瓣结构,即便在较低信噪比条件下仍具有一定的周期稳定性,是区分无人机目标与鸟群、气球等其他小目标的重要物理特征。

在密集城区、山地或强遮挡的非视距(non-line-of-sight, NLOS)环境中,发射信号经多次散射、反射与绕射后抵达接收端,直射路径通常被完全阻断,接收信号可视为大量独立多径分量的矢量叠加,其幅度包络近似服从瑞利分布,其概率密度函数为

$$p_R(r) = \frac{r}{\sigma^2} \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (5)$$

其中, σ^2 为多径分量功率的方差。瑞利信道对应显著的小尺度衰落与相位随机性,传播损耗较大、有效信噪比较低,弱目标回波极易被抬升的杂波底噪和多径扩展淹没,是验证被动感知系统鲁棒性的典型不利场景。

在郊区、开阔地带等存在稳定直射路径的视距(line-of-sight, LOS)环境中,接收信号除包含随机散射分量外,还包含能量占优的直达波成分,其幅度服从莱斯分布

$$p_R(r) = \frac{r}{\sigma^2} \exp\left(-\frac{r^2 + A^2}{2\sigma^2}\right) I_0\left(\frac{Ar}{\sigma^2}\right) \quad (6)$$

其中, A 为直射分量幅度, σ^2 为散射分量功率的方差, $I_0(\cdot)$ 为零阶修正贝塞尔函数。莱斯因子 $K = \frac{A^2}{2\sigma^2}$ 表示直射与散射分量的功率比,当 K 增大时,信道逐渐逼近加性白高斯噪声(additive white gaussian noise, AWGN)信道,小尺度衰落减弱,有利于提高目标检测的理论上限性能。

基于上述信号模型与复杂信道特性,本文将无人机目标检测任务转化为数据驱动的监督学习问题。构建深度神经网络映射函数 $F(\bar{x}_i; \theta)$,其中 θ 为网络的可学习参数集。网络训练的目标是寻找最优参数 θ^* ,使预测概率与真实标签之间的加权交叉熵损失 \mathcal{L} 最小化。

$$\theta^* = \arg \min_{\theta} E_{(x,y) \sim \mathbf{D}} \mathcal{L}(F(\tilde{x}; \theta), y) \quad (7)$$

其中, \mathbf{D} 表示训练样本与标签的联合分布 (或数据集), $\mathcal{L}(\cdot)$ 为加权交叉熵损失函数, $F(\cdot)$ 表示深度神经网络的非线性映射函数。通过优化该目标函数, 深度神经网络有助于自适应挖掘数据中的高维判别性特征, 进而支持在复杂信道环境下实现对无人机目标的鲁棒检测。

2 无人机被动感知方法

针对单通道 DTMB 外辐射源感知面临的弱回波与非平稳多径干扰挑战, 本文提出基于层级交叉注意力网络的无人机被动感知方法。该方法构建时-频双流互补机制: 时域分支利用层级化多尺度卷积捕捉多维时序依赖, 频域分支通过幅相联合编码解析精细的微多普勒特征。在此基础上, 引入层级交叉注意力模块, 在多个特征尺度上实现异构信息的自适应对齐与加权融合, 动态抑制多径冗余并增强目标响应。HCANet 架构如图 2 所示。

2.1 输入与预处理

单通道接收端采集到的监视信号为复基带序列 $s(t)$, 经采样后可写为

$$s[n] = s_I[n] + js_Q[n] \quad (8)$$

其中, $s_I[n]$ 与 $s_Q[n]$ 分别为同相与正交分量。为了在实值卷积网络框架下保留复信号的物理含义, 本文将实部与虚部分别作为两个通道进行堆叠, 构造输入矩阵

$$\mathbf{x} = \begin{bmatrix} s_I[0] & \cdots & s_I[L-1] \\ s_Q[0] & \cdots & s_Q[L-1] \end{bmatrix} \quad (9)$$

其中, L 为单帧采样点数。这种表示在结构上完整保留了幅度与相位信息, 使网络能够在实值域内同时学习与能量分布和相位演化相关的特征, 为后续时域与频域联合建模提供统一入口。

不同样本之间在传播损耗、目标散射强度和噪声水平等方面存在显著差异, 若直接将 \mathbf{x} 输入网络, 容易导致训练过程中统计分布不稳定。为减弱这种不一致性, 本文对每个通道独立执行零均值、单位方差标准化。

$$\tilde{x}_{c,n} = \frac{x_{c,n} - \mu_c}{\sigma_c + \varepsilon} \quad (10)$$

其中, μ_c 和 σ_c 分别为第 c 个通道在时间维上的均值和标准差, ε 为防止除零的微小常数。经该预处理后, 每帧样本的维度固定为 $(2, L)$, 输入的统计特性在不同信噪比 (signal-to-noise ratio, SNR) 与不同信道条件下更加稳定, 有利于后续多层卷积和注意力模块的收敛与泛化。




图 2 HCANet 架构

2.2 时域多尺度特征提取

在单通道 DTMB 外辐射源被动感知场景中, 无人机目标回波在时间轴上常表现为幅度较弱但具有一定连续性的结构变化, 其特征既包括符号级的短时突变, 也包括跨多个符号周期的包络波动和长程相关模式。简单的单尺度卷积难以覆盖如此宽泛的时间尺度, 而单纯依赖循环网络在低信噪比和长序列条件下学习效率较低。基于此, HCANet 在时域分支中采用多尺度多分支并行结构 (Inception) 式卷积块^[11-12]构成的层级结构, 对输入信号的局部和全局时序特征进行多尺度提取。

设第 i 个时域层级的输入特征为 $\mathbf{H}_{\text{time}}^{(i)} \in \mathbf{R}^{C_i^{(i)} \times T^{(i)}}$, 该层通过若干具有不同卷积核长度 k_j 的并行分支提取多尺度特征。

$$\mathbf{Z}_j^{(i)} = \text{ReLU}(\text{BN}(\text{Conv1D}(\mathbf{H}_{\text{time}}^{(i)}; \mathbf{W}_j^{(i)}))) \quad (11)$$

其中, $\mathbf{W}_j^{(i)}$ 为第 j 个分支的卷积核, 卷积核长度 k_j 的选取依据于 DTMB 信号的物理时域特性。具体而言, 小尺度卷积核 (如 $k=3$) 对应于微秒级的短时间窗, 旨在捕捉信号中符号级的快速相位跳变与高频瞬态细节; 大尺度卷积核 (如 $k=7$ 及以上) 则覆盖更长的观测窗口, 旨在提取由无人机旋翼微动引起的跨符号周期包络波动及长程相关结构。经实验中的参数敏感性分析验证, 采用这种小、中、大尺度并行的奇数核组合, 能够在保持相位对称性的同时, 最大化不同频率特征的解耦能力。在得到各分支输出后, 将其在通道维拼接, 并通过 1×1 卷积完成通道压缩与重整。

$$\tilde{\mathbf{H}}_{\text{time}}^{(i)} = \text{Conv1D}(\mathbf{Z}_j^{(i)}; \mathbf{W}_{\text{proj}}^{(i)}) \quad (12)$$

其中, $\mathbf{W}_{\text{proj}}^{(i)}$ 为核长为 1 的投影卷积核。这种设计使网络在同一层级中实现了多分辨率感知, 较小的卷积核有利于捕捉符号级瞬间波动和短周期调制模式, 较大的卷积核则更擅长表示缓慢包络和长程依赖结构, 从而有效解决了弱目标回波在单一时间尺度下特征不显著的问题。

为在保证判别力的同时控制计算复杂度, 时域分支在各层后通过带步长卷积与自适应池化对时间长度进行压缩, 将特征长度从 $T^{(1)} = 4096$ 逐步减小到 $T^{(3)} = 1024$ 。这种由细到粗的层级建模方式, 使高层特征能够聚合更大时间范围内与目标相关的证据, 对局部随机噪声形成平滑与抑制, 为后续时频融合提供更加稳健的时域表示。

2.3 频域幅相联合特征建模

在复杂电磁环境中, 多径传播和旋翼运动在频域上表现为不同的结构特征: 多径传播会导致频谱扩展和能量重分布, 旋翼运动引起的微多普勒效应则在目标多普勒附近产生周期性的谱线扰动。如果只在时域建模, 难以区分这两类效应; 若只观察功率谱, 又可能忽略对相位结构敏感的细节信息。为有效利用频域信息, 基于幅度谱与相位谱输入的频域特征提取分支, 对时域信号进行显式频域分析。

对预处理后的输入 $\tilde{\mathbf{x}}$ 沿时间维执行快速傅里叶变换 (fast Fourier transform, FFT), 得到复数频谱。

$$\mathbf{F} = \mathbf{F}\{\tilde{\mathbf{x}}\} = \mathbf{A}e^{j\Phi} \quad (13)$$

其中, \mathbf{A} 为幅度谱, Φ 为相位谱。为了同时感知能量分布与相位结构, 将二者在通道维上拼接, 构造基于幅度谱与相位谱的初始频域特征输入。

$$\mathbf{Z}_{\text{freq}}^{(0)} = [\mathbf{A} \parallel \Phi] \in \mathbf{R}^{C_f^{(0)} \times T_f} \quad (14)$$

其中, $C_f^{(0)} = 4$, 对应两路同相正交 (in-phase and quadrature, IQ) 的幅度与相位, T_f 为有效频点数。相位信息对多径路径差和微多普勒引起的轻微频偏具有区分能力, 与幅度谱结合后, 有助于在特征空间中区分目标散射与其他干扰因素。在获得上述幅相特征输入后, 频域分支通过多层小尺度卷积和非线性变换进行高阶特征提取。

$$\mathbf{Z}_{\text{freq}}^{(l)} = \text{GeLU}(\text{BN}(\text{Conv1D}(\mathbf{Z}_{\text{freq}}^{(l-1)}; \mathbf{W}_{\text{freq}}^{(l)}))) \quad (15)$$

其中, 卷积核长度取 3, 便于在较小频率邻域内表示谱线宽度、旁瓣背景和局部不连续等细节。多层卷积的堆叠在频域上形成逐渐扩大的“频域感受野”, 从而在幅相特征空间内获得对目标散射与杂波差异更具判别力的特征。

2.4 层级交叉注意力融合

仅依赖时域或频域特征难以在各种传播环境下保持稳定的检测性能, 时域信息容易在强直达波或强多径条件下被掩盖, 频域结构可能在某些场景中受到严重畸变而失真。为此, 受到注意力机制在序列建模及特征增强中成功应用的启发^[13-18], HCANet 在 3 个阶段引入层级交叉注意力融合模块。该设计立足于特征表示学习视角, 旨在利用信号在物理维度的跨域相关性提供判决增益。尽管时域信号与其频域投影在数学上具有线性等价性, 但在受限于局部感受野的深度特征空间中, 单一维度的表

示难以同时显式表征瞬态跳变与精细多普勒结构。层级交叉注意力融合模块通过挖掘时-频特征的耦合关系，利用目标回波在两域中的同步相干特性作为约束准则，以区分在时频双域表现出非相干特征的随机噪声与多径干扰。

设第 i 个尺度的时域特征为 $\mathbf{H}_{\text{time}}^{(i)}$ ，对应的频域特征为 $\mathbf{Z}_{\text{freq}}^{(i)}$ 。首先，通过 1×1 卷积将时域通道对齐到与频域一致。

$$\tilde{\mathbf{H}}_{\text{time}}^{(i)} = \text{Conv1D}(\mathbf{H}_{\text{time}}^{(i)}, \mathbf{W}_{\text{align}}^{(i)}) \quad (16)$$

此处选用 1×1 卷积核的物理逻辑在于：它仅在通道维度进行线性组合与重组，而不改变时间维度的感受野。这确保了特征对齐过程不会破坏时域信号原有的瞬态结构和相位连续性。通过自适应池化保证时域、频域两支特征在时间维度上具有相同长度。然后，将对齐后的时域特征与频域特征在通道维度拼接，得到融合输入。

$$\mathbf{U}^{(i)} = [\tilde{\mathbf{H}}_{\text{time}}^{(i)} \parallel \mathbf{Z}_{\text{freq}}^{(i)}] \quad (17)$$

交叉注意力模块对 $\mathbf{U}^{(i)}$ 进行非线性变换，旨在评估当前时刻各域信息的物理置信度。该过程本质上是在特征层面建立了一种时频特征重校准机制：利用两层卷积捕捉跨域特征间的非线性依赖关系，计算时域、频域分量的互信息。由于无人机回波引起的时域包络波动与频域谱线展宽在时间轴上高度同步，而平稳直达波或随机多径噪声不具备这种跨域耦合特征，计算得到的时/频双路权重矩阵 $\mathbf{A}^{(i)}$ 可表示为

$$\mathbf{V}^{(i)} = \text{GeLU}(\text{Conv1D}(\mathbf{U}^{(i)}, \mathbf{W}_1^{(i)})) \quad (18)$$

$$\mathbf{A}^{(i)} = \text{Softmax}_c(\text{Conv1D}(\mathbf{V}^{(i)}, \mathbf{W}_2^{(i)})) \quad (19)$$

其中， Softmax_c 在“时/频”两个通道维度上进行归一化，将权重矩阵 $\mathbf{A}^{(i)}$ 沿通道维度拆解为时域注意力向量 $\alpha_{\text{time}}^{(i)}$ 与频域注意力向量 $\alpha_{\text{freq}}^{(i)}$ 。最终，融合特征 $\mathbf{F}^{(i)}$ 可表示为

$$\mathbf{F}^{(i)} = \alpha_{\text{time}}^{(i)} \odot \tilde{\mathbf{H}}_{\text{time}}^{(i)} + \alpha_{\text{freq}}^{(i)} \odot \mathbf{Z}_{\text{freq}}^{(i)} \quad (20)$$

其中， \odot 表示按时间位置逐点加权。这一加权过程的物理含义在于动态分配“注意力资源”， Softmax 的归一化特性使网络自适应分配时域和频域的权重占比，使其泛化能力增强。

通过上述交叉注意力机制，HCANet 能够在每个时间位置上根据局部时-频证据自动调整对两条通路的依赖程度。当时域特征受强多径或噪声污染严重而频域仍能清晰表征微多普勒结构时，网络倾

向于提高频域权重；当频谱在特定场景中受到强干扰而畸变明显时，则更多依赖时域分支。多尺度的层级嵌入使这种软选择能力在不同时间-频率分辨率下反复发挥作用，从而在多种统计信道环境中展现出良好的鲁棒性和泛化性。

2.5 层级过渡与全局判决头

在完成 3 个尺度的时-频交叉融合后，HCANet 需要将高维时序特征压缩为紧致的全局表示，以便进行最终的目标存在判决。为此，网络在高层特征空间中引入层级过渡模块，通过卷积和池化组合结构实现特征压缩与信息聚合。对第 i 个融合尺度输出 $\mathbf{F}^{(i)}$ ，过渡模块可表示为

$$\mathbf{G}^{(i+1)} = \text{AdaptiveAvgPool1D} \left(\text{ReLU} \left(\text{BN} \left(\text{Conv1D} \left(\mathbf{F}^{(i)}, \mathbf{W}_{\text{trans}}^{(i)} \right) \right) \right) \right) \quad (21)$$

其中， $\mathbf{W}_{\text{trans}}^{(i)}$ 采用带步长的卷积核以逐步降低时间分辨率，并通过自适应池化保留能量更集中的区域，冗余背景和局部噪声在这一过程中得到进一步抑制。经过若干级过渡后，得到高层融合特征 $\mathbf{G}^{(\text{final})}$ ，其时间维度已大幅压缩，更适合作为全局语义判决的输入。

在决策阶段，网络采用全局平均池化（global average pooling, GAP）对 $\mathbf{G}^{(\text{final})}$ 在时间维进行聚合，得到通道级全局表示向量 \mathbf{z} 。

$$\mathbf{z} = \text{GAP}(\mathbf{G}^{(\text{final})}) \quad (22)$$

随后通过一层带随机失活（Dropout）的全连接层和 Softmax 分类器输出目标存在概率。

$$\hat{p}(y = 1|x) = \text{Softmax}(\mathbf{W}_{\text{cls}} \mathbf{z} + \mathbf{b}_{\text{cls}}) \quad (23)$$

其中， \mathbf{W}_{cls} 和 \mathbf{b}_{cls} 分别为全连接分类层的权重矩阵和偏置向量。Dropout 和 L2 正则化有效缓解了高维特征带来的过拟合风险，使模型在不同测试场景下仍能保持稳定的决策边界。

2.6 训练优化策略与算法流程

为确保 HCANet 在多变信道与低信噪比环境下的泛化性能，本文构建了一套包含类别平衡、动态优化及正则增强的训练框架。首先，针对正负样本分布不均的问题，采用加权交叉熵损失提升“目标存在”类别的梯度贡献，确保模型在弱信号条件下的召回率。其次，选用 AdamW 优化器配合余弦退火调度，利用解耦权重衰减与动态学习率调整，有效抑制参数振荡，实现模型在复杂解空间中的高效收敛。此外，在输入侧引入随机时移与噪声注入的

数据增强策略,并结合Dropout与L2正则化控制模型复杂度。上述策略在离线阶段有效提升了模型对时序起点及环境噪声的鲁棒性,且不增加在线推理开销。

为便于整体把握HCANet的处理流程,本文提出基于层级交叉注意力网络的无人机被动感知方法的伪代码如算法1所示。

算法1 基于层级交叉注意力网络的无人机被动感知方法

输入 单通道DTMB外辐射源监视信号样本集合 $\{\mathbf{x}_i, \mathbf{y}_i\}_{i=1}^N$, 样本总数 N , 批大小 B , 最大训练轮数 E , 学习率 η , 损失函数 \mathcal{L}

输出 训练收敛后的最优网络参数集 θ^*

- 1) for $e = 1$ to E do
- 2) for $b = 1$ to $\frac{N}{B}$ do
- 3) for $i = 1$ to B do
- 4) 令 $\tilde{\mathbf{x}}_i = \text{Norm}(\text{IQ}(\mathbf{x}_i))$, 并提取多尺度特征 $\tilde{\mathbf{H}}_{\text{time}}^{(i)}, \mathbf{Z}_{\text{freq}}^{(i)}$
- 5) for $j = 1$ to 3 do
- 6) 取 $(\alpha_{\text{time}}^{(i)}, \alpha_{\text{freq}}^{(i)}) = \text{Att}(\tilde{\mathbf{H}}_{\text{time}}^{(i)}, \mathbf{Z}_{\text{freq}}^{(i)})$, 融合 $\mathbf{F}^{(i)} = \alpha_{\text{time}}^{(i)} \odot \tilde{\mathbf{H}}_{\text{time}}^{(i)} + \alpha_{\text{freq}}^{(i)} \odot \mathbf{Z}_{\text{freq}}^{(i)}$
- 7) end for
- 8) end for
- 9) 计算损失 \mathcal{L} 并更新参数 θ
- 10) end for
- 11) 更新学习率 η
- 12) end for
- 13) return $\theta^* = \theta$

通过上述设计,HCANet将信号物理建模、时域多尺度卷积、基于幅相信息的频域特征提取以及层级交叉注意力有效整合,在不依赖参考通道的前提下有助于实现对弱目标回波的增强和对复杂多径干扰的抑制,为后续实验部分展示的检测性能提供了技术支持。

3 仿真分析

本节针对DTMB外辐射源微弱无人机目标检测任务,对本文方法进行系统性性能评估。首先,在AWGN、莱斯及瑞利3种典型仿真信道下开展,并进一步引入基于538 MHz中心频点DTMB信号(PN945帧头)的实测数据,以验证模型在真实复

杂电磁环境下的泛化性能;其次,在上述两种数据场景下,本文将HCANet与多种主流深度神经网络基准进行了对比分析;最后,从参数规模、计算复杂度及推理效率等维度进行轻量化性能评估,验证了本文方法在边缘计算场景下的工程部署潜力。

3.1 实验数据集及环境配置

本文采用全数字仿真与实测数据相结合的双重验证策略,旨在全方位评估模型在理论极限与真实复杂电磁环境下的泛化能力。首先,在仿真数据构建方面,严格参照DTMB标准物理层协议生成信号。体制采用PN945帧头模式,采样率设定为7.56 MHz,确保信号带宽与时域结构与实际系统一致。无人机目标被建模为叠加在监视信号上的微弱散射分量,其径向速度在10~50 m/s均匀随机抽取,径向距离在500~1 000 m变化,目标散射强度幅度因子在0.05~0.15浮动。为覆盖多样化的传播条件,构建了3类典型信道场景:仅考虑AWGN信道,用于评估基准噪声环境下的检测鲁棒性;模拟含视距分量与一阶散射的莱斯信道(K 因子取10,路径时延 $[0,1] \mu\text{s}$);以及模拟非视距强多径环境的瑞利信道(路径时延 $[1,2.5] \mu\text{s}$,最大多普勒频移200 Hz)。信噪比范围设定为-10~10 dB,步长为2 dB,在每个等级下分别生成等量的“含目标”与“仅背景”样本。本文主要仿真实验参数如表1所示。

表1 仿真实验参数

仿真参数	参数值
DTMB 信号采样率/MHz	7.56
DTMB 中心频率/MHz	538
帧头模式	PN945
无人机径向距离范围/m	500~1 000
无人机径向速度范围/(m·s ⁻¹)	10~50

为进一步验证模型在真实场景下的有效性,搭建了基于USRP B210的单通道DTMB外辐射源信号采集平台,构建了实测数据测试集。实验选取中心频率为538 MHz的DTMB广播信号作为机会照射源,该信号采用PN945帧头模式。采集环境为典型的复杂城市环境,包含建筑物反射、地物杂波及动态干扰。为验证算法的泛化性,实验选取了DJI Matrice 350无人机作为非合作目标。在数据采集过

程中,控制无人机飞行高度在30~80 m,与接收机站点的地面水平距离保持在200~300 m内。其中,“正样本(有目标)”定义为无人机在预设探测空域内执行任务(涵盖水平飞行、垂直升降及定点悬停等状态)的特征时段;“负样本(背景)”则定义为没有无人机存在时的纯环境回波与时变杂波段。最终利用该环境配置,获取包含目标回波与背景杂波的实测IQ数据,经下变频与同步处理后用于模型测试。

在实验配置与数据划分方面,全部模型训练与验证均在配备NVIDIA RTX 3090 GPU的计算平台上完成,深度学习框架采用PyTorch2.2,并启用混合精度训练以优化计算效率。数据集按7:1:2的比例划分为训练集、验证集和测试集,确保各类信道(仿真/实测)与信噪比等级在各子集中分布均匀。所有网络输入均设定为8 192维实值序列(实部与虚部堆叠),这一维度的选取在物理上确保了模型具备足够的时频分辨率增益。该配置在保证能够精确解析无人机旋翼微多普勒谱线的同时,也为时频交叉网络提供了跨越多个物理调制周期的观测窗口。相比于单一维度的短序列分析,长序列输入使得交叉注意力机制能够提取到信号在长程演化中的时频耦合特征,从而在特征层面补偿了单通道感知中由于参考信号缺失带来的处理增益损失。

3.2 仿真平台验证结果

为系统评估HCANet在理论信道条件下的检测

性能边界,本节选取双向门控循环单元(bidirectional gated recurrent unit, BiGRU)^[19]、双向长短期记忆网络(bidirectional long short-term memory network, BiLSTM)^[8]、变长训练卷积神经网络(variable-length training convolutional neural network, VTCNN)^[20]和相位编码Transformer与卷积门控深层神经网络(phase-encoded Transformer and convolutional gated deep neural network, PET-CGDNN)^[21]4种代表性网络作为基准模型。其中, BiGRU与BiLSTM代表循环神经网络对时序依赖的建模能力, VTCNN代表卷积网络对局部波形的特征提取能力, PET-CGDNN则代表时频并行混合结构的性能水平。5种模型在完全一致的数据划分与训练配置下进行对比,评价指标采用分类准确率和F1分数。图3为各模型在不同信道条件下的性能变化曲线。

在AWGN信道下的鲁棒性评估如图3(a)和图3(d)所示。5种模型在中高信噪比区间均能实现有效检测,但HCANet在测试范围内保持着较大优势。以10 dB为例,HCANet的准确率与F1分数均接近96%,相较于BiGRU、BiLSTM提升6~8个百分点,较VTCNN、PET-CGDNN表现出1~2个百分点的优势。随着SNR降低至0 dB,HCANet的性能指标仅缓慢回落至80%左右,而基准模型已普遍降低至60%~70%。在-6 dB的极限条件下,HCANet展现出较为平缓的性能退化趋势。这一结

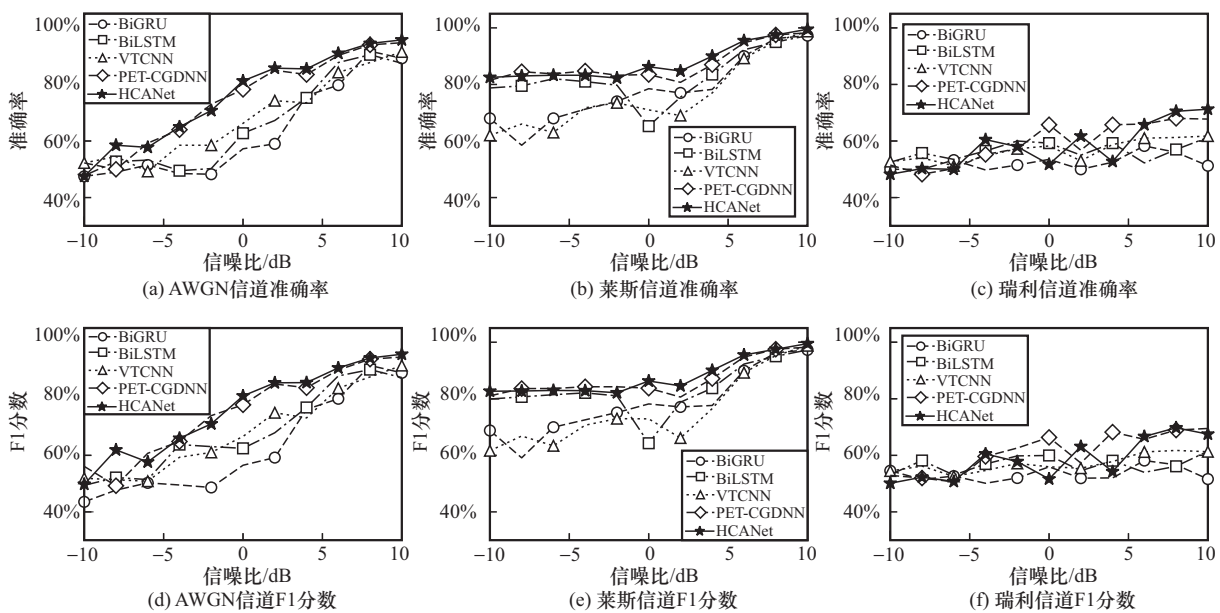


图3 各模型在不同信道条件下的性能变化曲线

果表明,单纯依赖门控循环或局部卷积的结构在噪声主导场景中可能导致特征鉴别力下降,而HCANet通过时域多尺度卷积与频域幅相联合编码构建的互补特征,在低信噪比下展现出较好的抗噪鲁棒性。从物理机理来看,HCANet能够抑制背景杂波干扰的关键在于其“特征空间解耦”能力。在单通道场景下,背景杂波中存在较多平稳或缓变分量,而无人机目标则携带高频微多普勒调制。时域多尺度卷积通过不同长度的感受野,能够识别并抑制平稳的背景信号,而层级交叉注意力机制则进一步通过时频权重的自适应分配,将“注意力资源”聚焦于具有非平稳特性的目标特征段,从而在不需要参考信号对消的前提下,实现了目标无人机回波与其他背景杂波的隐式分离。

此外,本节在莱斯与瑞利信道下评估模型对抗多径衰落的能力。图3(b)、图3(e)和图3(c)、图3(f)展示了两种多径场景下的测试结果。在含视距分量的莱斯信道中,得益于直射路径提供的稳定能量,各模型在高SNR下的性能均趋于饱和;但在-2~0 dB的中低SNR区域,HCANet的准确率与F1分数依旧维持较高水平,其层级交叉注意力机制能够有效利用直射成分的结构信息,同时抑制多径散射引起的波形畸变。

在最具挑战性的瑞利信道下,信号时域波形与

频谱结构高度破碎,导致所有模型的性能均出现明显下滑。即便如此,HCANet仍表现出良好的性能,在10 dB条件下,其指标优于BiGRU和VTCNN。这验证了HCANet通过时频双流交互与跨域加权融合,在抑制低贡献散射路径的同时,有效提取弱目标微动特征,从而在非视距场景下具有良好的检测可靠性。

图4为不同信道下典型信噪比工作点的各模型准确率与F1分数对比,直观反映了各模型在高中低3种信噪比状态下的表现。HCANet并非仅在单一场景下取得局部优势,而是在3类典型信道及全信噪比范围内均位居首位。特别是在瑞利信道0 dB条件下,其相对于BiLSTM的增益最为显著。总体而言,与4种代表性基线模型相比,HCANet构建了更契合DTMB外辐射源信号特性的特征空间,在复杂电磁环境中表现出更缓和的性能退化趋势和更优的准确率-F1分数平衡,验证了其在被动感知任务中的有效性与泛化能力。

此外,本文引入了能量检测(energy detection, ED)法^[22]、匹配滤波(matched filtering, MF)法^[23]及相干积累(coherent accumulation, CA)法^[24]3种经典信号处理算法作为基准进行对比,对比结果如表2所示。实验结果表明,在信噪比为10 dB的仿真条件下,传统方法在3种典型信

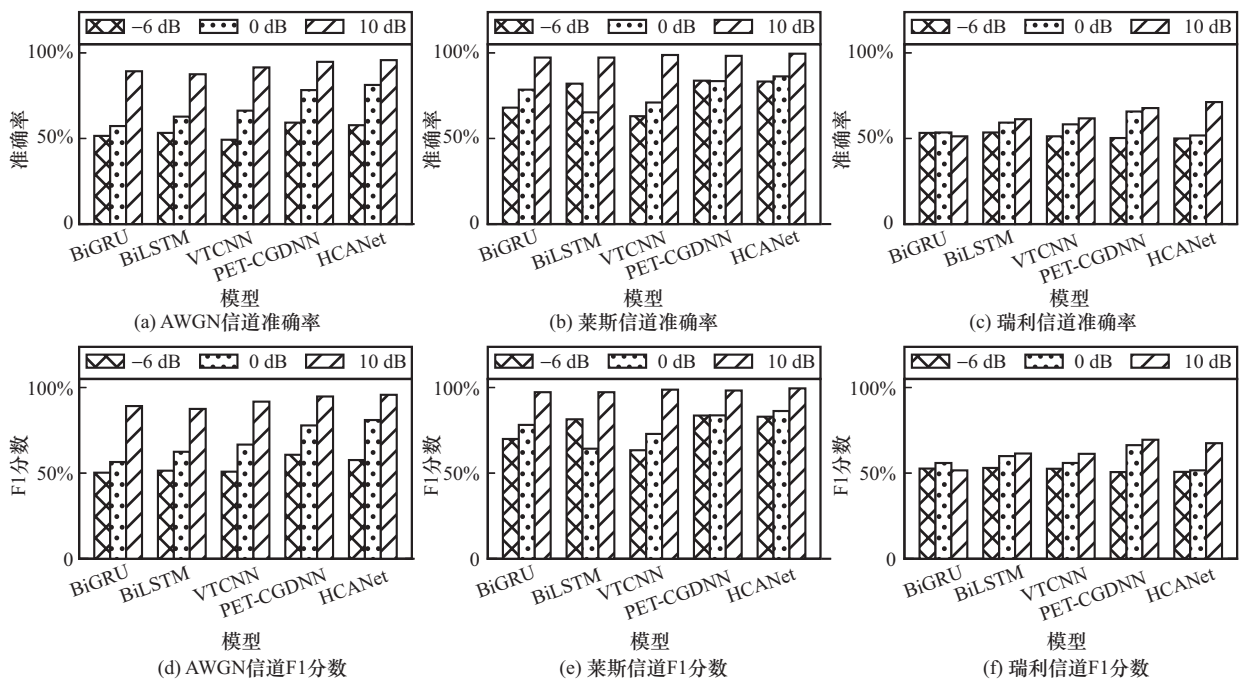


图4 不同信道下典型信噪比工作点的各模型准确率与F1分数对比

道下的检测准确率均徘徊在 47.5%~52.75%，而 HCANet 在同等条件下分别达到了 95.75%（加性白高斯噪声）、99.50%（莱斯）和 71.25%（瑞利）。

表 2 HCANet 与传统信号处理方法在不同环境下的性能对比

方法	10 dB 瑞利信道 环境数据准确率	10 dB 莱斯信道 环境数据准确率	10 dB 加性白高斯 噪声信道环境数 据准确率
能量检测法	47.50%	47.50%	48.50%
匹配滤波法	50.75%	52.75%	51.50%
相干积累法	52.50%	49.25%	50.00%
HCANet	71.25%	99.50%	95.75%

传统方法在单通道无源感知场景下存在本质局限，导致性能失效。首先，能量检测法无法区分信号与噪声的能量波动，且在缺乏纯净参考信号对消直达波的情况下，微弱的目标回波能量完全被直达波与背景噪声掩盖；其次，匹配滤波法高度依赖纯净的参考信号，在本文设定的单通道场景中，接收信号混叠了强直达波与多径杂波，导致传统互相关处理无法获得有效的相干增益，甚至因多径效应产生大量虚警；最后，相干积累法对相位一致性要求极高，仿真中模拟的非视距瑞利衰落及无人机微动导致的相位快速随机扰动，破坏了长时间积累所需的相干条件。相比之下，HCANet 的性能提升机理在于其并未显式依赖波形匹配或相位对齐，而是通过“时域多尺度卷积”捕捉信号的非平稳包络波动，利用“频域幅相联合编码”挖掘微多普勒纹理，并通过“层级交叉注意力机制”在特征空间自适应地对齐并增强被噪声淹没的目标特征。这种端到端的特征学习能力，使其能够有效规避传统方法对信号纯净度和信道稳定性的严苛假设，从而在低信噪比与强多径环境下实现鲁棒检测。

3.3 实测数据验证与工程效能分析

为验证本文方法在真实电磁环境下的泛化能力及在边缘设备上的部署潜力，本节结合 538 MHz 现网实测数据与模型轻量化指标进行综合评估。测试结果表明，HCANet 依然保持了高检测鲁棒性。HCANet 在实测数据上的分类准确率高达 99.65%，明显优于对比模型。这表明，HCANet 构建的时频

双流架构与注意力融合策略，在面临真实电磁环境的复杂动态杂波时，仍能保持稳定的特征提取能力。相较于基准模型，本文方法更有效地抑制了背景噪声与环境多径的干扰，从而显著提升了低信噪比下弱目标的检测灵敏度，验证了其在实际单通道 DTMB 外辐射源系统中的可用性。

同时，为验证模型在真实复杂电磁环境下的优势，本文将 HCANet 与传统信号处理方法在实测数据集上的性能进行了对比，如表 3 所示。

表 3 HCANet 与传统信号处理方法在实测数据集上的性能对比

方法	城市实测数据准确率
能量检测法	92.77%
匹配滤波法	92.19%
相干积累法	70.01%
HCANet	99.65%

结果显示，在实测数据集上，能量检测法与匹配滤波法受益于实测信号中较高的直达波信噪比，准确率回升至 92% 左右，但相干积累法仅为 70.01%，而 HCANet 以 99.65% 的准确率依然保持显著领先。

这一实测结果差异进一步印证了数据驱动的深度学习方法的优越性。虽然能量检测法和匹配滤波法在实测强信号下能检测到一定的信号扰动，但它们难以区分无人机目标引起的微弱散射与城市环境中的动态背景杂波（如车辆、植被晃动），导致效果较差。而 HCANet 通过层级交叉注意力模块，成功在特征空间抑制了动态杂波干扰，并敏锐捕捉到了无人机旋翼特有的微多普勒效应。这表明，在面对非合作辐射源与复杂城市信道时，基于深度特征挖掘的检测策略比基于固定物理模型的传统信号处理方法具有更强的环境适应性与目标分辨能力。具体而言，城市环境中的动态背景干扰通常表现为低频特性。HCANet 的优势在于其 Inception 式分支能够通过多尺度核函数匹配无人机旋翼特有的窄带周期性调制特征。网络对高频微动特征的响应权重高于随机摆动的植被干扰，这种自适应的特征过滤机制使得 HCANet 能够从复杂的空域背景中精准提取目标弱回波。

在确认模型具备实战性能的基础上，进一步考量其在资源受限平台上的工程效能。表 4 汇总

了各网络在参数量 (parameters, Params)、每秒十亿次浮点运算次数 (GFLOPS) 及准确率3个维度的对比结果。从模型规模与计算开销维度来看, BiLSTM 的参数量高达 4.06×10^6 , 计算量达到 2.01 GFLOPS; PET-CGDNN 虽然精度较好, 但其资源消耗也相对较高。相比之下, HCANet 通过 Inception 式多分支卷积与自适应池化机制削减了结构冗余, 将参数量控制在 1.33×10^6 , 计算开销为 1.69 GFLOPS, 明显优于上述两种复杂结构。虽然 BiGRU 与 VTCNN 保持了极低的计算量, 但这主要得益于其较为简单的特征提取路径, 往往以牺牲深层语义表征能力为代价。

表4 实测数据评估指标对比

方法	参数量	计算量/GFLOPS	准确率
BiGRU	0.45×10^6	0.43	94.31%
BiLSTM	4.06×10^6	2.01	95.74%
PET-CGDNN	2.04×10^6	1.97	97.71%
VTCNN	2.47×10^6	0.28	97.68%
HCANet	1.33×10^6	1.69	99.65%

综合检测精度与资源消耗的效能分析表明, HCANet 在多维指标上取得了平衡。具体而言, BiGRU 的检测精度 (94.31%) 与最优水平存在差距; 而 BiLSTM 消耗了大量的计算资源, 其精度 (95.74%) 却低于更轻量的卷积类网络, 表明单纯堆叠循环层难以高效适应信号在真实传播环境中的复杂时变特性。值得注意的是, 尽管 VTCNN 以较低的计算量取得了 97.68% 的较高精度, 但在高可靠性要求的无人机监测任务中, HCANet 所实现的 99.65% 精度满足了低空安防领域对系统高可靠性的需求。若以参数利用效率或计算效能比进行衡量, HCANet 均表现良好。这种稳健的性能表现得益于仿真与实测相结合的多维度验证方案。在仿真环节中, 数据集通过覆盖加性白高斯噪声、莱斯及瑞利等多类衰落信道, 模拟了复杂多径传播对信号的影响。在实测环节中, 数据集则涵盖了水平飞行、垂直升降及定点悬停等低慢小目标的核心运动模态, 并计入了不同复杂度的场景干扰。这种设计确保了模型能够捕捉到低慢小目标本征的微多普勒特征, 而非对特定实验环境的过拟合, 从而使 HCANet 在面对不同信道条件和任务场景时均展现

出较好的泛化能力。综上所述, 该方法在保证真实场景泛化能力的前提下, 兼顾了适中的参数规模、可控的计算开销与检测精度, 有效减轻了边缘设备的存储与算力负担, 为无人机被动感知提供了一种兼具良好性能与工程可行性的解决方案。

3.4 卷积核选取依据与参数敏感性分析

在时域多尺度卷积模块的设计中, 卷积核长度的选取主要基于对信号物理特性的多维度表征需求。从信号处理角度看, 短长度卷积核有利于捕获信号中的高频瞬态冲击与局部细微变化, 而长长度卷积核则更擅长提取低频包络及宏观周期性特征。通过构建不同长度的卷积核组合, 模型能够模拟多分辨率分析过程, 从而更全面地刻画非平稳信号。与之配套的层级交叉注意力模块, 其逻辑核心在于通过跨尺度信息交互, 识别并强化不同频带分量间的非线性耦合关系, 使模型在噪声背景下仍能精准锁定关键特征。为了验证参数选择的科学性, 本文选取了 3 组典型卷积核组合进行敏感性分析, 实验结果如表 5 和表 6 所示。

表5 仿真数据时域多尺度卷积核长度敏感性分析

卷积核组合	10 dB 加性白高斯噪声信道准确率	10 dB 莱斯信道准确率	10 dB 瑞利信道准确率	计算复杂度/GFLOPS
3/7/15	91.50%	99.00%	70.25%	1.431 8
3/9/19	95.50%	98.75%	68.00%	1.632 4
7/15/21	96.25%	99.25%	66.25%	2.033 4

表6 实测数据下时域多尺度卷积核长度敏感性分析

卷积核组合	城市实测数据准确率	计算复杂度/GFLOPS
3/7/15	99.71%	1.431 8
3/9/19	99.73%	1.632 4
7/15/21	99.71%	2.033 4

根据实验数据分析, 卷积核长度的变化对不同信道环境的表现具有一定的差异性。在 10 dB 信噪比的仿真条件下, 如表 5 所示, 增大卷积核长度有助于提升加性白高斯噪声和莱斯信道的识别精度, 这表明较大感受野有利于提取平稳信道下的长程包络特征; 在瑞利信道下, 短卷积核组合 (3/7/15) 反而展现出更好的适应性, 其原因在于短卷积核组合能更敏锐地捕捉深衰落环境下信号的瞬态波动与微多普勒细节, 避免了长窗口对快速时变特征的平

滑效应。如表 6 所示, 在实测数据中, 3 组不同尺度的组合表现极为接近, 准确率均维持在 99.7% 以上的高水平。综合对比计算复杂度, 尽管长卷积核组合在特定仿真场景下精度略微占优, 但其计算开销较 3/7/15 组合明显提升。因此, 考虑到无人机感知任务的实时性需求, 3/7/15 组合在保持高精度的同时具备更高的计算效率, 更适合资源受限的边缘检测场景。

4 结束语

本文针对单通道 DTMB 外辐射源探测中弱回波淹没与多径干扰的难题, 提出了一种基于层级交叉注意力网络的无人机被动感知方法。该方法通过时域多尺度卷积与频域幅相联合编码的双流架构, 实现了对信号互补时频特性的充分挖掘与表征。针对单通道盲探测场景下缺乏物理参考信号导致的检测难题, 本文从特征域解耦的角度论证了弱目标响应增强的理论合理性。理论分析表明, 强直达波及背景杂波在时域表现为准静态分布, 而无人机旋翼散射则携带具有本征规律的非平稳微多普勒调制。层级交叉注意力机制通过学习目标与背景在特征流形空间内的分布差异, 建立了自适应的权重分配准则。这种机制在特征层面起到了“非线性滤波器”的作用, 通过弱化背景分量的特征贡献, 隐式地提升了掩映在强杂波下的弱目标特征显著性, 从而补偿了传统相干对消增益的缺失, 确保了无参考通道条件下的检测稳健性。实验结果表明, HCANet 在多种典型衰落信道及真实城市复杂电磁环境下均保持了较高的检测准确率与泛化性能, 且在模型参数量与推理效率之间取得了良好平衡。本文构建的单通道盲检测框架, 为利用机会照射源进行低成本、轻量化组网探测提供了参考方案。未来工作将聚焦于多站协同探测与模型边缘化部署技术, 以满足低空安防体系对实时感知与大规模覆盖的需求。

参考文献:

- [1] Guebsi R, Mami S, Chokmani K. Drones in precision agriculture: a comprehensive review of applications, technologies, and challenges[J]. *Drones*, 2024, 8(11): 686.
- [2] Pascarella D, Gigante G, Vozella A, et al. A methodological framework for the risk assessment of drone intrusions in airports[J]. *Aerospace*, 2022, 9(12): 747.
- [3] Tang Z, Ma H, Qu Y, et al. UAV detection with passive radar: algorithms, applications, and challenges[J]. *Drones*, 2025, 9(1): 76.
- [4] Jian M, Lu Z Z, Chen V C. Drone detection and tracking based on phase-interferometric Doppler radar[C]//*Proceedings of the 2018 IEEE Radar Conference (RadarConf18)*. Piscataway: IEEE Press, 2018: 1146-1149.
- [5] Zhang W, Fu W H, Xie X X, et al. Range-Doppler characteristics of multi-rotor unmanned aerial vehicle in low-frequency passive radar[J]. *IET Conference Proceedings*, 2024, 2023(47): 26-30.
- [6] Martelli T, Colone F, Tilli E, et al. Multi-frequency target detection techniques for DVB-T based passive radar sensors[J]. *Sensors*, 2016, 16(10): 1594.
- [7] Mendis G J, Wei J, Madanayake A. Deep learning-based automated modulation classification for cognitive radio[C]//*Proceedings of the 2016 IEEE International Conference on Communication Systems (ICCS)*. Piscataway: IEEE Press, 2016: 1-6.
- [8] Liu K, Gao W J, Huang Q H. Automatic modulation recognition based on a DCN-BiLSTM network[J]. *Sensors*, 2021, 21(5): 1577.
- [9] Ezuma M, Erden F, Anjinappa C K, et al. Micro-UAV detection and classification from RF fingerprints using machine learning techniques[C]//*Proceedings of the 2019 IEEE Aerospace Conference*. Piscataway: IEEE Press, 2019: 1-13.
- [10] Liang R F, Cen Y G. Radar signal classification with multi-frequency multi-scale deformable convolutional networks and attention mechanisms[J]. *Remote Sensing*, 2024, 16(8): 1431.
- [11] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//*Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2015: 1-9.
- [12] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2017: 2261-2269.
- [13] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[J]. *arXiv Preprint, arXiv: 1807.06521*, 2018.
- [14] Chen X, Kang B, Wang D, et al. Efficient visual tracking via Hierarchical cross-attention transformer[C]//*Computer Vision-ECCV 2022 Workshops*. Berlin: Springer, 2023: 461-477.
- [15] Su J, Liang J M, Zhu J Y, et al. HCAM-CL: a novel method integrating a hierarchical cross-attention mechanism with CNN-LSTM for hierarchical image classification[J]. *Symmetry*, 2024, 16(9): 1231.
- [16] Xing Z J, Wei G F, Dan B, et al. Hierarchical cross attention model for multi-modal HRRP recognition[J]. *IET Conference Proceedings*, 2024, 2023(47): 933-939.
- [17] Wang Q, Wang Z X, Song J. Weak target detection algorithm for passive radar based on deep learning[C]//*Proceedings of the 2025 4th International Symposium on Computer Applications and Information Technology (ISCAIT)*. Piscataway: IEEE Press, 2025: 532-536.
- [18] Chu T W, Zhou H J, Ren Z Z, et al. Intelligent detection of low-slow-small targets based on passive radar[J]. *Remote Sensing*, 2025, 17(6): 961.
- [19] Raslan W A, Mohamed M A, Abdel-Atty H M. Deep-BiGRU based channel estimation scheme for MIMO-FBMC systems[J]. *Physical Communication*, 2022, 51: 101592.

- [20] O' Shea T J, Corgan J, Clancy T C. Convolutional radio modulation recognition networks[C]//Engineering Applications of Neural Networks. Berlin: Springer, 2016: 213-226.
- [21] Zhang F X, Luo C B, Xu J L, et al. An efficient deep learning model for automatic modulation recognition based on parameter estimation and transformation[J]. IEEE Communications Letters, 2021, 25(10): 3287-3290.
- [22] Ma T J, Anderson R J. Remote sensing low signal-to-noise-ratio target detection enhancement[J]. Sensors, 2023, 23(6): 3314.
- [23] Xu Z, Zhou G. Long-time coherent integration based on reconstructed spectrum for weak target detection using pulse-Doppler radar[J]. IEEE Sensors Journal, 2024, 24(5): 6597-6611.
- [24] Lu X, Pan Z W, Zhou H L. Cross-attention transformer for coherent detection in radar under low-SNR conditions[J]. Sensors, 2025, 25(24): 7588.

[作者简介]



白静 (1982-), 女, 河南新乡人, 博士, 西安电子科技大学教授、博士生导师, 主要研究方向为遥感影像解译、智能信号处理。



肖竹 (1981-), 男, 湖南涟源人, 博士, 湖南大学教授、博士生导师, 主要研究方向为机器学习、移动计算和智能信息处理。



何佳成 (2003-), 男, 福建福州人, 西安电子科技大学硕士生, 主要研究方向为雷达目标检测。



张卓 (2002-), 男, 河南南阳人, 西安电子科技大学硕士生, 主要研究方向为辐射源个体识别。