

# 基于DETR\_S的卫星信号智能检测方法

李 昱, 石晓然\*, 苗昊倩, 王晓宁, 周 峰

(西安电子科技大学电子信息对抗与仿真技术教育部重点实验室, 陕西西安 710000)

**摘要:** 复杂电磁环境下卫星信号往往淹没在背景和噪声中, 传统的信号检测算法在没有准确先验知识的情况下性能急剧降低, 目前基于深度学习的信号检测算法往往需要依赖专家经验的数据后处理步骤, 无法对信号进行端到端检测. 针对上述缺陷, 提出一种基于DETR\_S (DEtection with TRansformer on Signal) 的卫星信号智能检测方法. DETR\_S以编码器-解码器架构为基础, 利用Transformer网络全局建模能力捕获频谱信息, 采用多头自注意力机制有效改善频谱信息长距离依赖的问题. 基于匈牙利算法的预测框匹配模块摒弃了非极大值抑制的数据后处理步骤, 将信号检测问题转变为集合预测问题, 使模型并行输出检测结果. 引入信号重构模块, 将频谱重构损失函数加入损失函数中, 辅助模型挖掘频谱深层表征, 提升信号检测性能. 实验结果表明, 在仅使用信号频谱幅度信息条件下, DETR\_S能够在信噪比等于0 dB及以上对卫星信号进行精确检测(>95%), 优于典型的目标检测方法.

**关键词:** 复杂电磁环境; 卫星信号检测; 多头自注意力; 频谱特征; 匈牙利算法; 二分图匹配

**基金项目:** 国家自然科学基金(No.61201418); 博士后科学基金(No.2020M673346); 教育部联合基金(No.6141A02022367); 新一代电子信息热点领域的若干问题研究(No.YJSJ24011)

**中图分类号:** TN95; TP181

**文献标识码:** A

**文章编号:** 0372-2112(2025)05-1365-14

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20240639

## Intelligent Detection Method of Satellite Signal Based on DETR\_S

LI Yu, SHI Xiao-ran\*, MIAO Hao-qian, WANG Xiao-ning, ZHOU Feng

(Key Laboratory of Electronic Information Countermeasure and Simulation Technology,  
Ministry of Education, Xidian University, Xi'an, Shaanxi 710000, China)

**Abstract:** Satellite signals in complex electromagnetic environments are often submerged in background and noise, and the performance of traditional signal detection algorithms degrades dramatically without accurate a priori knowledge. Currently, deep learning-based signal detection algorithms often require data post-processing steps that rely on expert experience and cannot achieve end-to-end detection of signals. To address the limitations of existing algorithms, an intelligent detection method of satellite signals based on DETR\_S (DEtection with TRansformer on Signal) is proposed. Firstly, DETR\_S is based on the coder-decoder architecture and uses the global modeling ability of the transformer network to capture spectrum information. Secondly, uses the multi-head self-attention mechanism to effectively improve the problem of long-distance dependence of spectrum information. Then, the prediction frame matching module based on the Hungarian algorithm abandons the post-processing step of data with non-maximum suppression, and transforms the signal detection problem into a set prediction problem, so that the model can output the detection results in parallel. Finally, the signal reconstruction module is introduced, and the spectrum reconstruction loss function is added to the loss function to further improve the signal detection performance by mining the deep representation of the spectrum. The experimental results show that DETR\_S can accurately detect faint satellite signals (>95%) at signal-to-noise ratios of 0 dB and above using only the signal spectral amplitude information, which is a significant improvement in the detection effect compared with the typical target detection representative network.

**Key words:** complex electromagnetic environment; satellite signal detection; multi-headed self-attention; spectrum feature; Hungarian algorithm; bipartite graph matching

**Foundation Item(s):** National Natural Science Foundation of China (No.61201418); China Postdoctoral Science Foundation (No.2020M673346); Joint Fund of Ministry of Education (No.6141A02022367); Fundamental Research Funds for the Central Universities (No.YJSJ24011)

## 1 引言

无线通信技术的迅猛发展推动了其在 5G 移动通信<sup>[1]</sup>、物联网<sup>[2]</sup>、卫星通信<sup>[3]</sup>等领域的广泛应用。其中拥有广阔发展前景的卫星通信技术能够有效解决传统有线通信覆盖范围不全面、稳定性差等问题。随着通信频段的持续开发、不明体制和私有协议的信号增加,通信环境日趋复杂。各式各样的信号交织在一起,频谱混叠情况愈发严重,面对时、频、空、能域的电磁信号分布密集、样式繁多以及电磁谱权争夺激烈的复杂电磁环境<sup>[4]</sup>,卫星信号的检测与分析面临巨大挑战。

地面接收设备需要根据要求选择合适的数据传输方式,平衡数据量、实时性能和信号信息的详细程度。在接收信号幅度和相位信息完备的条件下,卫星信号能够通过自适应重构<sup>[5]</sup>、时域均衡<sup>[6]</sup>等技术对信号进行恢复,实现高精度检测。然而,在实际信号的接收中,装备端需要快速传输中频信号便于实时分析,完整中频信号的原始数据量很大,使实时传输不切实际。实时处理通常只能得到信号的频谱幅度,缺失相位信息。此外,在非合作的信息受限场景下,侦察方难以精确获得卫星信号完整的时域信息,在仅使用频谱幅度信息的条件下,建立在时域序列的信号处理与恢复手段几乎无法执行。现有解决方案中研究这一挑战的内容有限,在相位信息受到严重限制的情况下,基于传统时域处理方法表现出显著的局限性。

传统信号检测方法中,基于能量的检测算法<sup>[7]</sup>是最早出现且最直观的方法,能量检测法依赖测量特定时间段内接收信号的总能量,将测得的信号总能量与预设的判决门限比较,实现信号检测。文献<sup>[8]</sup>以码速率为步长进行搜索,将跳频、跳码扩频双图案和能量检测算法相结合,提出一种卫星信号检测算法。该类方法无须先验知识且检测速度较快,然而当信号噪底较强或者受到干扰时,往往达不到检测精度。随后研究者们提出了特征值检测法<sup>[9]</sup>,该算法依赖信号协方差矩阵的特征值,将协方差矩阵的特征值与判决门限对比,能否获得精确的阈值门限是特征值检测算法的关键。在能够获得信号的幅频响应合作场景下,匹配滤波法<sup>[10-12]</sup>是一种常用且高效的检测方法。然而,在没有先验信息的条件下,其检测性能会大幅下降。在信噪比低的条件下,循环平稳检测法<sup>[13,14]</sup>由于良好的抗噪性能受到学者们广泛关注,利用对码速率、载波频率以及采样频率等调制信息的估计、信号循环平稳性来检测信号。然而,循环谱的计算复杂度较高,且对参数估计的精度较低,难以满足卫星检测场景下实时性和准确性的要求。总体来说,基于传统经验特征的信号检测算法存在以下问题:(1)需要信号的先验信息或是对背景噪声进行精确估计;(2)在高动态背景下手动选取的专家经验特

征检测效果较差。随着杂波类型的多样化趋势,当卫星信号能量弱于杂波和噪声能量时,阈值门限的设计是一个棘手的问题,尤其在复杂背景且接收条件受限的情况下,传统算法难以实现高性能检测,需要智能化的检测方法。

深度神经网络的发展为解决信号检测和识别中的各项任务提供了许多工具和框架<sup>[15]</sup>,基于深度学习的卫星信号检测算法凭借神经网络强大的拟合能力展现出显著优势<sup>[16]</sup>,无须先验知识便可自动学习卫星信号的关键特征信息,减少人为因素干扰且检测准确率高。目前,用于目标检测的深度学习算法主要归纳为两大类:基于候选区域的两阶段模型和基于回归的单阶段模型。双阶段模型首先在全局图像上初步判断候选区域是否包含目标,接下来对候选区进行分类,实现目标检测和分类。双阶段目标检测算法的典型代表如下:R-CNN(Region-based Convolutional Neural Networks)算法<sup>[17]</sup>、SPPNet(Spatial Pyramid Pooling Network)算法<sup>[18]</sup>、Fast R-CNN(Fast Region-based Convolutional Neural Networks)算法<sup>[19]</sup>、Faster R-CNN(Faster Region-based Convolutional Neural Networks)算法<sup>[20]</sup>、R-FCN(Region-based Fully Convolutional Neural networks)算法<sup>[21]</sup>等。两阶段的设计使得这些模型在目标检测任务中具有较高准确率和可靠性,但实时性较差。单阶段目标检测算法以其高效性和实时性得到了广泛应用。OverFeat算法<sup>[22]</sup>为首个单阶段目标检测算法,单阶段算法典型代表还包括YOLO(You Only Look Once)系列算法(如YOLO<sup>[23]</sup>、YOLOv2<sup>[24]</sup>、YOLOv3<sup>[25]</sup>等)、SqueezeDet算法<sup>[26]</sup>、SSD(Single Shot multi-box Detector)算法<sup>[27]</sup>等。该类算法可直接在预设的候选区域进行特征提取,检测速度快但精度相对偏低。

目标检测框架的蓬勃发展为基于深度学习的信号检测算法提供了新思路<sup>[28]</sup>,Prasad等人<sup>[29]</sup>利用Faster R-CNN实现对无线射频RF(Radio Frequency)信号的检测和定位,Zha等人<sup>[30]</sup>借助SSD实现对通信调制信号的检测和分类,Li等人<sup>[31]</sup>利用YOLOv3模型提出通信信号的盲检测模型。上述基于锚点框的目标检测方法需要提前为空间的每一个位置设定多个矩形框称之为锚点,用于定义模型要检测目标的位置、大小和长宽比,锚点的设置直接影响模型检测效果。信号频谱检测时,从经典检测器到信号检测的框架修改主要通过统计或聚类方法调整先验锚的大小以适应信号。然而,频谱图中信号的纵横比变化很大,即使是设计良好的先验锚点也很难匹配所有信号<sup>[28]</sup>。合适的锚点设置需要对目标信号的频谱特性和包络形状依赖专家经验的先验知识。模型对候选区域信号位置预测时,生成预测框的数量通常远远大于真实信号个数。选择最合适预测框作

为最后的推理结果. 非极大值抑制 NMS(Non-Maximum Suppression)<sup>[32]</sup> 通过筛选和保留同一目标的最优预测框, 设定阈值确保最终选择概率最高的预测框. 但阈值的设定是一个依赖经验的困难操作, 不合适的阈值会导致漏检或误检. 此外, 模型一旦整合了 NMS, 检测器的复杂性就会显著增加, 使整个模型在优化和调整参数时变得困难重重, 其迁移性和实用性会受到严重限制. 另一方面, 现有大多数的基于深度学习的卫星信号检测方法通过对图像内部像素点定位物体, 其中 CNN 的感受野难以覆盖较长时间长度的信号. 上述缺陷使经典检测器在用于信号检测时性能下降.

复杂多变的电磁环境对卫星信号检测的有效性和准确性都提出了更高要求, 尤其在非合作接收条件情况下, 获取的信息十分有限, 本文提出一种基于 DETR\_S(Detection with TRansformer on Signal) 的卫星信号智能检测算法, 将多头自注意力机制引入信号频谱图像检测中. 在仅接收到卫星信号频谱幅度信息的条件下, 首先将 1D 信号幅度序列变换为 2D 频谱图, 利用卷积神经网络提取信号浅层空间特征信息, 基于 Transformer 网络<sup>[33]</sup> 的全局建模能力关联信号频谱幅度特征的全局信息, 提出使用解码器重构信号频谱来约束 DETR\_S 的特征提取, 最后利用匈牙利算法将信号检测转化为集合预测问题<sup>[34]</sup>, 摒弃了依赖先验知识的参考框设定和 NMS 的后处理部分, 模型可直接并行输出预测框的坐标和信号类型, 不需要专家特征信息和人为阈值设定, 实现端到端的卫星信号智能检测和分类.

## 2 卫星信号检测场景

卫星信号的存在性检测是信号估计与接收的前提, 为后续的调制识别提供了重要基础. 然而, 各类电磁噪声以及不同频段和机制的电磁信号混叠在电磁空间中, 使卫星信号和背景信号交织在一起. 图 1 描述了卫星下行链路的传输场景, 卫星通过下行信道与地面站通信, 地面站在接收卫星信号  $x_i(t)$  的同时也会收到地面有意或无意的干扰源信号  $b_k(t)$ , 而卫星信号  $x_i(t)$  由于传输距离远、存在阴影遮蔽, 信道衰落严重使信噪比降低, 信号常常淹没在复杂背景中, 呈现极低谱密度特性, 非合作卫星测控信号的盲检测问题即从接收到的原始数据  $y(t)$  中判断有无卫星下行链路信号, 其本质上是一个二元的假设检验问题. 具体表示如下:

$$\begin{cases} H_0: y(t) = \sum_{k=1}^{N_{\text{signal}}} b_k(t) + n(t) \\ H_1: y(t) = \sum_{i=1}^{N_{\text{signal}}} x_i(t) + \sum_{k=1}^{N_{\text{background}}} b_k(t) + n(t) \end{cases} \quad (1)$$

其中,  $x_i(t)$  为接收信号模型,  $N_{\text{signal}}$  为原始数据中所含卫

星信号的个数,  $b_k(t)$  为环境存在的背景信号或干扰信号,  $N_{\text{background}}$  为环境存在的背景信号或干扰信号的个数,  $n(t)$  为信道环境引入的噪声,  $H_0$  表示仅含噪声(不存在卫星信号),  $H_1$  表示存在卫星信号.

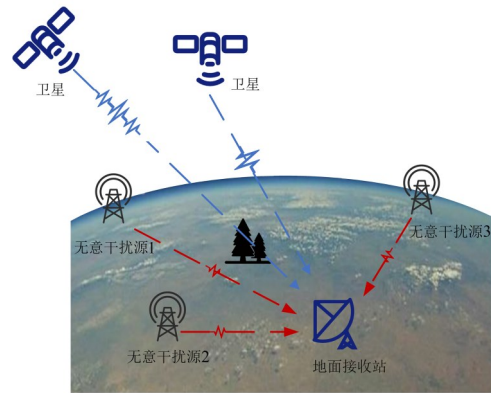


图1 卫星下行链路信号接收场景示意图

星下行信号多用复合调制类型<sup>[33]</sup>, 会对信息进行多级调制, 其中 PCM-BPSK-PM(Pulse Code Modulation-Binary Phase Shift Keying-Phase Modulation) 属于一种常用的卫星下行信号类型, 将发送的信息依次经过编码、二进制相移键控调制得到内层的 BPSK 信号. 最后对内层 BPSK 信号再进行一次 PM 调制得到最终 PCM-BPSK-PM 信号, 其表达式为

$$s_{\text{PCM-BPSK-PM}}(t) = A_c e^{j[2\pi f_c t + K_p s_{\text{BPSK}}(t)]} \quad (2)$$


其中,  $A_c$  为主载波振幅;  $f_c$  为主载频;  $K_p$  为调相灵敏度, 表示单位调制信号幅度所造成的相位调制 PM(Phase Modulation) 信号中的相位偏移量;  $s_{\text{BPSK}}$  表示内层的 BPSK 信号, BPSK 调制将原有信息加在相位上, 所携带的信息通过相位变化来表示. BPSK 信号中的 2 个码元分别代表了 2 种不同的相位, 通常情况下会取  $0^\circ$  与  $180^\circ$ . BPSK 信号时域表达式如下:

$$s_{\text{BPSK}}(t) = A_{\text{BPSK}} \cos[2\pi f_{\text{BPSK}} t + \varphi] \quad (3)$$


PCM-BPSK-PM 信号的主载波为 PM, 副载波为 BPSK, 其中的主载波主要用于探测, 副载波主要用于传递信息.

传统的卫星信号检测方法通常作用于时域序列或时频图, 但在相位信息受限的场景下, 通常难以实现. 如图 2 所示, PCM-BPSK-PM 信号在频谱上会显著展现出其内层 BPSK 调制信号的频谱特性. 这些特性的显现程度与调制指数紧密相关. 具体而言, 当调制指数较小时, 频谱上主导的特征是一根极为突出的载波分量, 此时内层 BPSK 调制信号的频谱特征相对不明显. 随着调制指数增大, 频谱上除了载波分量外, 还会清晰地呈现出内层 BPSK 调制信号的频谱特征, 包含载频以及符号速率等信息. 因此, 通过对卫星信号的频谱图像进行细

致观测和特征提取,实现有效检测和识别.



(a) PCM-BPSK-PM 信号时域图



(b) PCM-BPSK-PM 信号频域图

图2 PCM-BPSK-PM 信号时频域图

对频谱 $y(t)$ 的观测值构建检验统计量,再判决得到检验结果,判断信号的有无和个数以及每个卫星信号 $x_i(t)$ 的具体类别.理想情况下的 $n(t)$ 是均值为0、方差为 $\sigma^2$ 的高斯白噪声.而复杂空天链路信道往往存在阴影遮蔽、多径衰落等损失使信号信噪比降低,部分有意或无意的背景干扰信号能量远远高于卫星信号,传统基于专家特征的信号检测算法往往效果较差,且在信息受限条件下,缺乏信号相位信息时传统方法几乎失效.本文提出的基于DETR\_S的卫星信号智能检测算法流程如图3所示,主要包括4个步骤:(1)卫星信号频谱图标注;(2)DETR\_S网络模型的设计和训练,得到最优检测模型;(3)利用模型对卫星信号频谱图推理检测;(4)根据图像检测结果重构各个信号的频点位置、带宽等关键参数,为重点目标特征库构建奠定基础.

### 3 基于DETR\_S的卫星信号智能检测方法

#### 3.1 基于数据增强的频谱图扩充标注

利用DETR\_S网络进行信号检测前,需要构建卫星

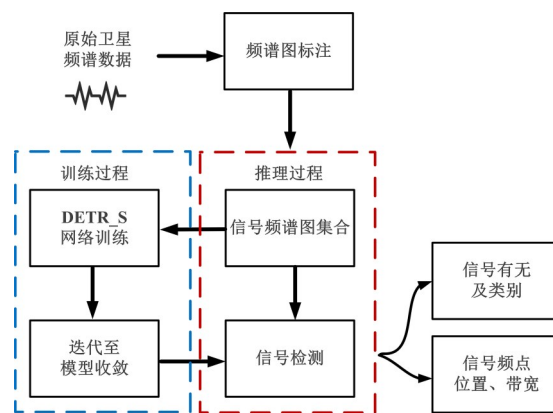


图3 基于DETR\_S的卫星信号智能检测方法

信号频谱图训练集合,训练集中信号的标注质量与网络检测效果息息相关.在相位信息受限的场景下,接收的样本为频域中幅度序列,考虑到1D的频域幅度序列缺乏信号频谱的空间信息.将其转换为2D频谱图可以更直观显示信号的频谱特征和幅度包络.由第2节的理论分析可知,这样的改进能够利用1D格式中不易识别的空间和纹理特征(例如复合调制信号的旁瓣能量).

然而,标注整张频谱图是一项极为耗时且繁重的工作,在非合作条件下难以获得大量高精度标签.为了实现非合作场景下样本的高效标注,本文基于有限的卫星信号频谱图样本,利用一种基于数据增强思路的频谱图样本集扩充标注的方法,显著减轻了标注工作的繁重负担,主要分为4个步骤:

(1)卫星信号频谱区域提取.首先,从已收集的信号频谱图库中,通过精细的手工截取或先进的图像边缘显著性检测技术,提取目标卫星信号所对应的频谱图像区域,作为后续合成的信号块.

(2)背景噪声底仿真映射.为模拟真实环境中的信号接收场景,根据不同的背景环境需求,仿真生成高斯噪声、瑞利噪声、非高斯 $\alpha$ 稳定噪声等多种类型噪声信号.同时加入背景中出现的常见干扰信号,变换至频域如图4(a)所示.

(3)频谱图合成.将步骤(1)中提取的目标频谱像素块叠加到仿真映射生成的背景噪声底频谱图上.为进一步增强样本的多样性和真实性,对目标信号像素块施加适量的干扰和噪声,模拟实际环境中信号可能遭受的各种影响.

(4)扩充标签生成.基于合成频谱图中信号的实际位置与类型,自动生成标准化的标签文件,为后续数据处理与模型训练提供准确指引.

通过上述方法,仅需少量的实际卫星信号接收数据,结合大量仿真生成的背景噪声样本,高效地扩展出规模庞大的带标签频谱图样本集.基于数据增强的卫星频谱图扩充标注结果如图4所示.




图4 标注前后的信号频谱图

### 3.2 DETR\_S 浅层特征提取模块

本文提出的信息受限条件下卫星信号智能检测方法 DETR\_S 结构如图 5 所示. DETR\_S 网络由浅层特征提取模块、DETR\_S 编码器和解码器模块以及信号检测模块 3 个部分组成. 其中浅层特征提取模块用于提取信号频谱的浅层空间特征, 帮助 DETR\_S 编码器-解码器捕获信号的频谱关联性. 受文献[34]的启发, 采用

ResNet50(Residual Network50)作为主干网络, 提取 2D 频谱图中的信号幅值包络变化和空间纹理特征, 让多头自注意力机制作用于信号频谱的浅层特征上. 因此, 浅层特征提取网络的输入是 高为  $H$ , 宽为  $W$  的 2D 频谱图像  $S_i \in \mathbb{R}^{3 \times H \times W}$  (RGB 通道), 通过残差神经网络将频谱图的高度和宽度降维 32 倍的同时减弱梯度消失带来的影响, 为后续 DETR\_S 编码器和解码器模块提供高质量频谱特征.

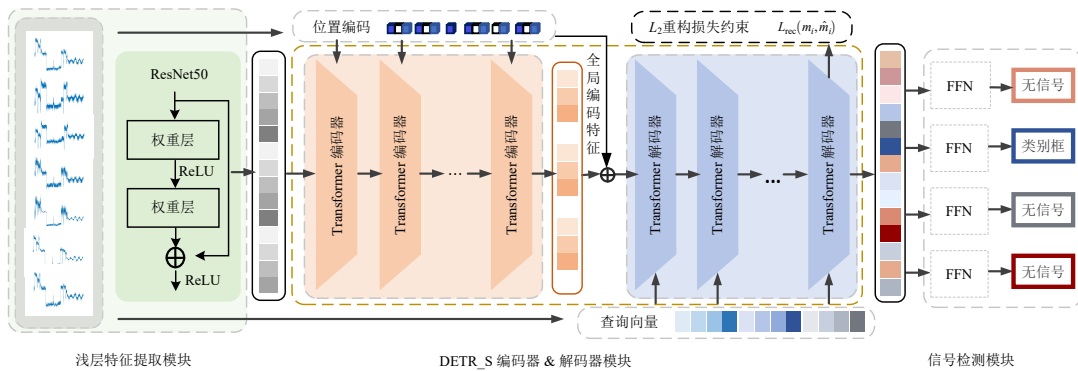


图5 DETR\_S 网络结构

### 3.3 DETR\_S 编码器-解码器

信号频谱特征具有离散抽象的特点, 且具有明显的上下文联系. 为了获得更大的感受野并保证频率上下文的连接关系. DETR\_S 编码器-解码器模块的设计由 Transformer 模型的编码器-解码器结构所启发, 使用自注意力机制进行全局的特征关联. DETR\_S 编码器模块由  $N_e$  个结构相同的编码器单元串联构成, 每一个编码器由多头自注意力层和 2 层全连接层 FFN (Feed-Forward Network) 构成. 由频谱特征提取网络得到的输入信号频谱紧凑特征, 首先通过  $1 \times 1$  的卷积层压缩通道维度信息, 并铺平频谱特征, 最终得到特征向量  $F_{1f-img} \in \mathbb{R}^{C_1 \times (H_1, W_1)}$ . 其中,  $H_1$  与  $W_1$  分别代表降维后的特征的高度和宽度, 由于不同频点具有位置相关性, 本文对信号使用位置编码以获取全局频谱信息, 重点关注卫星信号频点位置的变化, 将其与特征图融合共同作

为编码器多头自注意力层的输入. DETR\_S 编码器的结构如图 6 所示.

卫星信号添加位置编码后提取的特征向量作为 DETR\_S 编码器的输入, 通过可学习的矩阵  $W^Q$ 、 $W^K$ 、 $W^V$

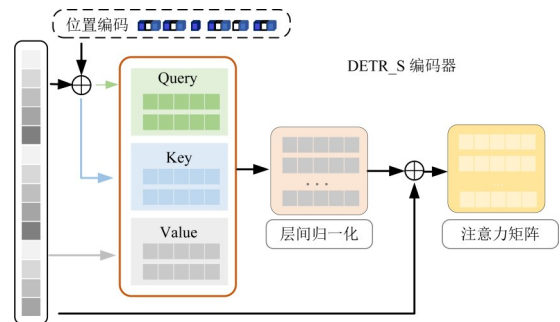


图6 DETR\_S 编码器结构

映射为 Query、Keys 和 Values 向量. 进行自注意力操作:

$$\text{attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_{\text{keys}}}}\right)\mathbf{V} \quad (4)$$

其中, softmax 为归一化指数函数将数值映射到  $[0, 1]$ ,  $\mathbf{Q}, \mathbf{K}, \mathbf{V}$  分别表示 Query 向量、Keys 向量和 Values 向量.  $\mathbf{Q}$  和  $\mathbf{K}^T$  对应位置元素相乘, 并缩小  $\sqrt{d_{\text{keys}}}$ , 表示自注意力矩阵结果, 其中  $d_{\text{keys}}$  为 Keys 向量的维度.

注意力得分除以  $\sqrt{d_{\text{keys}}}$  保证内积之后的相似度均值为 1, 反向传播时获取平衡梯度, 经过 softmax 后将得分转换为概率, 乘以自身的 Values 向量得到自注意力向量. 输入特征同时通过残差连接至自注意力向量后进行归一化, 以保证不出现梯度消失和退化的问题. 由于输入信号特征的每一个向量之间都会进行自注意力操作, 即任意 2 个向量之间都有直线连路. 因此, 自注意力机制可以在宽带接收情况下学习卫星信号长距离频点间的关联性.

考虑到单一的自注意力操作会过度将注意力集中在自身位置, 导致信号特征的子空间表示较单一. 卫星信号的检测需要捕获序列内多范围的依赖关系, 本文采用多头注意力机制, 利用多组的权值矩阵得到多组的 Query、Keys、Values 向量, 学习不同层面的信号信息, 每个注意力头会关注输入的不同部分. 通过多个头可以关注更多层次的频谱依赖信息.

DETR\_S 解码器由  $N_d$  个结构相同的解码器连接而成. 解码器的整体构成与编码器类似, 不同的是为了使解码预测位置为  $i$  时不使用  $i$  之后的输出信息, 引入了掩码机制. 解码器以自回归的方式输出信号检测结果, DETR\_S 解码器的结构如图 7 所示.

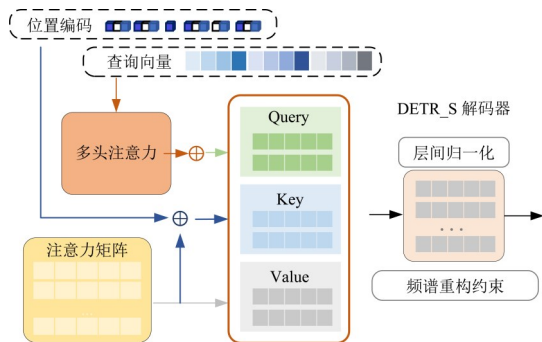


图 7 DETR\_S 解码器结构

首先, 解码器的 Values 向量是编码器生成的自注意力向量, Keys 向量则是 Values 向量和位置编码逐元素相加获得, Query 向量则是编码后的卫星信号检测框. 接下来, 3 个向量的自注意力操作按照式(4)进行.

最后, 为了缓解梯度消失问题, 加速收敛、稳定训练, 将注意力后的结果通过层归一化对每个样本的不同通道进行归一化限制. 由于信号频谱图前景和背景的分度差, 且待检测频谱纵横比变化较大, 导致网络对包络特征难以捕获, 对 DETR\_S 解码器模块的输出进行  $L_2$  范数的约束重构, 在像素级衡量重构前后的频谱图相似性, 保证信号频谱经过编码器和解码器模块后能提取有效信号的空间特征信息.

### 3.4 信号检测模块

传统基于极大值抑制算法的后处理步骤依赖于人工设置阈值从  $N$  个结果中保留概率最大的框作为预测结果. 本文采用匈牙利算法调整匹配过程, 计算二分图的最小匹配损失, 将依赖人工经验的后处理步骤智能化. 具体来说, 解码器模块生成的信号特征首先通过 FFN 映射到高维特征空间, 随后经过 3 层感知器和线性层的处理, 并通过 ReLU (Rectified Linear Unit) 进行非线性激活, 最终生成信号检测框的预测坐标. 对于待检测的  $N$  个卫星信号, 预测检测框的 4 个坐标值与经 softmax 函数预测得到的类别标签由 FFN 层同时进行预测, FFN 的输出维度为  $N \times 5$ . 最后将标注好的标签也拓展为  $N \times 5$  的检测框, 对预测的结果和标签进行一一对应使匹配损失最小, 匹配损失的计算如式(5)和式(6)所示:

$$\hat{\sigma} = \arg \min_{\sigma \in N} \sum_{i=1}^N L_{\text{match}}(a_i, \hat{a}_{\sigma(i)}) \quad (5)$$

$$L_{\text{match}}(y_i, \hat{y}_{\sigma(i)}) = -1_{\{c_i \neq \emptyset\}} \hat{p}_{\sigma(i)}(c_i) + 1_{\{c_i \neq \emptyset\}} L_{\text{box}}(s_i, \hat{s}_{\sigma(i)}) \quad (6)$$

其中,  $\hat{\sigma}$  为匈牙利算法对匹配损失进行优化以得到最小损失, 预测得到成对的匹配索引;  $L_{\text{match}}(a_i, \hat{a}_{\sigma(i)})$  为预测的每一个信号预测框和真实标签拓展的检测框之间的匹配损失,  $L_{\text{match}}(a_i, \hat{a}_{\sigma(i)})$  由 2 个部分组成,  $-1_{\{c_i \neq \emptyset\}} \hat{p}_{\sigma(i)}(c_i)$  为最小化类别预测过程的损失,  $1_{\{c_i \neq \emptyset\}} L_{\text{box}}(s_i, \hat{s}_{\sigma(i)})$  为最小化信号检测过程损失, 其中  $c_i$  为信号类标签,  $c_i \neq \emptyset$  代表不考虑预测信号类别为背景 ( $\emptyset$ ) 的情况;  $\hat{p}_{\sigma(i)}$  代表预测信号属于类别  $c_i$  的概率;  $s_i \in [0, 1]^{d=4}$  的前 2 个数值对检测框进行定位, 代表中心的横坐标  $x_i$  和纵坐标  $y_i$ , 后 2 个数值为检测框的范围预测结果, 对应其以频谱图为基础的相对高度  $h$  和相对宽度  $w$ .

传统匈牙利算法通常假设 2 组匹配对象的数量是相同的, 但在卫星信号检测场景下, 信号的出现是随机的, 频谱图中目标信号的频谱个数可变, 大多数情况下真实的信号框会少于模型生成的预测框数量, 为此, 在匹配过程中对缺少真实信号频谱的预测框进行“无信号”匹配. 具体来说, 在模型中, 匈牙利算法的代价矩阵  $\hat{\mathbf{C}}$  并不是一个方阵, 假设每张信号频谱图中存在  $M$  个真实信号框, DETR\_S 解码器生成  $N$  个预测信号框, 则代价矩阵被构建为  $\hat{\mathbf{C}} \in \mathbb{R}^{M \times N}$ , 对于每个多余的预测框, 设

置其目标类别为“背景”类. 没有真实信号出现的预测框不会被简单忽略,而是被有意义地设置为“背景”,并在损失计算中纳入考虑,保持训练过程的稳定性. DETR\_S 在输出层中专门引入了“背景”类别,用于标记这些没有匹配到真实信号的预测框,通过一个简单的分类损失,鼓励模型在没有目标信号的地方预测为“背景”,减少信号的虚假检测.

获得信号预测框的最优匹配  $\hat{\sigma}$  后,计算 DETR\_S 模型的损失函数由 3 个部分组成,分别是信号类别预测的负对数损失  $L_{\text{pre}}$ 、边界框损失  $L_{\text{box}}$  以及频谱重构损失  $L_{\text{rec}}$ .

信号类别预测损失采用负对数损失,模型学习信号分布特性,得到正确的类别预测结果. 该类别预测损失定义如下:

$$L_{\text{pre}} = -\log \hat{p}_{\hat{\sigma}(t)}(c_i) \quad (7)$$

边界框预测损失采用 GIoU (Generalized Intersection over Union) 损失和  $L_1$  损失的双损失计算方式,量化预测框和真实框的位置偏差和大小偏差. GIoU 损失不仅关注预测框和真实框的重叠区域,还关注非重叠区域,解决了  $L_1$  损失无法衡量非重叠区域差异的缺陷.

边界框损失函数定义如下:

$$L_{\text{box}}(s_i, \hat{s}_{\sigma(t)}) = \lambda_{\text{iou}} L_{\text{iou}}(s_i, \hat{s}_{\sigma(t)}) + \lambda_{L_1} \|s_i, \hat{s}_{\sigma(t)}\|_1 \quad (8)$$

其中,  $\lambda_{\text{iou}}, \lambda_{L_1} \in \mathbb{R}$  为 GIoU 损失函数和  $L_1$  损失函数的权重,  $s_i$  为边界框的真实标签,  $\hat{s}_{\sigma(t)}$  为最优匹配条件下预测框结果. 其中,边界框损失  $L_{\text{box}}(s_i, \hat{s}_{\sigma(t)})$  采用 GIoU 损失函数的定义如下:

$$L_{\text{iou}}(s_i, \hat{s}_{\sigma(t)}) = 1 - \left( \frac{|\hat{A}_{\sigma(t)} \cap A_i|}{|\hat{A}_{\sigma(t)} \cup A_i|} - \frac{|B(s_i, \hat{s}_{\sigma(t)}) / \hat{A}_{\sigma(t)} \cup A_i|}{|B(s_i, \hat{s}_{\sigma(t)})|} \right) \quad (9)$$

其中,  $\hat{A}_{\sigma(t)}, A_i$  分别表示信号预测框边界和真实框边界;  $\hat{A}_{\sigma(t)} \cap A_i$  表示二者的相交面积,不相交时则为 0;  $\hat{A}_{\sigma(t)} \cup A_i$  表示两框覆盖的总面积;  $B(\cdot, \cdot)$  表示能够将两框包含在内的最小矩形的面积. GIoU 损失通过最大化信号出现位置的预测框和真实框的重叠程度,得到最优信号检测结果.

为保证信号频谱经过编码器和解码器模块后能提取信号的空间特征信息,对解码器得到的信号特征进行频谱重构. 重构损失在像素级衡量重构前后的频谱图的相似性,定义如下:

$$L_{\text{rec}}(m_i, \hat{m}_i) = \sum_i^M (m_i - \hat{m}_i)^2 \quad (10)$$

其中,  $m_i, \hat{m}_i$  分别为原始信号频谱图和重构后的信号频谱图中的像素点,  $M$  为像素点的总个数.

损失函数  $L_H$  定义为这 3 类损失函数的总和:

$$L_H(y, \hat{y}) = \sum_{i=1}^N \left[ -\log \hat{p}_{\hat{\sigma}(t)}(c_i) + 1_{\{c_i \neq \phi\}} L_{\text{box}}(s_i, \hat{s}_{\sigma(t)}) + \lambda_{\text{mse}} L_{\text{rec}}(m_i, \hat{m}_i) \right] \quad (11)$$

DETR\_S 预测的集合结果需要经过反向映射操作还原为卫星信号的待检测参数,由 FFN 预测结果到信号参数的映射如式(12)所示:

$$\begin{aligned} f_{\text{sig}} &= \frac{x}{x_{\text{max}} - x_{\text{min}}} (f_{\text{max}} - f_{\text{min}}) \\ B_{\text{sig}} &= \frac{w}{x_{\text{max}} - x_{\text{min}}} (f_{\text{max}} - f_{\text{min}}) \end{aligned} \quad (12)$$

其中,  $f_{\text{sig}}, B_{\text{sig}}$  分别为待检测卫星信号的中心频率、带宽,  $x, w$  为 FFN 预测的检测框结果中标准化中心坐标和宽度.

综上,基于 DETR\_S 的卫星信号智能检测算法流程如算法 1 所示.

算法 1 基于 DETR\_S 的卫星信号智能检测算法流程

输入: 训练集中少量带噪声的信号样本, 真实场景接收到的  $x_i(t)$

输出:  $x_i(t)$  对应的信号参数, 包括信号总数  $\hat{N}$  和各信号的参数  $\hat{f}_{\text{sig}}^i$ ,

$\hat{B}_{\text{sig}}^i, i = 1, 2, \dots, \hat{N}$

1. 原始信号频谱图自动标注:

- a. 对仿真的卫星信号和噪声样本使用 Welch 功率谱法变换, 得到宽带频谱图样本集, 展示不同频段上信号和噪声的功率分布情况;
- b. 对 a 中的频谱图样本集通过数据增强进行样本量扩充, 得到卫星信号频谱图集  $A$ , 对其进行标注得到对应的标签集合  $B$

2. 根据图 5 和式(11)分别构建与训练 DETR\_S 检测网络

3. 基于 DETR\_S 的卫星信号检测:

- a. 将待检测信号频谱图输入步骤 2 中训练好的 DETR\_S 网络, 得到预测框坐标和类别坐标;
- b. 对预测结果进行参数转换和映射, 得到信号总数  $\hat{N}$  和各信号参数  $\hat{f}_{\text{sig}}^i, \hat{B}_{\text{sig}}^i, i = 1, 2, \dots, \hat{N}$

## 4 实验结果与分析

### 4.1 数据集介绍

本文的实验数据集是基于数据增强的频谱图扩充标注的, 卫星信号来自某实地卫星通信接收站的仿真环境映射, 共有 2 100 张仿真信号频谱图, 卫星信号采用了 PCM-BPSK-PM 和 PCM-QPSK-PM 这 2 种常用的复合调制信号, 信噪比分布范围为  $-15 \sim 15$  dB, 间隔 5 dB. 其中卫星信号频谱区域提取使用 Labelme 工具截取 (<https://github.com/tzutalin/labelImg>, accessed), 标注文件是为了便于验证而转换成 PASCAL VOC 格式的注释文件. 每张频谱图的大小为  $3\,500 \times 2\,625$ , 涵盖频率范围为  $2.1 \sim 2.4$  GHz, 为模拟真实接收条件下的卫星数据传输过程, 在构建背景信号时, 特别关注了频率范围内当前广泛应用的 3G 与 4G 移动通信技术背景信号, 其中包

话 WCDMA、CDMA2000、TD-SCDMA 3 种类型的 3G 信号以及 4G 信号 TD-LTE, 背景信号通过 MATLAB 中的 Simulink 平台及其集成的 Toolbox 工具箱进行仿真, 为了与实际信道环境保持一致, 仿真中加入了随机高斯白噪声以及瑞利衰落. 具体的数据集信号仿真参数和网络参数设置如表 1 所示.

表 1 卫星信号仿真参数

参数类型	信号调制类型	PCM-BPSK-PM、PCM-QPSK-PM		
卫星信号 仿真参数	信号中心频率/ MHz	2 220		
	信号副载频/MHz	200		
	带宽/MHz	10(±5)		
	信道环境	高斯噪声、瑞利衰落		
	包含信号个数	0~1		
	信噪比 SNR/dB	-15~15		
背景信号 仿真参数	频谱图大小	3 500 × 2 625		
	频率范围/MHz	2 100~2 400		
	背景环境信号	3G/4G 信号等		
	3G 信号类型	WCDMA	CD- MA2000	TD- SCDMA
	码片速率/ (Mchip.s <sup>-1</sup> )	3.8	3.68	1.28
	帧长/ms	10	25	10
	时隙	15	15	15
	数据调制	QPSK	QPSK	QPSK
	信道宽度/MHz	5.0	5.0	1.6
	4G 信号类型	TD-LTE		
	载波带宽/MHz	20		
	副载波带宽/MHz	15		
	帧长/ms	10		
	时隙配置	10 : 2 : 2		
	数据调制	OFDM		
网络训练 参数	训练轮次	200		
	批处理大小	20		
	初始学习率	×10 <sup>-4</sup>		
	学习率调整策略	StepLR		
	优化器	Adam		

## 4.2 实验设置

实验将整个数据集分为 3 个部分, 其中 60% 作为训练数据集, 20% 作为测试数据集, 20% 作为验证集进行推理检测. 训练集和测试集用于训练模型, 验证集用于评估模型性能. 对于验证集来说, 频谱是不被标注的, 但被人工检查以评价模型有效性. 在训练阶段, 卫星信号频谱图被输入至 DETR\_S 网络中. 利用 Adam 优化算法驱动整个训练过程, 设定最大训练周期为 200 个 epochs. 每次迭代(即一个批次的更新)采用

20 个样本, 并设置初始学习率为  $1 \times 10^{-4}$ . 为更精细地控制学习进程, 采用等间隔调整学习率策略(Step Learning Rate scheduler, StepLR), 具体为每完成 20 个 epochs 后, 学习率自动下降为原来的 1/10. 反向传播依据式(11)所定义的损失函数. 整个模型的训练和测试通过 PyTorch 框架完成. 显卡为 NVIDIA GeForce RTX 3080TI(24G).

## 4.3 评价指标

为了全面且客观地衡量本文所提方法的检测效能, 采用了多维度的性能评估策略. 具体而言, 通过召回率(Recall, R)、平均精度(Average Precision, AP), 以及信号参数估计误差  $M_s$ , 来综合评价信号检测的效果. 这些指标分别从不同的方面反映了算法在识别目标信号、准确评估信号位置及属性, 以及估计信号参数方面的能力, 提供了一个全面审视算法性能的视角. 表 2 是一个混淆矩阵, 说明真阳性(True Positive, TP)、真阴性(True Negative, TN)、假阴性(Fake Negative, FN)和假阳性(Fake Positive, FP)的概念.

表 2 混淆矩阵

真值/预测值	正样本	负样本
正标签	正样本正确检测(TP)	负样本错误检测(FN)
负标签	正样本错误检测(FP)	负样本正确检测(TN)

召回率, 也称为全部检查率, 用于测量网络的漏检率. 它是正确检测的目标(TP)占有待检测目标(TP和FN)的概率.

mAP 表示多个类别 AP 的平均值, 其中 AP 表示准确率-召回率(Precision-Recall, PR)曲线下的面积. PR 曲线反映了模型在不同召回率水平下所能达到的准确率. PR 曲线下方的面积越大, 则模型的综合检测性能更优异. 定义如下:

$$AP = \int_0^1 P(r) dr \quad (13)$$

其中,  $P(r)$  为检测结果的准确率-召回率曲线.

信号参数估计误差是指待检测卫星信号的关键参数归一化估计误差的平均值, 计算公式为

$$M_s = \frac{1}{k} \sum_{i=1}^k \left| \frac{\bar{x}_i - x_i}{x_i} \right| \quad (14)$$

其中,  $\bar{x}_i$  为检测框映射得到的卫星信号参数的估计结果,  $x_i$  为实际参数,  $k$  为待估计的参数个数.

## 4.4 实验结果与分析

实验通过不同信噪比下的卫星信号检测数据集对本文所提方法有效性和鲁棒性进行验证, 对测试样本在信噪比-15~15 dB 间隔 5 dB 分别进行 1 000 次蒙特卡罗实验, 不同信噪比下本文所提算法检测指标结果定量比较如表 3 和图 8 所示.

表 3 各信噪比下 DETR\_S 检测指标

单位:%

评价指标	-15 dB	-10 dB	-5 dB	0 dB	5 dB	10 dB	15 dB
Recall	21.420	81.400	87.620	96.400	98.300	99.800	99.810
mAP@0.5:0.95	23.120	49.010	53.110	67.120	82.310	84.500	85.010
mAP@0.50	87.310	98.700	98.960	99.320	99.410	99.850	99.890
mAP@0.75	22.430	34.460	51.470	93.710	96.620	97.920	98.210
$M_s$	0.043	0.041	0.036	0.031	0.025	0.022	0.022




图 8 DETR\_S 算法检测结果

平均精度 mAP@0.50 和 mAP@0.75 分别表示预测框与真实信号框 IoU 分别为 0.5 和 0.75 时的 mAP 结果, 代表不同重合程度情况下的检测效果, mAP@0.5:0.95 表示在不同 IoU 阈值 (从 0.5~0.95, 步长 0.05) 下的平均 mAP 结果. 由表 3 可知, 随着信噪比的提高, 多个 AP 指标和召回率不断提升, 参数估计误差不断降低. 当信噪比大于等于 10 dB 时, 检测召回率指标超过 99%, 充分说明高信噪比下 DETR\_S 的良好检测效果, 当信噪比大于等于 0 dB 时, 平均精度 mAP@0.50:0.95 和 mAP@0.75 指标分别达到 67% 和 93% 以上. 当信噪比下降至 -10 dB 的条件下, 召回率依然能够保持在 80% 以上, 说明 DETR\_S 在低信噪比条件下依然能够保持较好的信号检测效果. 当信噪比降低至 -15 dB 时, 信号几乎完全被噪声淹没, 网络难以捕捉信号特征.

进一步分析不同信噪比下 DETR\_S 对频谱具体区域特征的关注情况, DETR\_S 较好的检测性能很大程度上归因于有效地将多头自注意力机制引入信号频谱检测任务中, 有效的频谱自注意力关联应该让网络能够自动聚焦于需要关注的区域, 因此, 对不同信噪比下 DETR\_S 的检测结果进行直观展示, 同时对 DETR\_S 解码器最后一层的输出进行可视化热图分析, 观察复杂电磁环境下网络重点关注的区域, 可视化分析结果如图 9 和图 10 所示.

图 9 和图 10 分别展示了低信噪比和高信噪比下的 DETR\_S 检测的可视化结果, 从上往下依次表示信号真实标签框、注意力可视化热图、DETR\_S 检测框结果. 绿色框表示真实的信号位置, 红色框表示检测结果, 而热图中的亮区显示了训练后网络的关键焦点. 在高信噪

比下, 如图 10(a)~图 10(c) 所示, 当信噪比为 0、5、10 dB 时, 热图中的高亮区域集中在信号尖峰和旁瓣上, 网络能够以信号频谱峰值为重点关注目标. 随着信噪比的降低, 热图的高亮区域逐渐分散, 网络将注意力重点转移到信号的尖峰和周围区域的包络上, 如图 9(a)~图 9(c) 所示.

信号的检测结果直观地展示了 DETR\_S 在不同信噪比下的检测性能, 在高信噪比下, 输出的检测框和真实信号标签框基本一致, DETR\_S 能够很好地对卫星信号进行检测和重点参数估计. 这归因于信号重构模块对 DETR\_S 解码器的约束, 使得网络能够对频谱图进行精细化特征提取和检测框输出. 随着信噪比不断降低, 检测框相较于真实信号标签框呈现包含的趋势, 与表 3 中的结果相对应, 各 AP 指标随着信噪比不断降低. 总的来说, DETR\_S 能够较好地对待信噪比 -10 dB 以上的信号实现检测.

为验证所提方法的优越性. 通过将本文所提 DETR\_S 模型和当前代表性的目标检测网络 YOLOv5 以及 Faster R-CNN 共 5 种算法的检测效果进行对比, 指标结果定量比较如表 4 所示. 对比方法中 YOLOv5s、YOLOv5m、YOLOv5l 分别表示 YOLOv5 最小版本、中等版本和大型版本, 通过召回率、AP 等指标可以看出, 随着模型参数数量的增大, 召回率、AP、AP50、AP75 等指标的精度也逐步提升. Faster R-CNN (MobileNetv2, Mv2) 和 Faster R-CNN (R50) 分别表示主干特征提取网络采用 MobileNetv2 和 ResNet50 的 Faster R-CNN 模型. 由表 4 可知, 相较于 Faster R-CNN 和 YOLOv5 系列模型, DETR\_S 在召回率和多个 AP (mAP@0.5:0.95、mAP@0.50、

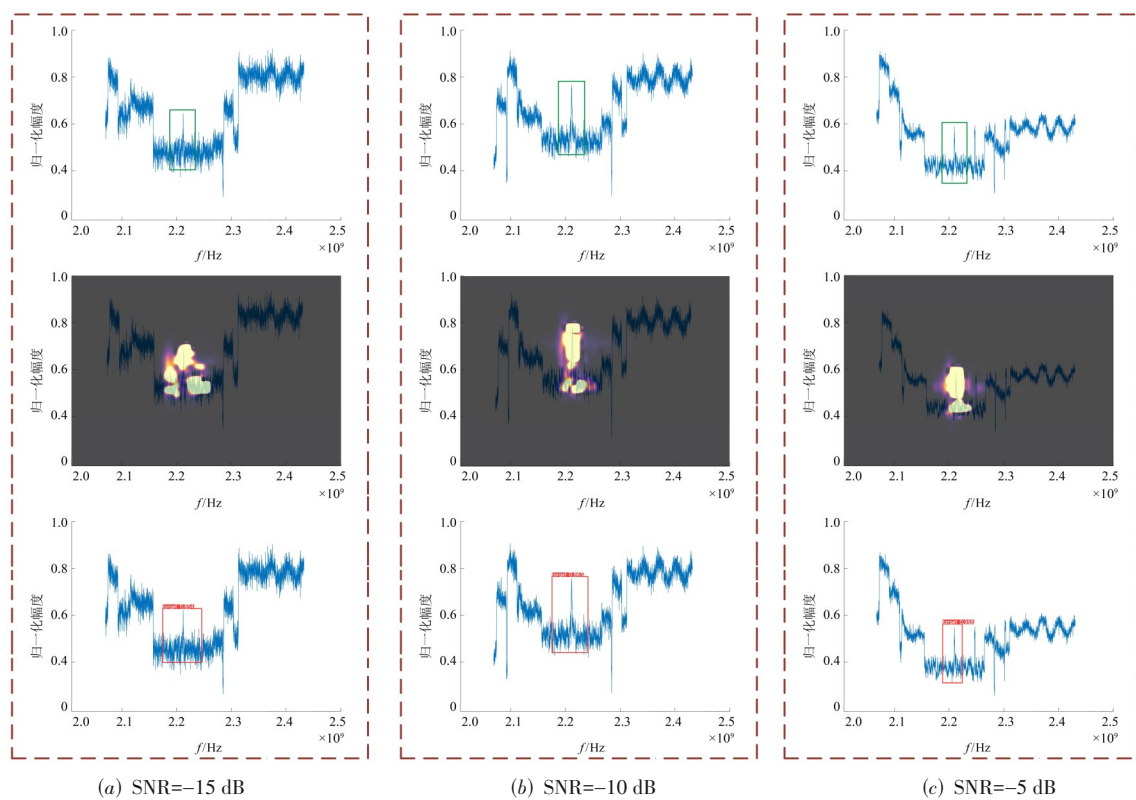


图9 -15~-5 dB下信号可视化检测结果

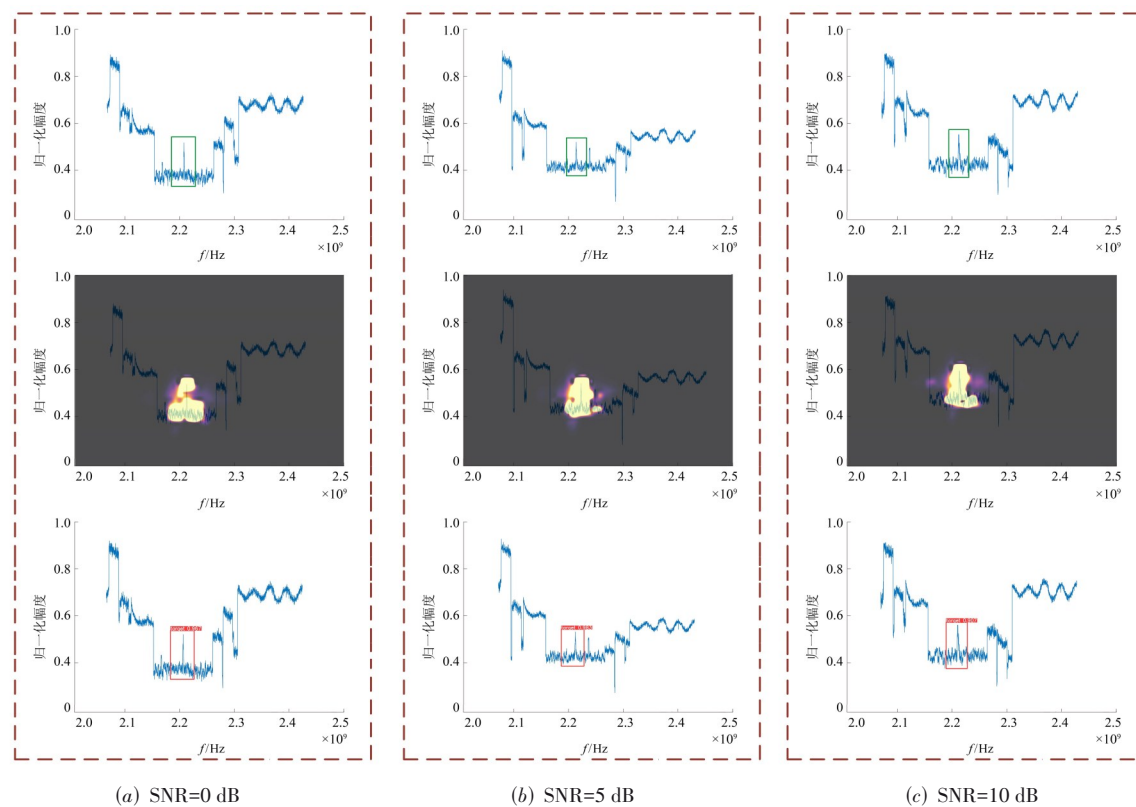


图10 0~10 dB下信号可视化检测结果

mAP@0.75)指标上分别达到了最优,在3个AP指标上,相较于Faster R-CNN(Mv2)模型,性能分别提升了8.08、1.37和7.60个百分点.与当前目标检测最流行的YOLOv5系列模型(YOLOv5s、m、l)相比,DETR\_S在3个AP指标上分别取得了1.81~7.01个百分点、0.49~1.02个百分点,以及2.79~5.40个百分点的性能提升.在参数估计误差上,考虑信号的载频和码速率的估计误差,DETR\_S算法同样表现出色,估计误差指标相较于其他算法减少了0.001~0.023.这意味着DETR\_S在信号参数的准确性上也达到了更高的水平.综合以上各项性能指标,DETR\_S算法的信号检测效果最好,充分验证了本文所提算法的有效性. DETR\_S算法虽然在召回率上低于YOLOv5l模型0.57个百分点,但AP、AP50、AP75等指标的精度分别高于YOLOv5l模型1.81、0.49和2.79个百分点.表明在召回的信号中DETR\_S的预测信号框和真实信号框重合度更高,说明YOLOv5l模型在对卫星信号高召回率的同时存在虚警概率高的问题.

表4 不同信号检测模型基于各信噪比下平均评价指标对比  
单位:%

算法名称	Recall	mAP@0.5:0.95	mAP@0.50	mAP@0.75	$M_s$
YOLOv5s	93.20	76.41	98.59	92.12	0.044
YOLOv5m	95.41	80.24	98.79	93.23	0.041
YOLOv5l	<b>95.72</b>	81.61	99.12	94.73	0.034
Faster R-CNN(Mv2)	79.13	75.34	98.24	89.92	0.049
Faster R-CNN(R50)	76.92	68.62	96.32	85.01	0.054
DETR_S No SR	94.31	81.15	98.14	94.56	0.032
DETR_S	95.15	<b>83.42</b>	<b>99.61</b>	<b>97.52</b>	<b>0.031</b>

注:加粗数据表示最优结果.

为更深入地验证本文所提方法的有效性,分析不同因素对算法影响.对信号的预处理操作、浅层特征提取模块、DETR\_S编码器与解码器的层数,以及频谱重构模块4个方面进行了消融分析.具体标记的含义

如下.

- (1)DETR\_S-1th 1D:去除DETR\_S编码器和解码器,修改浅层特征提取网络使其适配1D序列.
- (2)DETR\_S-2th 1D:去除浅层特征提取网络模块,修改DETR\_S编码器和解码器适配1D序列.
- (3)DETR\_S-3th 1D:保留所有网络模块,同时全局修改DETR\_S以适应1D序列.
- (4)DETR\_S No FE:去除浅层特征提取网络模块的DETR\_S.
- (5)DETR\_S No SR:去除信号重构模块的DETR\_S.
- (6)DETR\_S 2层:使用2层编码器-解码器的DETR\_S.
- (7)DETR\_S 4层:使用4层编码器-解码器的DETR\_S.

实验结果如表5所示,在信号的预处理阶段,输入为2D频谱图的性能整体优于输入为1D序列的情况.相较于2D输入的DETR\_S,1D输入的DETR\_S-1th、DETR\_S-2th和DETR\_S-3th在召回率指标上相差21.73、15.54和11.91个百分点,在平均准确率和参数估计精度上也大幅低于2D输入的DETR\_S.结果验证了2D频谱图中卫星信号和背景信号的差异性相较于1D序列更加明显,进一步证明预处理阶段操作的有效性.此外,DETR\_S-3th的结果要整体优于DETR\_S-1th和DETR\_S-2th,验证了浅层特征提取模块和DETR\_S编码器解码器模块联合使用的优越性.另一方面,基于图像的检测更适合卫星信号接收设备.接收端存在大量的中频数据,操作员经常直接与信号频谱的幅度数据流(随时间变化的二维频谱图)交互.基于2D频谱图的DETR\_S只要对瀑布图进行帧裁剪以进行推理检测,获得视觉结果.这种转换将问题从基于序列的回归预测转移到基于图像的检测问题.检测框的中心和坐标可以直接与载波频率和带宽等重要参数相关联.直接映射能够更加有效地帮助操作员完成检测任务和估计

表5 不同信号检测模型基于各信噪比下平均评价指标对比  
单位:%

模型名称		Recall	AP			$M_s$
1D 输入	DETR_S-1th 1D	73.42	75.74			0.120
	DETR_S-2th 1D	79.61	78.99			0.086
	DETR_S-3th 1D	83.24	84.67			0.073
模型名称		Recall	mAP@0.5:0.95	mAP@0.50	mAP@0.75	$M_s$
2D 输入	DETR_S No FE	84.51	71.21	88.46	83.03	0.053
	DETR_S No SR	94.31	81.15	98.14	94.56	0.032
	DETR_S 2层	73.02	68.34	86.16	80.74	0.089
	DETR_S 4层	92.26	76.51	94.52	92.27	0.046
	DETR_S	<b>95.15</b>	<b>83.42</b>	<b>99.61</b>	<b>97.52</b>	<b>0.031</b>

注:加粗数据表示最优结果.

参数.

编码器和解码器的层数对模型性能和能力有显著影响. 随着层数增加, 模型的训练难度也会提升, 经过验证, 6层编码器和解码器对于 DETR\_S 来说能够较好地完成任务, 使用4层编码器和解码器的 DETR\_S 检测效果略有降低, 召回率降低 2.89 个百分点, 3 个 AP 指标分别降低 6.91、5.09 和 5.25 个百分点. 而仅使用 2 层编码器和解码器的 DETR\_S 性能下降较为严重, 说明需要一定层数的模型才能使其捕捉较复杂的信号频谱特征.

DETR\_S No FE 的检测指标显示, 去除了浅层特征提取网络模块的检测性能显著降低, 这展示出和 1D 输入相似的结论, 即前置浅层特征网络的必要性. 浅层特征提取模块得到的空间特征有助于 DETR\_S 编码器解码器模块建立特征之间的频谱关联性, 以更细粒度捕获目标信号和背景信号特征的差异性. 而融入 SR 模块的 DETR\_S 在关键检测指标上实现显著提升, 3 个 AP 指标上分别提高 2.27、1.47 和 2.96 个百分点. 这说明引入信号重构模块, DETR\_S 模型在特征提取阶段能够显著增强对高质量频谱特征的捕获能力. 与未采用信号重构模块的模型相比, 这一显著的性能提升反映了在加入信号重构模块后, 模型预测的信号框与真实信号框之间的重叠度显著增加, 验证了所提信号重构模块是提升 DETR\_S 模型检测性能的有效手段.

## 5 结束语

针对非合作场景接收条件受限的情况下侦察方难以获取先验知识和完整的信号信息, 复杂电磁环境下卫星信号检测结果易受强背景信号干扰等问题, 本文提出一种端到端的卫星信号检测算法 DETR\_S. 实验结果表明, DETR\_S 在仅使用卫星信号频谱图作为输入的条件下, 能够对强背景干扰情况下信噪比不低于 -15 dB 的卫星信号实现有效检测, 与目标检测代表性网络 (Faster R-CNN、YOLOv5) 相比, DETR\_S 不仅在多个 AP 指标上取得了更好的结果, 并且在处理流程上无需特别依赖先验知识的 NMS 的后处理部分, 简化利用深度神经网络检测信号的步骤, 提高网络检测性能.

在未来的工作中, 研究将考虑 DETR\_S 的实际部署问题, 由于在 DETR\_S 的编码器和解码器模块使用了多头注意力机制帮助网络实现长距离频谱关联, 相较于单纯使用卷积神经网络的结构, 在运算时间和开销方面有一定的增加, 实施部署中通常需要高性能处理设备. 后续在保证检测性能的前提下尽可能地减少网络的可学习参数量, 通过网络剪枝或轻量化注意力机制的方式降低资源开销, 进一步提升实时检测能力.

## 参考文献

- [1] ZHANG T, ZHANG X, YANG Q. Passive location for 5G OFDM radiation sources based on virtual synthetic aperture[J]. *Remote Sensing*, 2023, 15(6): 1695.
- [2] CHETTRI L, BERA R. A comprehensive survey on Internet of Things (IoT) toward 5G wireless systems[J]. *IEEE Internet of Things Journal*, 2020, 7(1): 16-32.
- [3] 陈昊, 乔凯, 童业平. 一种卫星通信的突发传输同步算法[J]. *电子学报*, 2023, 51(4): 907-913.  
CHEN H, QIAO K, TONG Y P. A burst transmission synchronization algorithm for satellite communication[J]. *Acta Electronica Sinica*, 2023, 51(4): 907-913. (in Chinese)
- [4] 高锐. 复杂电磁环境下的信号检测技术研究[D]. 西安: 西安电子科技大学, 2015.  
GAO R. Research on Signal Detection Technology in Complex Electromagnetic Environment[D]. Xi'an: Xidian University, 2015. (in Chinese)
- [5] SUN J Y, WANG Y Q, SHEN Y Y, et al. High-precision trajectory data reconstruction for TT&C systems using LS B-spline approximation[J]. *IEEE Signal Processing Letters*, 2020, 27: 895-899.
- [6] ZHAO Y, YANG P, XIAO Y, et al. Soft-feedback time-domain turbo equalization for single-carrier generalized spatial modulation[J]. *IEEE Transactions on Vehicular Technology*, 2018, 67(10): 9421-9434.
- [7] CHEN Y F. Improved energy detector for random signals in Gaussian noise[J]. *IEEE Transactions on Wireless Communications*, 2010, 9(2): 558-563.
- [8] 何其恢, 朱立东. 一种基于双图案的卫星信号能量检测粗同步方法[J]. *电子学报*, 2022, 50(3): 524-532.  
HE Q H, ZHU L D. Double pattern based coarse synchronization method using energy detection for satellite signal[J]. *Acta Electronica Sinica*, 2022, 50(3): 524-532. (in Chinese)
- [9] ZENG Y, LIANG Y C. Eigenvalue-based spectrum sensing algorithms for cognitive radio[J]. *IEEE Transactions on Communications*, 2009, 57(6): 1784-1793.
- [10] 王泽玉, 李明, 卢云龙. 一种改进的自适应匹配滤波方法[J]. *西安电子科技大学学报*, 2018, 45(1): 12-16, 82.  
WANG Z Y, LI M, LU Y L. Modified adaptive matched filter[J]. *Journal of Xidian University*, 2018, 45(1): 12-16, 82. (in Chinese)
- [11] THEILER J, FOY B R. Effect of signal contamination in matched-filter detection of the signal on a cluttered background[J]. *IEEE Geoscience and Remote Sensing Letters*, 2006, 3(1): 98-102.

- [12] 郑作虎, 王首勇. 复杂海杂波背景下分数低阶匹配滤波检测方法[J]. 电子学报, 2016, 44(2): 319-326.  
ZHENG Z H, WANG S Y. Radar target detection method of fractional lower order matched filter in complex sea clutter background[J]. Acta Electronica Sinica, 2016, 44(2): 319-326. (in Chinese)
- [13] LUNDEN J, KASSAM S A, KOIVUNEN V. Robust non-parametric cyclic correlation-based spectrum sensing for cognitive radio[J]. IEEE Transactions on Signal Processing, 2010, 58(1): 38-52.
- [14] 张各各, 王俊, 吴日恒. 复杂环境下的循环平稳信号 DOA 估计[J]. 西安电子科技大学学报, 2015, 42(1): 91-97.  
ZHANG G G, WANG J, WU R H. Cyclostationary signal DOA estimation under complex environment[J]. Journal of Xidian University, 2015, 42(1): 91-97. (in Chinese)
- [15] HORBERT E, GARCÍA G M, FRINTROP S, et al. Sequence-level object candidates based on saliency for generic object recognition on mobile systems[C]//2015 IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2015: 127-134.
- [16] 李润东. 基于深度学习的通信信号智能盲检测与识别技术研究[D]. 成都: 电子科技大学, 2021.  
LI R D. Research on Intelligent Blind Detection and Recognition of Communication Signals Based on Deep Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2021. (in Chinese)
- [17] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 580-587.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 346-361.
- [19] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2015: 1440-1448.
- [20] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [21] DAI J F, LI Y, HE K M, et al. R-FCN: Object detection via region-based fully convolutional networks[EB/OL]. (2023-12-11)[2025-05-12]. <https://arxiv.org/abs/1605.06409v3>.
- [22] SERMANET P, EIGEN D, ZHANG X, et al. Overfeat: Integrated recognition, localization and detection using convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 3456-3465.
- [23] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 779-788.
- [24] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 6517-6525.
- [25] REDMON J, FARHADI A. YOLOV3: An incremental improvement[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7263-7271.
- [26] WU B C, WAN A, IANDOLA F, et al. SqueezeDet: Unified, small, low power fully convolutional neural networks for real-time object detection for autonomous driving[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2017: 446-454.
- [27] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot Multibox Detector[M]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.
- [28] LI W H, WANG K R, YOU L, et al. A new deep learning framework for HF signal detection in wideband spectrogram[J]. IEEE Signal Processing Letters, 2022, 29: 1342-1346.
- [29] PRASAD K N R S V, D'SOUZA K B, BHARGAVA V K. A downscaled faster-RCNN framework for signal detection and time-frequency localization in wideband RF systems[J]. IEEE Transactions on Wireless Communications, 2020, 19(7): 4847-4862.
- [30] ZHA X, PENG H, QIN X, et al. A deep learning framework for signal detection and modulation classification[J]. Sensors, 2019, 19(18): 4042.
- [31] LI R D, HU J H, LI S Q, et al. Blind detection of communication signals based on improved YOLO3[C]//2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP). Piscataway: IEEE, 2021: 424-429.
- [32] WANG D C, CHEN X N, YI H, et al. Improvement of non-maximum suppression in RGB-D object detection[J].

IEEE Access, 2019, 7: 1-7.

- [33] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[M]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 213-229.

- [34] 王利全. 数传信号的调制识别与参数估计[D]. 成都: 电子科技大学, 2020.

WANG L Q. Modulation Identification and Parameter Estimation of Digital Signal[D]. Chengdu: University of Electronic Science and Technology of China, 2020. (in Chinese)

## 作者简介



**李昱男**, 1999年11月生, 山西太原人. 西安电子科技大学电子工程学院电子信息对抗与仿真技术教育部重点实验室博士研究生. 主要研究方向为认知无线电、深度学习、信号检测与调制识别.  
E-mail: yli\_1999@stu.xidian.edu.cn



**王晓宁** 女, 1998年11月生, 山东省烟台人. 2024年毕业于西安电子科技大学工程学院. 主要研究方向为电子侦察以及卫星通信信号处理.  
E-mail: wxn20170926@163.com



**石晓然** 女, 1987年7月生, 河北石家庄人. 西安电子科技大学电子工程学院电子信息对抗与仿真技术教育部重点实验室副教授. 主要研究方向为电子侦察与智能信号处理等.  
E-mail: xrshi@xidian.edu.cn



**周峰** 男, 1980年1月生, 河南通许人. 二级教授, 博导, 西安电子科技大学空间科学与技术学院院长. 主要研究方向为电子对抗、空间电子信息系统. 入选国家级人才支持计划, 在国内外相关领域主流期刊和会议上发表论文200余篇, 授权发明专利50余项. 获国家技术发明二等奖1项、省部级科技奖励一等奖4项. 中国电子学会会员编号:E190012834F.  
E-mail: fzhou@mail.xidian.edu.cn



**苗昊倩** 女, 2000年2月生, 河北邯郸人. 西安电子科技大学电子工程学院电子信息对抗与仿真技术教育部重点实验室硕士研究生. 主要研究方向为电子侦察以及通信信号处理.  
E-mail: snowwhite@uestc.edu.cn