



## 基于 Nyquist 折叠接收和 CBDNet-YOLOv5 的非合作信号超宽带感知与载频测量

袁子杰<sup>1</sup>, 仇兆扬<sup>1</sup>, 王佩<sup>2</sup>, 李博文<sup>1</sup>, 汤嘉城<sup>1</sup>

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 南京电子设备研究所, 江苏 南京 210016)

**摘要:** 随着电磁频谱使用频段的不断拓宽, 非合作感知系统的宽带感知能力受到挑战。Nyquist 折叠接收机 (Nyquist folding receiver, NYFR) 具备超宽带感知能力, 输出信号重构依赖 Nyquist 区 (Nyquist zone, NZ) 标号估计, 但是, 同时到达多个非合作调制信号时, 现有 NZ 标号估计算法难以具备泛化能力。针对上述问题, 提出了基于卷积盲去噪网络 (convolutional blind denoising network, CBDNet) 和 YOLOv5 的 NYFR 输出信号参数估计算法, 将 NYFR 输出信号转换为时频图像, 通过 CBDNet 重构信号时频特征, 再利用 YOLOv5 估计信号 NZ 标号, 最后根据 NZ 标号重构信号频谱并计算被感知原信号的未知频率。仿真结果表明, 该方法能以 2 GHz 的采样率完成 0~20 GHz 频段内多种调制信号的频谱感知和载频估计, 且在频谱混叠时具有较好的感知性能, 提升了感知系统对非合作信号的泛化感知和载频估计能力。

**关键词:** 频谱感知; Nyquist 折叠接收机; Nyquist 区标号; YOLOv5

**中图分类号:** TN971

**文献标志码:** A

**doi:** 10.11959/j.issn.1000-0801.2026026

## Ultra-wideband spectrum sensing and carrier frequency estimation for non-cooperative signals based on Nyquist folding receiver and CBDNet-YOLOv5

Yuan Zijie<sup>1</sup>, Qiu Zhaoyang<sup>1</sup>, Wang Pei<sup>2</sup>, Li Bowen<sup>1</sup>, Tang Jiacheng<sup>1</sup>

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. Nanjing Electronic Equipment Research Institute, Nanjing 210016, China

**Abstract:** With the continuous expansion of the utilized electromagnetic spectrum, the wideband sensing capability of reconnaissance receivers is increasingly challenged. The Nyquist folding receiver (NYFR), characterized by its ultra-wideband sensing potential, depends on the estimation of the Nyquist zone (NZ) index to reconstruct signal. However, existing NZ index estimation algorithms fail to achieve satisfactory generalization performance for mixed inputs comprising multiple types of non-cooperative signals. Based on the convolutional blind denoising network (CBDNet) and



YOLOv5, a novel parameter estimation algorithm for NYFR output signals was proposed to solve these problems. Firstly, the output signals of the NYFR were transformed into time-frequency representations. Then, CBDNet was used to reconstruct the time-frequency features of signal, and YOLOv5 was used to estimate the corresponding NZ index. Based on the estimation results of NZ index, each signal spectrum was reconstructed, and the unknown carrier frequencies of the sensed signals were obtained. Simulation results validate the effectiveness of the algorithm approach, demonstrating its capability to sense spectrum accurately and estimate carrier frequency for a variety of modulation types from 0~20 GHz, under a sampling rate of 2 GHz. Furthermore, the method exhibits robust performance under spectrum aliasing conditions, enhancing the generalization and adaptability of the NYFR for processing non-cooperative modulated signals.

**Key words:** spectrum sensing, NYFR, NZ index, YOLOv5

## 0 引言

随着雷达技术的发展,电磁频谱中雷达信号的工作频段逐渐变宽,非合作频谱感知对瞬时带宽的需求也不断增长。非合作雷达信号感知系统中,准确感知信号频谱特性,尤其是载频信息,是提高信号截获能力、增强系统可靠性的关键<sup>[1-2]</sup>。传统宽带感知技术<sup>[3]</sup>通常将宽频带划分为多个子带,通过能量检测、循环平稳检测等算法实现窄带感知,但该方法高度依赖信号的先验信息,难以应对非合作感知中的未知信号。因此,如何在超宽带范围内有效感知非合作雷达信号成为超宽带感知技术的重要研究方向。

模数转换器(analog-to-digital converter, ADC)是将电磁信号数字化的关键部件,直接影响接收机超宽带感知性能。Nyquist采样定理要求ADC采样频率高于信号最高频率的两倍,这对超宽带感知任务中的ADC提出了很高的硬件性能要求。为提高接收机宽带接收能力,以往研究提出了多种并行采样结构,但存在对定时误差敏感和结构实现复杂等问题<sup>[4-5]</sup>。Liu等<sup>[6]</sup>提出了Nyquist折叠接收机(Nyquist folding receiver, NYFR),在保证较低结构复杂度的同时,能以低于Nyquist频率采样并重构信号。信号经NYFR折叠后处于较低频率区间,同时获得与输入信号Nyquist区(Nyquist zone, NZ)有关的频率信息。为从被折叠的NYFR

输出信号中重构原信号,需要进行NZ标号估计。

近年来,国内外学者围绕NYFR架构和NZ标号估计算法进行了大量研究。国内研究方面,文献[7]使用Bessel函数特性估计频移键控(frequency-shift keying, FSK)信号NZ标号;文献[8]提出双天线双通道结构,并给出Bessel峰值匹配算法;文献[9]通过瞬时自相关消除同步Nyquist折叠接收机接收信号调制方式干扰,提高了线性调频(linear frequency modulation, LFM)信号NZ标号估计的准确率;文献[10]分析了解模糊问题、频谱展宽问题和频谱混叠问题并分别提出改进;文献[11]将NYFR部署在无人机群,通过多通道协作重构算法从欠采样数据中重构原始频谱;文献[12]改进了基于随机采样一致性和分数阶傅里叶变换的LFM信号NZ标号估计算法,通过优化参数提高NZ标号估计性能;文献[13]建立了本地振荡器(local oscillator, LO)信号性能评价指标,证明优化LO信号可增强系统的抗噪声性能和宽带处理能力。国外研究方面,文献[14]针对折叠后信号频谱反转、幅度不匹配等问题修改调制信号并使用修正矩阵减少了重建误差;文献[15]使用卷积神经网络(convolutional neural network, CNN)学习折叠信号频谱特征,实现NZ标号估计和解混叠。既有研究多聚焦于提高NYFR接收单个或少量特定调制类型信号时NZ标号估计性能,但对其他调制类型的泛化能力有

限。例如，文献[9, 12]关注输入单个 LFM 信号，但对多信号和其他调制类型不适用；文献[7]关注 FSK 信号，但对其他调制类型缺少讨论。当输入信号超出预设调制类型集合时，算法泛化能力不足导致 NZ 标号估计效果下降。在非合作雷达信号感知场景中，接收机通常会收到来自多个发射源的不同信号，且缺乏信号到达数量、调制类型等先验信息，对 NZ 标号估计算法的泛化性要求较高。因此，如何在 NYFR 接收多种调制信号条件下实现泛化性强的信号参数估计，尤其是 NZ 标号估计，成为亟待解决的问题。

针对 NYFR 接收不同调制类型的非合作雷达信号时，NZ 标号估计算法泛化性不佳的问题，本文提出了一种基于卷积盲去噪网络（convolutional blind denoising network, CBDNet）<sup>[16]</sup> 和 YOLOv5<sup>[17]</sup> 的 NYFR 输出信号参数估计方法。该方法通过 CBDNet 滤除无关时频特征，增强系统对未知信号的适应能力，使用 YOLOv5 锚框输出关键参数。经算法流程估计 NZ 标号后，再利用 NZ 标号重构信号频谱和真实频率，从而以单片低速 ADC 实现超宽带感知与载频测量。相较现有方法，该方法在接收多种调制类型非合作信号场景中，有更高的 NZ 标号估计准确率和载频估计精度，提高了 NYFR 超宽带接收多种不同调制信号时的参数估计性能。

## 1 NYFR 输出信号模型及模型驱动的参数估计

### 1.1 NYFR 架构

NYFR 架构的核心思想是通过非均匀采样，将输入信号载频信息转化为折叠输出信号频率信息，后续从频率中提取载频信息用于信号重构。NYFR 系统结构<sup>[18]</sup>如图 1 所示。

图 1 中，NYFR 输入信号  $x(t)$  首先通过宽带预选滤波器  $H(\omega)$ ，筛选所需的感知频段范围内

的信号。随后，NYFR 使用过零上升沿（zero crossing rate, ZCR）控制射频（radio frequency, RF）前端采样时钟并产生非均匀冲激串，与经过宽带滤波器  $H(\omega)$  筛选后的信号混频。混频后信号被折叠至频域上宽度与接收机采样率  $f_s$  相同的区间内，即 NZ 内。其中，第  $i$  个 NZ 频率范围为  $-k \cdot f_s/2 \sim k \cdot f_s/2$ ，记作 NZ $i$ 。在此过程中，NYFR 输出信号折叠后位于 NZ0。最终，经内插滤波器  $F(\omega)$  得输出信号  $y(t)$ ，通过单片低速 ADC 采样后进行信息恢复，完成超宽带接收与处理。




图 1 NYFR 系统结构

假设输入 NYFR 的信号  $x(t)$  为：

$$x(t) = e^{2\pi f_c t + \varphi_c(t)} + w(t) \quad (1)$$

其中， $f_c$  表示输入信号的载波频率， $\varphi_c(t)$  表示输入信号的相位， $w(t)$  是加性高斯白噪声。NYFR 利用 ZCR 控制 RF 采样时钟，产生非均匀冲激串  $p(t)$ ：

$$p(t) = \sum_{k=-\infty}^{\infty} \delta[m(t) - 2\pi k] \quad (2)$$

其中， $m(t) = 2\pi f_s t + \theta_{LO}(t) + \varphi_{LO}$ ， $\theta_{LO}(t)$  是 RF 的 LO 的调制部分， $\varphi_{LO}$  是 LO 的初始相位。经宽带滤波的输入信号与非均匀冲激串混频，折叠至 NZ0。为重构输入信号，须利用混频引入的时频特征估计 NZ 标号。NYFR 原型结构采用正弦调频（sinusoidal frequency modulation, SFM）LO，其输出信号重构依赖带宽估计。因极大瞬时带宽，NYFR 可感知超宽频段内多个同时到达的雷达信号。若信号折叠后频率接近，则可能发生频谱混叠。当折叠后频率相同时，信号频谱完全混叠，此时带宽难以直接估计，导致信号重构过程更加复杂。



周期线性调频 (periodic linear frequency modulation, PLFM) LO<sup>[19]</sup>把NZ信息转为调制斜率参数。相比SFM,其LO使NYFR输出信号频谱混叠时有更多的差异性特征,可实现频谱完全混叠时的NZ标号估计,因此本文基于该LO调制进行分析,其表达式为:

$$\theta_{\text{PLFM}}(t) = \pi\mu_0 \text{mod}(t, t_{\text{LO}})^2 \quad (3)$$

其中,  $\mu_0$ 表示线性调制斜率,  $t_{\text{LO}}$ 表示每个调制周期时间长度。输入信号经混频和内插滤波得到输出信号为:

$$y(t) = e^{j2\pi(f_c - f_s K_H)t + j\phi_c(t) - jK_H\pi\mu_0 \text{mod}(t, t_{\text{LO}})^2} + \tilde{w}(t) \quad (4)$$

其中,  $f_c - f_s K_H$ 为输出信号的中心频率,记作  $f_{\text{fold}}$ ,  $K_H = \text{round}(f_c/f_s)$ 表示输入信号NZ标号(当  $K_H = i$ 时,对应输入信号分布于NZ*i*),  $\text{round}$ 表示四舍五入取整操作,  $\tilde{w}(t)$ 是经采样的噪声。经NYFR后信号被折叠至低频,同时包含LO的调制成分,此时利用LO调制特性估计信号NZ标号并消除LO调制可得信号频谱,再测得信号折叠频率  $\hat{f}_{\text{fold}}$ ,根据:

$$\hat{f}_c = \hat{f}_{\text{fold}} + \hat{K}_H f_s \quad (5)$$

其中,  $\hat{K}_H$ 是估计的信号NZ标号,可得信号真实频率  $\hat{f}_c$ ,实现雷达信号的超宽带频谱感知与频率测量。

## 1.2 信号模型

为构建具有代表性的信号模型,本文主要关注在雷达系统广泛使用的单脉冲(mono-pulse, MP)、相位编码(phase-shift keying, PSK)、LFM、FSK这4类调制方式<sup>[20]</sup>。上述输入信号调制方式,覆盖了雷达信号存在的相位跳变、频率连续变化和频率跳变,具有较好的调制类型普适性。为简化模型,假设信号和LO的初相为0,得到4类信号表达式为<sup>[21]</sup>:

$$y_{\text{MP}}(t) = A e^{j2\pi(f_c - K_H f_s)t - jK_H\pi\mu_0 \text{mod}(t, t_{\text{LO}})^2} + \tilde{w}(t) \quad (6)$$

$$y_{\text{PSK}}(t) = A e^{j2\pi(f_c - K_H f_s)t + j\phi(t) - jK_H\pi\mu_0 \text{mod}(t, t_{\text{LO}})^2} + \tilde{w}(t) \quad (7)$$

$$y_{\text{LFM}}(t) = A e^{j2\pi(f_c - K_H f_s)t + j\pi\mu^2 t - jK_H\pi\mu_0 \text{mod}(t, t_{\text{LO}})^2} + \tilde{w}(t) \quad (8)$$

$$y_{\text{FSK}}(t) = \frac{2\pi A}{T_c} e^{j2\pi[f_c(t) - K_{\text{HP}} f_s]t - jK_{\text{HP}}\pi\mu_0 \text{mod}(t, T_{\text{LO}})^2} + \tilde{w}(t), f_c(t) = \begin{cases} f_{c1}, t \in [t_0, t_1) \\ f_{c2}, t \in [t_1, t_2) \\ \dots \\ f_{cp}, t \in [t_{p-1}, t_p) \end{cases} \quad (9)$$

其中,  $A$ 表示信号幅度;式(7)中,  $\phi(t)$ 表示调制相位;式(8)中,  $\mu$ 表示LFM调制斜率;式(9)中,  $T_c$ 表示码宽,  $K_{\text{HP}}$ 表示信号载频  $f_{cp}$ 对应的NZ标号。选取二相编码(binary phase-shift keying, BPSK)与二进制频移键控(binary frequency-shift keying, BFSK)分别作为PSK与FSK信号的代表进行分析。时频域上,输入不同调制信号时NYFR输出信号时频图如图2所示。




图2 输入不同调制信号时NYFR输出信号时频图

图2中4种时频图具有输入信号与LO调制方式融合的复合调制特征,其中,图2(a)信号为起始频率为  $f_c - K_H f_s$ 、调制斜率为  $-K_H\mu_0 \text{mod}(t, t_{\text{LO}})$ 的周期线性调频信号;图2(b)信号的各LO周期起始频率以调制斜率  $\mu$ 随时间变化;图2(c)信号引入了二相位突变点;图2(d)信号具有多个

频率跳变点。上述信号经NYFR处理后的共同点是经LO引入周期线性调频,其中,图2(a)、图2(c)和图2(d)信号的调制斜率为 $\alpha=-K_H\mu_0$ ,图2(b)信号的调制斜率为 $\alpha_{\text{LFM}}=\mu-K_H\mu_0$ 。因此,通过调制斜率提取 $\hat{K}_H$ ,利用 $\hat{K}_H$ 消除本振引入的频谱特性,即可重构信号频谱。随后结合起始频率估计值 $\hat{f}_{\text{fold}}$ ,可得载频估计值 $\hat{f}_c$ ,实现超宽带频谱感知与载频测量。

### 1.3 基于模型驱动的折叠信号参数估计方法

由第1.2节分析可知,估计输入信号NZ标号的核心是估计输出信号的调制斜率。解调法(demodulation, DM)是一种可用于多分量LFM信号的调制斜率估计方法<sup>[22]</sup>,核心思想是对各可能的NZ标号生成解调信号,经多通道解调并搜索最小带宽实现NZ标号估计。但该方法须进行信号同步,且算法性能受输入信号带宽影响较大。当输入信号带宽较大时,算法会失效。

为实现输入LFM信号的NZ标号估计,随机采样一致性(random sample consensus, RANSAC)优化的时频边界拟合(RANSAC-based time-frequency boundary fitting, RTFBF)<sup>[12]</sup>被提出。但该方法对瞬时频率估计精度要求高,应对调制带宽过大或输入多信号等复杂情况时,性能同样受限。

针对上述问题,采用神经网络提取信号特征并输出信号参数是一种可行的解决思路。DM与RTFBF均为模型驱动算法,频域峰值搜索高度依赖先验信号模型。接收非合作信号时,输入信号个数、调制方式和混叠情况均未知,频域成分复杂,依靠单一数学模型不足以应对非合作信号超宽带感知问题。神经网络是数据驱动算法,对信号模型先验知识需求少<sup>[3]</sup>,凭借其特征学习能力,能直接从数据中捕捉信号的内在结构<sup>[15, 23]</sup>并学习与NZ标号相关的时频特征,从而实现具有较强泛化性的NYFR输出信号参数估计。

## 2 基于CBDNet-YOLOv5的NYFR输出信号参数估计方法

近年来,基于时频特征和神经网络的信号分析得到了广泛的应用<sup>[23]</sup>。针对NYFR输出信号,可用短时傅里叶变换(short-time Fourier transform, STFT)将信号转为时频图像,输入神经网络处理。STFT表达式为:

$$\text{STFT}(t, f) = \int_{-\infty}^{\infty} y(\tau)g(\tau-t)e^{-j2\pi f\tau}d\tau \quad (10)$$

其中, $\tau$ 为时延, $g(\tau-t)$ 是以时间 $t$ 为中心的窗函数, $f$ 是频率分量,STFT( $t, f$ )是时频变换结果。变换后,一维数字信号转为二维时频分布,可利用神经网络提取时频图像特征。

时频图中,噪声的存在会破坏时频信息,导致信号特征弱化,降低特征的可识别性。CBDNet是一种降噪神经网络,通过残差学习实现图像盲去噪。时频图经CBDNet处理后,滤除部分噪声和无关调制特征,强化信号自身特征,从而重构关键时频特征。YOLOv5是一种目标检测神经网络,根据输入图像提取特征并输出目标信号NZ标号、时频能量聚集位置等信息,实现NYFR输出信号参数估计。二者结合可减弱噪声与无关特征对NYFR输出信号参数估计的影响,提高算法的泛化能力。

基于CBDNet-YOLOv5的NYFR输出信号参数估计流程如图3所示。图3中,NYFR输出信号通过STFT转为折叠信号时频图像训练集,用训练集预训练CBDNet,完成后输出去噪图像用于YOLOv5训练,得到预训练模型。在非合作信号接收处理阶段,通过STFT将NYFR输出信号转化为时频图像,经CBDNet盲去噪重构信号特征。将去噪图像输入YOLOv5神经网络得到目标NZ标号和能量聚集区,最后结合输出信号处理数据,重构信号频谱并估计输入信号的真实频率,以单片低速ADC完成超宽带感知和载频测量。

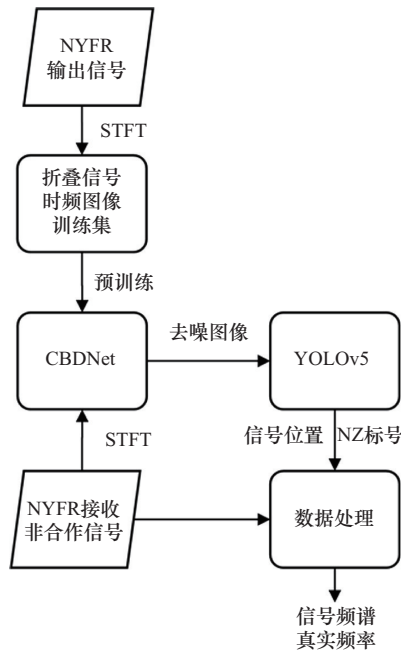


图3 基于CBDNet-YOLOv5的NYFR输出信号参数估计流程

## 2.1 CBDNet结构

CBDNet<sup>[16]</sup>是一种基于深度学习的盲去噪模型，能抑制时频图像中的噪声、重构信号特征以提高算法稳定性。CBDNet神经网络结构如图4所示。




图4 CBDNet神经网络结构

图4中，CBDNet由用于噪声估计的全卷积网络（fully convolutional network, FCN）和用于去噪的UNet<sup>[24]</sup>构成。FCN由4层卷积层组成，卷积层之间使用ReLU激活函数，输入含噪图像，输出3通道噪声估计结果。FCN输出的噪声估计图与原始含噪图像拼接后输入UNet。UNet结合对称跳跃连接、分支卷积和转置卷积提高感受野，各卷积层间以ReLU连接，输入噪声估计图和含噪图像，经残差连接去噪，最后输出去噪图

像。去噪图像中重建了被噪声破坏的时频特征，随后去噪图像输入YOLOv5进一步完成特征提取和NZ标号估计。

## 2.2 YOLOv5网络结构

YOLOv5<sup>[17]</sup>是一种目标识别神经网络模型，在本文中用于检测时频图中信号能量聚集区，输出NZ标号和置信度，YOLOv5神经网络结构如图5所示。

图5中，YOLOv5神经网络由图像输入层、主干网络、颈部网络和检测头构成<sup>[17]</sup>。输入层接收分辨率为 $640 \times 640$ （单位为像素）的3通道时频图，通过Mosaic数据增强<sup>[24]</sup>、MixUp数据增强<sup>[24]</sup>等方式实现数据集扩充。

主干网络由注意力（Focus）模块、卷积-批归一化-激活函数（convolution-batchnorm-SiLU, CBS）模块、空间金字塔池化（spatial pyramid pooling, SPP）模块和C3模块构成，主要负责特征提取。Focus模块通过切片（Slice）降低特征提取计算量。CBS是YOLOv5标准卷积层，由基础卷积层（Conv）、批归一化层（BatchNorm）和SiLU激活函数组成，用于提取特征。C3模块通过双分支结构平衡深浅层次特征，减少特征传递过程中的信息衰减。SPP模块通过组合最大池化窗（Maxpool）提取多尺度特征，从而增大模型感受野。时频图经多层CBS、C3特征提取后，特征图尺寸逐渐变小，通道数逐渐变多，最终向颈部网络输出 $80 \times 80 \times 256$ 、 $40 \times 40 \times 512$ 和 $20 \times 20 \times 1024$ 这3种尺度的特征图。

颈部网络接收主干网络输出的特征图，逐级上采样（Upsample）并与高层特征拼接（Concat），通过CBS和C3模块实现下采样。随后拼接不同层级特征图以实现特征融合，增强模型泛化能力，最终同样向检测头输出3种尺度的特征图。

检测头由 $1 \times 1$ 卷积层和锚框计算层（Head）组成，负责NZ标号估计和信号定位。卷积层将特征图转为NZ标号、置信度和边界框等参数，Head根据参数生成目标检测框。检测框经非极大

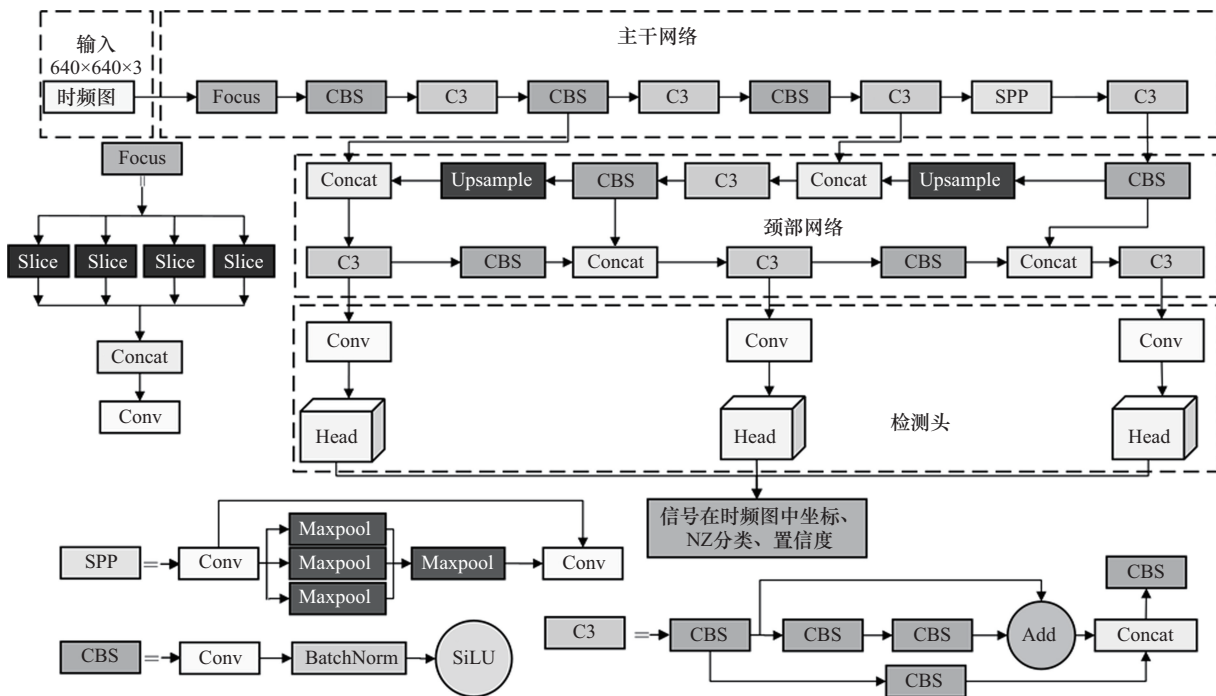


图5 YOLOv5神经网络结构

值抑制 (non-maximum suppression, NMS) 筛选高置信度候选框, 得到YOLOv5的最终输出结果。输出结果中包含时频图能量聚集区坐标、NZ标号信息, 处理后得到信号频谱和载频估计值。

### 2.3 基于CBDNet-YOLOV5的NYFR输出信号参数估计

考虑训练耗时, 选用参数量较小的YOLOv5s作为研究模型。本文提出基于CBDNet-YOLOv5的参数估计方法对NYFR输出信号处理包含以下过程。

#### (1) 数据增强

对NYFR输出信号进行STFT, 得到信号时

频图 $y_{STFT}(t, f)$ , 其中, NZ标号信息包含于时频图像斜率中。时频图输入CBDNet后经FCN得到噪声估计结果 $\hat{\sigma}(t, f) = F_E[y_{STFT}(t, f); W_E]$ , 其中,  $W_E$ 表示FCN参数, 随模型训练过程动态优化。随后去噪网络UNet将含噪图像和噪声估计结果作为输入, 输出去噪图像 $\hat{x}(t, f) = F_D[y_{STFT}(t, f), \hat{\sigma}(t, f); W_D]$ , 其中,  $W_D$ 是UNet的参数。CBDNet去噪过程如图6所示, 为CBDNet在信噪比(signal-to-noise ratio, SNR)为-8 dB时的去噪过程, 依次为 $y_{STFT}(t, f)$ 、 $\hat{\sigma}(t, f)$ 和 $\hat{x}(t, f)$ 。

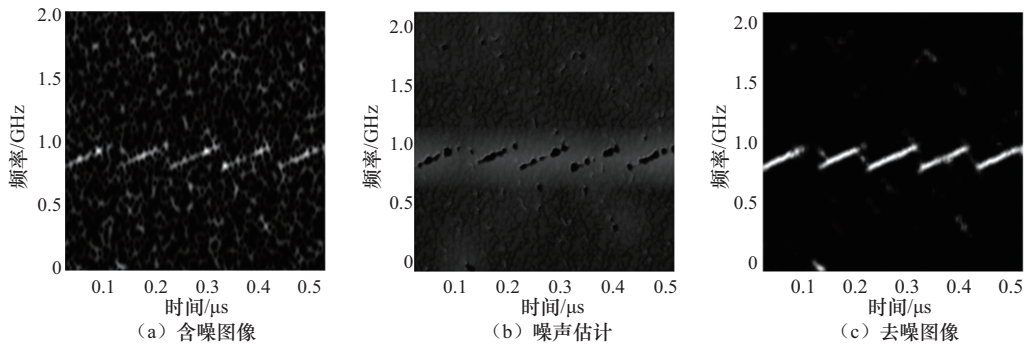


图6 CBDNet去噪过程



图6 (a) 中噪声导致图中信号时频结构不清晰, 影响后续感知与分析。图6 (b) 是FCN输出噪声估计结果, 将其与图6 (a) 所示图像输入UNet, 得到图6 (c)。图6 (c) 中信号特征被重构, 同时背景噪声受到抑制。可见, 通过CBDNet可减少噪声对估计结果的干扰, 增强时频图中信号的分布特征。

去噪后图像进入YOLOv5输入层, 经Mosaic拼接和MixUp融合实现数据增强。Mosaic拼接生成随机交叉点 $(c_t, c_f)$ 并沿交叉点拼接图像, 表示为:

$$\hat{\mathbf{x}}_{\text{Mosaic}}(t, f) = \begin{cases} \hat{\mathbf{x}}_1(t, f), t \leq c_t, f \leq c_f \\ \hat{\mathbf{x}}_2(t - c_t, f), t > c_t, f \leq c_f \\ \hat{\mathbf{x}}_3(t, f - c_f), t \leq c_t, f > c_f \\ \hat{\mathbf{x}}_4(t - c_t, f - c_f), t > c_t, f > c_f \end{cases} \quad (11)$$

其中,  $\hat{\mathbf{x}}_q(t, f)$ ,  $q \in \{1, 2, 3, 4\}$  是经去噪的4张图像。MixUp将图片加权线性叠加, 可表示为:

$$\hat{\mathbf{x}}_{\text{MixUp}}(t, f) = \lambda \cdot \hat{\mathbf{x}}_1(t, f) + (1 - \lambda) \cdot \hat{\mathbf{x}}_2(t, f) \quad (12)$$

其中,  $\lambda \in [0, 1]$  表示融合比例。通过Mosaic拼接和MixUp, 加强模型在输入多信号等复杂情况下的表现。

## (2) 特征提取

由输入层扩充的数据进入主干网络, Focus模块将输入图像以行列奇偶方式拆分成4个等尺度子图, 沿通道维度拼接, 再使用 $3 \times 3$ 卷积运算扩充通道。输入尺寸 $640 \times 640 \times 3$ 的时频图经Focus模块后被拆分为 $320 \times 320 \times 64$ 的子图像, 斜率信息保留, 分辨率下降, 在减少浮点运算次数的同时增加了计算速度。

由Focus模块切分的数据经多层CBS、C3模块和SPP模块, 提取不同深度时频特征后, 得到不同深度的特征图, 随后各层特征图在颈部网络通过上采样恢复尺寸, 再拼接融合。最终, 颈部网络向检测头输出多尺度特征图, 为检测头计算目标置信度、能量聚集区和NZ标号等信息提供数据来源。

## (3) 频谱重构与载频测量

颈部网络输出特征图传入检测头, 通过 $1 \times 1$ 卷积通道变换得到不同尺度的检测输出结果。根据检测输出结果计算网格坐标并映射回原图, 使用NMS去除冗余目标框后, 得到最终的信号预测框为:

$$\text{Output} \in \mathbf{R}^{\text{BS} \times \text{AN}_{\text{total}} \times (\hat{x}, \hat{y}, \hat{h}, \hat{w}, p_{\text{obj}}, p_{\text{cls}}^{\text{NZ0}}, p_{\text{cls}}^{\text{NZ1}}, \dots, p_{\text{cls}}^{\text{NZi}})} \quad (13)$$

其中, BS是图片数量,  $\text{AN}_{\text{total}}$ 是经NMS后的总预测框数,  $\hat{x}$ 、 $\hat{y}$ 、 $\hat{h}$ 、 $\hat{w}$ 分别是目标在图像中心横向中心坐标、纵向中心坐标、高度和宽度,  $p_{\text{obj}}$ 是分类置信度,  $p_{\text{cls}}^{\text{NZi}}$ 是分类成不同NZ的概率, 该次NZ标号估计值是最大分类概率对应的NZ标号。经NZ标号估计值消除本振引入调制成分, 再给频域滤波完成折叠后信号频谱的重构与感知。 $\hat{f}_{\text{fold}}$ 由锚框坐标得出, 表示为:

$$\hat{f}_{\text{fold}} = \left( \hat{x} + \frac{\hat{h}}{2} \right) f_s \quad (14)$$

完成NZ标号与 $\hat{f}_{\text{fold}}$ 估计后, 据式(5)得载频估计值, 以单片低速ADC完成超宽带频谱感知与载频估计。

## 2.4 算法运算量分析

为全面评估算法性能, 对比了本算法与传统NZ标号估计方法的复杂度和运算量, 复杂度与运算量对比见表1。

其中,  $N_{\text{fft}}$ 、 $N_{\text{pts}}$ 、 $N_{\text{iter}}$ 和 $N_w$ 分别表示FFT点数、特征点数、迭代次数和STFT窗口长度,  $H$ 表示窗口步进。DM须11次2048点FFT以及解调相乘, RTFBF须8次128点FFT及20次距离计算, 而本算法通过窗长64点、步进3点的STFT和深度学习模型得到更高泛化性的NZ标号估计结果。尽管传统方法有更低的运算量, 但依赖信号同步、特征点准确时刻等先验知识, 且难以适应多信号、多调制等复杂场景。本算法需要算力支持, 但对先验知识不敏感, 适合部署在GPU等具有并行计算能力的现代硬件平台。

表 1 复杂度与运算量对比

| 类别   | 算法            | 参数量     | 计算复杂度   | 运算量            |
|------|---------------|---------|---|----------------|
| 传统方法 | DM            | —       | $M \times O(N_{\text{fft}} \text{lb} N_{\text{fft}})$   | 1.370 MFLOPS   |
|      | RTFBF         | —       | $N_{\text{pts}} \times O(N_{\text{fft}} \text{lb} N_{\text{fft}}) + N_{\text{iter}} \times O(N_{\text{pts}})$ | 0.038 MFLOPS   |
| 本文算法 | STFT          | —       | $(N_w/H) \times O(N_w \text{lb} N_w)$   | 1.240 MFLOPS   |
|      | CBDNet-YOLOv5 | 11.57 M | —   | 268.270 GFLOPS |

### 3 仿真实验和结果

#### 3.1 参数设置

实验训练集采用 MP、BPSK、LFM 混合信号，NYFR 的 ADC 采样率为 2 GHz，LO 调制斜率为 300 MHz/μs，调制周期为 0.2 μs。信号时长为 1 μs，载频在 0.2~20.0 GHz 范围内随机选取。其中，LFM 调制斜率为 500 MHz/μs，BPSK 采用 2~13 位巴克码随机序列。设置 SNR 范围为 -10~10 dB，步进为 2 dB 并添加高斯白噪声后，通过 STFT 生成 640×640 分辨率的时频图像。验证集为 MP 信号，SNR 范围为 -20~0 dB，其余参数与训练集一致。

使用另一组数据作为测试集，向测试集信号添加加性高斯白噪声，SNR 范围为 -20~0 dB，步进为 2 dB，各组 SNR 使用 300 条测试信号。BPSK、LFM 是常见的雷达信号调制方式，Costas-FSK<sup>[21]</sup> 有高频率动态范围和频率跳变特性，与训练集信号差异较大，可测试模型对未知信号的泛化性。测试集参数见表 2。

表 2 中，测试数据集分为单信号部分和多信号部分。测试集中 LFM 信号调制斜率为 500 MHz/μs，BPSK 信号调制 7 位巴克码，Costas-FSK 信号载频在表中所示范围以等时间间隔跳变。考虑频域不混叠与混叠情况设两组同时到达多信号测试集，各组两种频率对应两种信号类型。组 4 折叠频率相同，频谱完全混叠；组 5 调制带宽导致频谱部分混叠；组 6 折叠频率相差 0.01 GHz，频谱混叠严重。为更全面地评估模型性能，添加 DM 与 RTFBF 作为传统方法性能对比。须指出，DM 与 RTFBF 严重依赖先验信息，因此，本文为 DM 提供输入信号个数、为 RTFBF 提供输入信号个数和特征点时刻，这些信息通常在非合作场景中无法提前获取。最后，引入 AlexNet<sup>[25]</sup>、DenseNet<sup>[26]</sup>、VGGNet<sup>[27]</sup> 3 种典型的 CNN 架构网络作为神经网络性能对比。

#### 3.2 仿真结果

将训练集输入 YOLOv5s 模型训练 300 轮，通过验证集得到混淆矩阵，YOLOv5s 验证集混淆矩阵如图 7 所示。

表 2 测试集参数

| 测试集类型       | 信号组编号 | 信号类型              | $f_c/\text{GHz}$                            | NZ 标号 |
|-------------|-------|-------------------|---|-------|
| 单信号         | 1     | LFM               | 6.21  | 3     |
|             | 2     | BPSK              | 6.21  | 3     |
|             | 3     | Costas-FSK        | {4.16, 4.14, 4.22, 4.18, 4.20, 4.12}        | 2     |
| 多信号 (频谱不混叠) | 4     | BPSK + LFM        | 4.81, 14.21                                 | 2, 7  |
|             | 5     | Costas-FSK + LFM  | {4.16, 4.14, 4.22, 4.18, 4.20, 4.12}, 14.55 | 2, 7  |
|             | 6     | Costas-FSK + BPSK | {4.16, 4.14, 4.22, 4.18, 4.20, 4.12}, 14.81 | 2, 7  |
| 多信号 (频谱混叠)  | 7     | BPSK + LFM        | 4.21, 14.21                                 | 2, 7  |
|             | 8     | Costas-FSK + LFM  | {4.16, 4.14, 4.22, 4.18, 4.20, 4.12}, 14.36 | 2, 7  |
|             | 9     | Costas-FSK + BPSK | {4.16, 4.14, 4.22, 4.18, 4.20, 4.12}, 14.21 | 2, 7  |

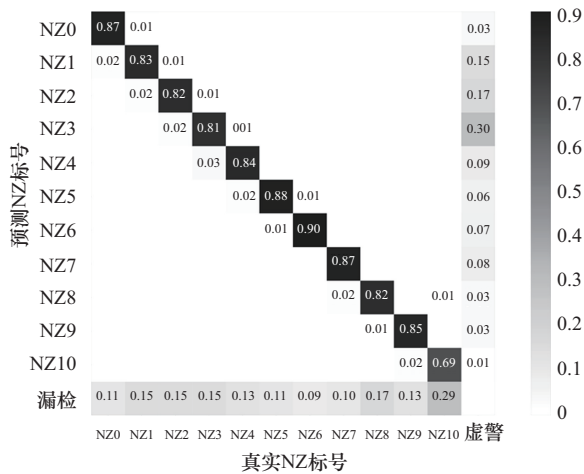


图7 YOLOv5s验证集混淆矩阵

图7中，横坐标表示验证集的真实标签，包括NZ标号和背景噪声。纵坐标表示模型的NZ标号分类结果，坐标交点的数值代表模型将真实NZ标号或噪声分类为对应NZ标号的频率。在SNR范围为-20~0 dB的验证集上，正确估计NZ标号的频率最高，表明模型能有效地区分不同NZ标号，实现NZ标号估计。

为验证引入CBDNet的有效性，设NMS阈值为0.45，在添加CBDNet前后分别使用网络处理Costas-FSK折叠输出信号，NYFR输出信号参数估计对比如图8所示。

图8中，输入信号的SNR = -2 dB，NZ标号真实值为2。图8(a)中，NMS算法抑制了冗余目标框，但受噪声影响，末段LO调制周期内出现错误目标框，影响NZ标号估计的准确性。图8(b)

加入CBDNet后，模型可重建被噪声破坏的信号时频特征，从而正确地估计该调制类型的NZ标号，提高算法性能。




图8 NYFR输出信号参数估计对比

### (1) 单信号NZ标号估计结果

定义准确率 (accuracy, ACC) 为  $ACC = T/(T+F) \times 100\%$ ，其中， $T$ 和 $F$ 分别表示使用样本估计NZ标号与真实值的一致次数和不一致次数。不同模型对单个调制信号NZ标号估计准确率结果如图9所示。

图9中，对3种不同调制信号，本文方法估计准确率达100%时所需的SNR分别为：BPSK，-10 dB；Costas-FSK，-6 dB；LFM，-10 dB。Costas-FSK信号存在频率跳变，时频谱线更短，时频特征更易受噪声破坏，且该类信号调制特征未经网络学习，导致YOLOv5性能下降。引入CBDNet后，噪声破坏的时频特征被重建，模型对该调制类型的NZ标号估计性能得到了较大的提升，提高了算法的普适性。BPSK和LFM信号特征更清晰，




图9 不同模型对单个调制信号NZ标号估计准确率结果

YOLOv5对BPSK与LFM信号的基础性能较好，因此，CBDNet的引入得到的性能提升有限。观察到DM对BPSK效果较好，但图9(c)中DM对LFM信号参数估计失败，原因是DM须估计信号带宽，而LFM信号的较大带宽导致DM带宽估计偏离预期。RTFBF虽能成功估计3组信号，但其结果易受噪声影响，估计准确率低于本算法。相比其他经典CNN类算法，本文算法同样具有更高的NZ标号估计准确率。

(2) 多信号NZ标号估计结果

真实电磁环境通常同时存在多种信号。相比单信号，多信号DM须提前确定信号个数并滤波，对滤出信号分别解调，多信号RTFBF同样须预先确定信号个数，再取对应特征点分别拟合。在单信号仿真实验中，已证明CBDNet-YOLOv5相比本文中其他CNN类算法有更高的性能，在多信号实验中，仅将本文所提方法与传统数字信号处理方法对比。使用多信号(频谱不混叠)测试集分别测试DM、RTFBF和CBDNet-YOLOv5，多信号(频谱不混叠)NZ标号估计准确率如图10所示。

图10(a)中，DM对BPSK信号的NZ标号估计准确率较高，原因是BPSK信号比其他信号带宽更窄，频域能量更集中，因此能较好地经频域滤波分离。在得知信号个数且频谱不混叠时，频谱滤波可有效地分离信号，因此，DM对窄带信号可用，但仍无法正确实现LFM信号的参数估

计。图10(b)中，RTFBF对其中3组高频信号估计失败，原因是RTFBF在调制周期内估计带宽，估计结果相比真实值偏小。受NYFR影响，高频信号在时间窗内有更大带宽，瞬时频率难以确定，而加窗引起频谱展宽进一步导致NZ标号估计失败。图10(c)中，CBDNet-YOLOv5对各信号组均可实现正确的估计，NZ标号估计的准确率达100%，所需的估计SNR比传统方法低2~6dB，且与图9相比，输入多信号对性能影响小。估计多信号时，本文所提方法表现出良好的泛化性。

输入信号经折叠输出后可发生频谱混叠，为更全面地测试模型的泛化性能，使用多信号(频谱混叠)测试集分别测试DM、RTFBF和CBDNet-YOLOv5，多信号(频谱混叠)NZ标号估计准确率如图11所示。

图11(a)中，由于频域滤波难以分离频谱混叠信号，此时DM只能完成单信号NZ标号估计，带宽较小、频谱能量集中的BPSK性能较好，宽带信号性能显著下降，无法正确估计混叠时频谱能量较分散的另一信号。图11(b)中，因频谱混叠导致特征点难以确定，RTFBF参数估计性能下降。图11(c)中，本文所提方法在频谱混叠时存在漏检，对BPSK信号参数估计性能低于DM，但SNR≥0时估计仍然准确，且对其余信号的NZ标号估计准确率更高，参数估计过程不依赖信号个数或信号同步，表现出良好的泛化能力。




图10 多信号(频谱不混叠)NZ标号估计准确率

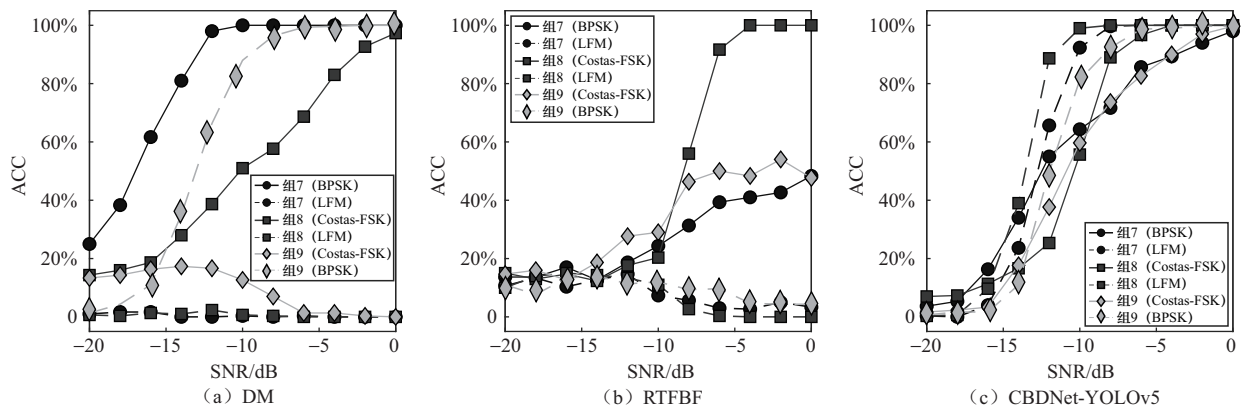


图11 多信号(频谱混叠)NZ标号估计准确率

### (3) 频谱重构结果

NZ标号估计完成后通过解调消除本振调制成分，再通过频谱峰值搜索和滤波来重构信号频谱，当SNR=0时，得到一组频谱混叠的多信号频谱重构结果，NYFR输出信号频谱与重构频谱如图12所示。

图12中，第1列为频谱混叠信号频谱，第2、3列为第1列信号解调、滤波重构频谱。图12(a)、图12(d)和图12(g)是输入信号经NYFR混叠的输出结果，因信号在不同程度上频谱混叠，难

以从中正确感知信号。正确估计NZ标号后，经过解调和滤波重构频谱得到剩余图像，可见明显的对应输入信号调制特征。因此，正确估计NZ标号可解NYFR本振调制，重构输入信号原始调制特征。

### (4) 载频估计结果

利用YOLOv5输出的NZ标号和边界框计算载频估计值 $\hat{f}_c$ ，当YOLOv5未能识别信号时，假设目标来自NZ0。使用均方根误差（root mean square error, RMSE）衡量 $\hat{f}_c$ 参数估计精度，表

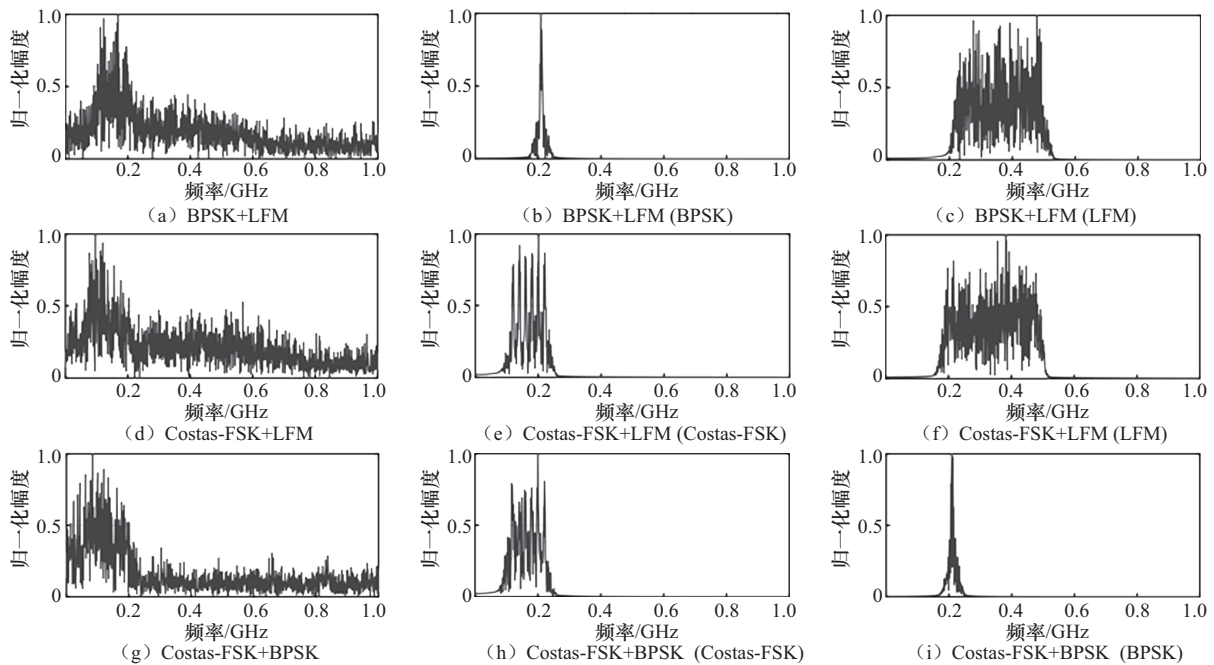


图12 NYFR输出信号频谱与重构频谱

达式为  $RMSE = \sqrt{(1/N) \sum_{i=1}^N (\hat{f}_c - f_c)^2}$ 。由于图 9、图 10 和图 11 中，DM 的 NZ 标号估计性能优于 RTFBF，而据式 (5) 的 NZ 标号估计结果对载频估计性能影响较大，因此添加 DM 载频估计作对比，单信号和多信号载频估计 RMSE 如图 13 所示。

图 13 (a) 中，随着 SNR 增加， $\hat{f}_c$  估计 RMSE 逐渐减小，在 SNR 高于 -4 dB 时收敛于 0.01 GHz 附近。Costas-FSK 的时频分布较复杂且未经训练提前学习，因此 RMSE 略高，稳定于 0.05 GHz 附近。图 13 (b) 和图 13 (c) 中，因低 SNR 时 YO-

LOv5 未输出目标框并假设输入信号来自 NZ0，输入高频（位于 NZ7）信号在低 SNR 下 RMSE 显著高于低频（位于 NZ2）信号，且高频信号在 SNR = -20 dB 时 RMSE 接近 14 GHz，与预设参数相符。与单信号  $\hat{f}_c$  估计结果一致，在 SNR 较高时多信号载频估计 RMSE 降至低水平，实现了  $\hat{f}_c$  的估计。图 13 (d)、图 13 (e) 和图 13 (f) 中，DM 对 BPSK 有较好的载频估计性能，对其余信号的载频估计性能不佳，原因是 DM 算法依赖频域上对信号滤波分离，而窄带信号更易被准确地分离。图 13 (f) 中，观察到 Costas-FSK 随着信

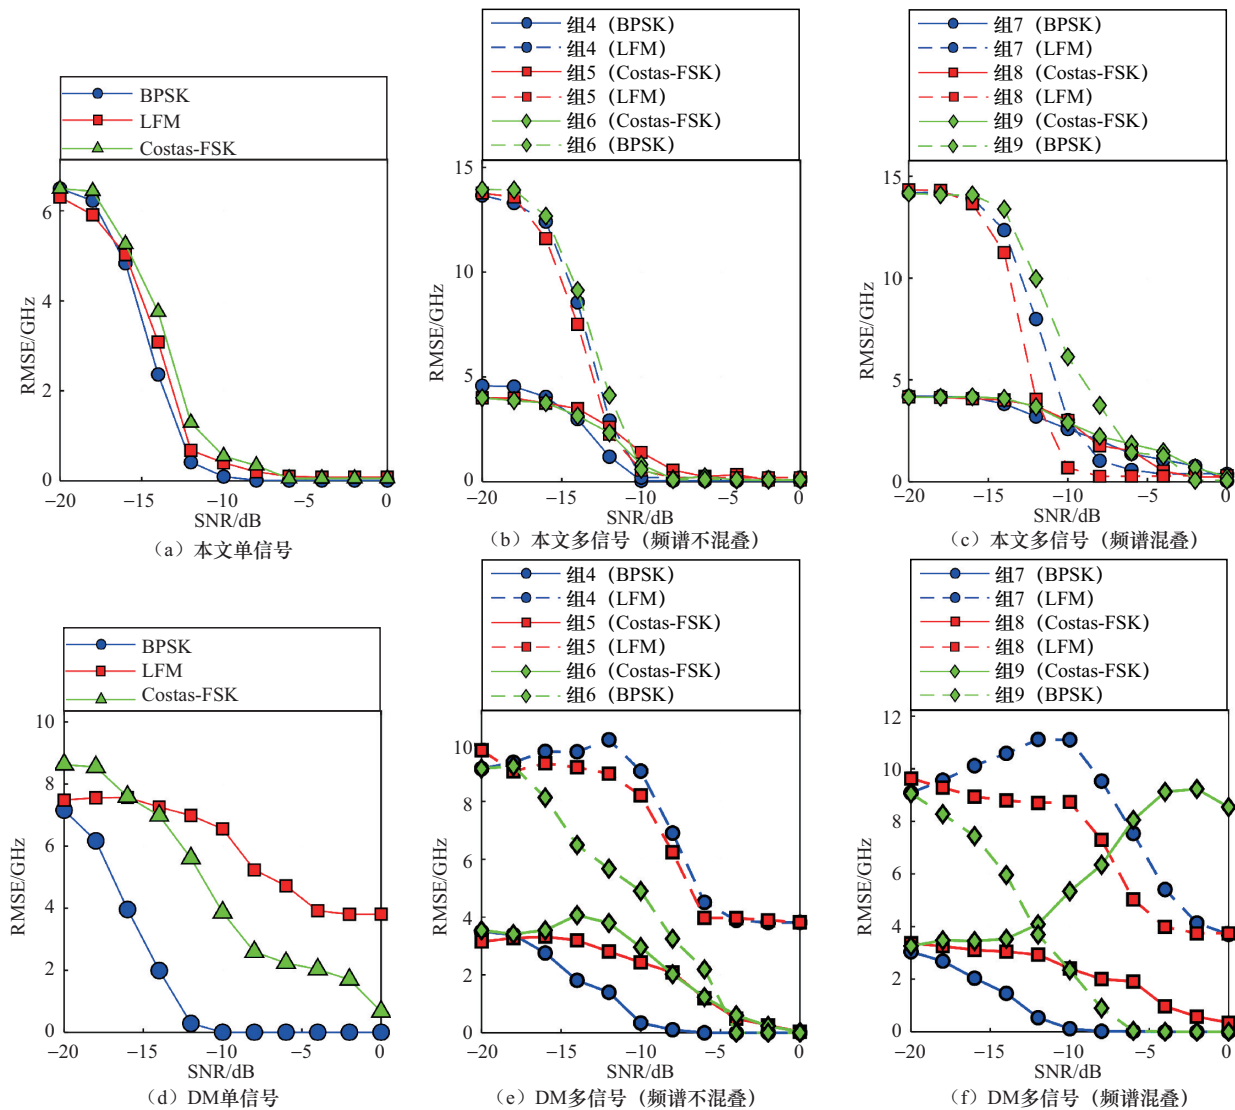


图 13 单信号和多信号载频估计 RMSE



噪比提高而RMSE增大。分析认为,在该组数据中,BPSK信号载频更高,受NYFR影响调制带宽更大,在频谱中与Costas-FSK信号产生了严重的频谱混叠。此时,DM算法的频域滤波器试图分离BPSK信号时,会将与之重叠的Costas-FSK信号一并滤除。算法使用滤波后的剩余频谱进行NZ标号估计,将BPSK信号的残余频谱作为NZ标号估计目标,因此,对Costas-FSK信号的NZ标号估计失败,载频估计RMSE增大。

### (5) 参数普适性分析

为讨论算法对不同信号参数的普适性,修改LFM调制斜率为 $0\sim 1\,000\text{ MHz}/\mu\text{s}$ ,步进为 $50\text{ MHz}/\mu\text{s}$ ,各NZ对应的载频区间内使用50条信号训练模型。以第3.2节单LFM信号参数为默认参数,修

改调制斜率为 $10\text{ MHz}/\mu\text{s}$ 和 $800\text{ MHz}/\mu\text{s}$ ;修改噪声类型为有色噪声<sup>[28]</sup>和冲击噪声;修改分辨率为 $580\times 580$ 和 $700\times 700$ (单位为像素);修改信号时长为 $0.8\mu\text{s}$ 和 $1.2\mu\text{s}$ ,分别分析该模型在输入信号参数变化时的普适性,参数普适性分析结果如图14所示。

图14(a)、图14(b)和图14(d)中,由于信号部分特征未经提前学习,输入信号与训练信号参数不一致时算法性能略微下降。图14(c)中,输入分辨率为 $700\times 700$ (单位为像素)的时频图像时信号NZ估计性能略高于低分辨率,原因是较大的分辨率保存了更多可分辨的信号时频特征。从图14可知,本文所提算法在调制斜率、噪声类型、时频图像分辨率和信号时长等参数变

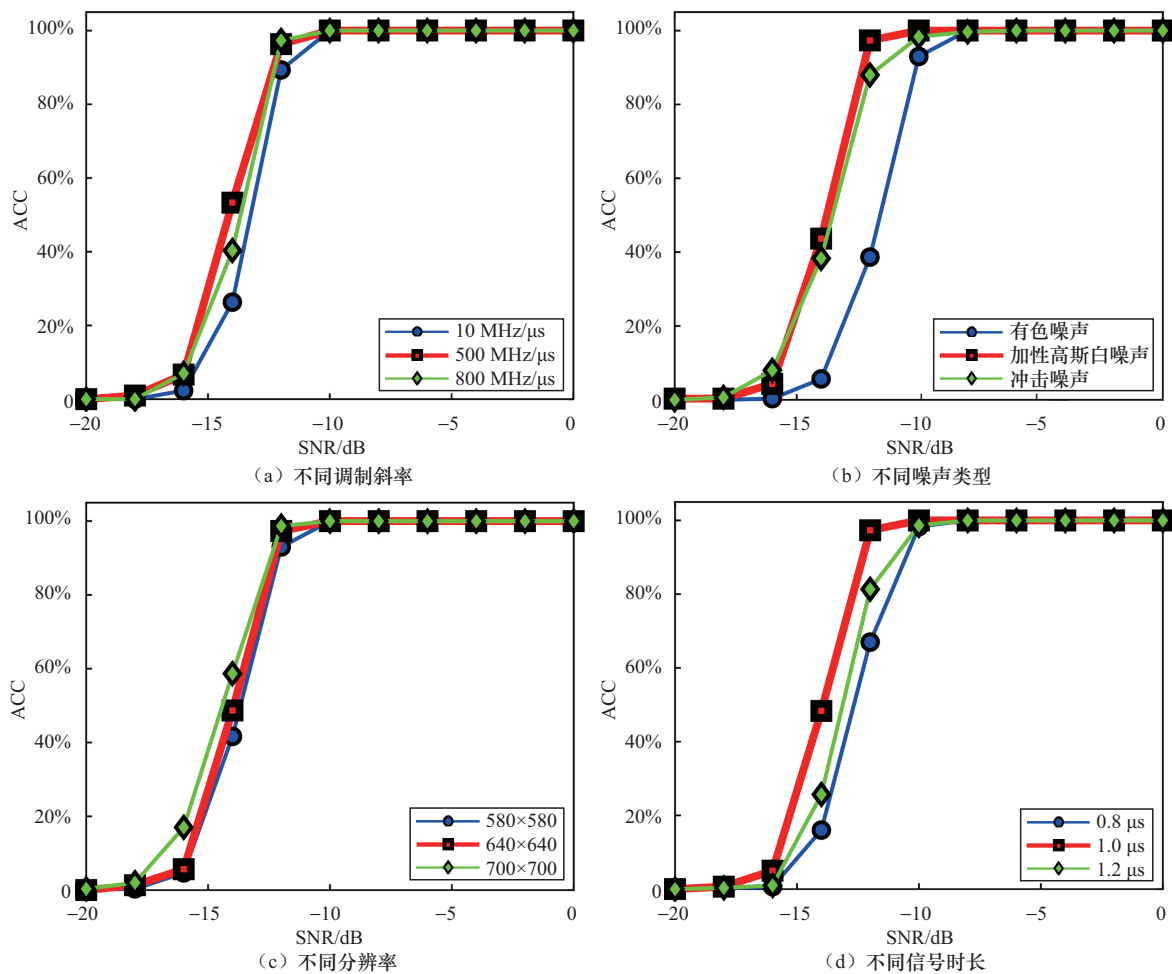


图14 参数普适性分析结果

化时性能变化小, 表现出良好的参数普适性。

### 3.3 实验结论

相较于传统的NZ标号估计算法, 本文所提方法受NYFR接收信号调制类型和信号数量影响小, 能以更低的SNR实现信号的NZ标号估计, 且在频谱混叠时可维持良好的算法性能。原YOLOv5网络处理Costas-FSK信号时性能下降, 加入CBDNet后, 模型的NZ标号估计性能接近其他预训练调制类型, 稳定性得到提升。相较实验所用的3种CNN类算法, 本文所提方法表现出更高的NZ标号估计精度。此外, 算法参数普适性分析证明, 本文所提方法的性能对信号参数不敏感, 具有泛化性。实验结果表明: 基于CBDNet-YOLOv5的NYFR输出信号参数估计算法具有更强的泛化性, 能同时输出NZ标号信息、折叠频率信息, 并重构信号频谱和真实频率, 以单片低速ADC实现瞬时超宽带频谱感知与载频测量。

## 4 结束语

针对NYFR接收多种调制类型的非合作雷达信号时NZ标号估计泛化性不足的问题, 本文提出了基于CBDNet-YOLOv5的联合参数估计算法。该算法通过STFT将NYFR接收信号转为时频图, 使用CBDNet残差学习方法抑制噪声并重建特征, 利用YOLOv5锚框实现NZ标号估计和起始频率提取, 最后处理YOLOv5输出信息来重构信号频谱和真实频率, 从而以单片低速ADC实现超宽带频谱感知与载频测量。实验表明, 该算法能以2GHz采样率实现0~20GHz频段多种非合作雷达信号的超宽带频谱感知与载频测量, 且在频谱混叠时具有良好的参数估计性能, 算法性能对信号参数变化不敏感, 具有较强的泛化能力。由于超宽带接收机在非合作信号接收任务中无法提前确定接收信号的调制类型和数量, 本文提出的基于CBDNet-YOLOv5的NYFR输出信号参数估计算法更具实用性。

## 参考文献:

- [1] 吴世鹏, 孙浩. 非合作通信中一种高精度载频估计算法[J]. 通信技术, 2021, 54(4): 798-802.  
Wu S P, Sun H. A high-precision carrier frequency estimation algorithm for non-cooperative communication[J]. Communication Technology, 2021, 54(4): 798-802.
- [2] 肖东. 基于压缩感知的宽带频谱感知技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2024.  
Xiao D. Research on wideband spectrum sensing technology based on compressed sensing[D]. Harbin: Harbin Engineering University, 2024.
- [3] 王豪. 非合作条件下的智能频谱感知技术研究[D]. 成都: 电子科技大学, 2022.  
Wang H. Research on intelligent spectrum sensing technology under non-cooperative conditions[D]. Chengdu: University of Electronic Science and Technology of China, 2022.
- [4] Peng X Y, Li J Y, Zhang J, et al. Calibration technique for new-structure, two-channel hybrid filter banks ADC[J]. IEICE Electronics Express, 2018, 15(9): 20180290-20180290.
- [5] 崔文涛, 李杰, 张德彪, 等. 基于国产ADC芯片的TIADC系统时间误差自适应校准算法[J]. 仪器仪表学报, 2021, 42(11): 132-139.  
Cui W T, Li J, Zhang D B, et al. TIADC system time error adaptive calibration algorithm based on domestic ADC chip[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 132-139.
- [6] Liu Y F, Zhao Y, Zhu J, et al. Passive localization algorithm for spaceborne SAR using NYFR and sparse Bayesian learning[J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2019, 102(3): 581-585.
- [7] Wang W, Li Z Y, Qiu Z Y, et al. A parameter estimation method for binary frequency shift keying radar signal intercepted by Nyquist folding receiver[C]//Proceedings of the IET International Radar Conference. Piscataway: IET Press, 2020(9): 1764-1768.
- [8] Tian K L, Wan T, Xiong Y, et al. A Nyquist folding receiver architecture with improving Nyquist zone estimation precision[C]//Proceedings of the IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2022: 2311-2314.
- [9] Liu X Q, Bai J J, Peng J L. Parameter estimation of LFM signal intercepted by synchronous Nyquist folding receiver based on instantaneous autocorrelation[C]//Proceedings of the 2023 5th International Conference on Electronic Engineering and Informatics (EEI). Piscataway: IEEE Press, 2023: 570-574.
- [10] 李淳夏. 频率折叠采样接收机局限性分析及改进研究[D]. 成都: 电子科技大学, 2024.  
Li C X. Limitations analysis and improvement research of frequency folding receiver[D]. Chengdu: University of Electronic



- Science and Technology of China, 2024.
- [11] Jiang K L, Tian K L, Feng H C, et al. Distributed UAV swarm augmented wideband spectrum sensing using Nyquist folding receiver[J]. IEEE Transactions on Wireless Communications, 2024, 23(10): 14171-14184.
- [12] 高振斌, 刘进圆, 宿绍莹. 基于时频边界拟合的NZ估计优化方法[J]. 现代雷达, 2024, 46(8): 59-64.  
Gao Z B, Liu J Y, Su S Y. NZ estimation optimization method based on time-frequency boundary fitting[J]. Modern Radar, 2024, 46(8): 59-64.
- [13] Li C X, Tian K L, Jiang K L, et al. Modeling and optimization of local oscillation signals for Nyquist folding receiver[C]//Proceedings of the 2023 5th International Conference on Circuits and Systems (ICCS). Piscataway: IEEE Press, 2023: 181-185.
- [14] Swartz P, Ren S, Sun S. Improved sampling model for the Nyquist folding receiver[C]//Proceedings of the NAECON 2024-IEEE National Aerospace and Electronics Conference. Piscataway: IEEE Press, 2024: 173-179.
- [15] Murray M J, Schermer R T, Hart J, et al. Deep learning enabled photonic Nyquist folding receiver for wideband RF spectral analysis[J]. APL Photonics, 2025, 10(2): 026112.
- [16] Guo S, Yan Z F, Zhang K, et al. Toward convolutional blind denoising of real photographs[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Piscataway: IEEE Press, 2019: 1712-1722.
- [17] 谈世磊, 别雄波, 卢功林, 等. 基于YOLOv5网络模型的人员口罩佩戴实时检测[J]. 激光杂志, 2021, 42(2): 147-150.  
Tan S L, Bie X B, Lu G L, et al. Real-time detection for mask wearing of personnel based on YOLOv5 network model[J]. Laser Journal, 2021, 42(2): 147-150.
- [18] 刘进圆. 基于NYFR的宽带雷达信号特征提取与参数估计算法研究[D]. 天津: 河北工业大学, 2023.  
Liu J Y. Research on feature extraction and parameter estimation algorithms of wideband radar signals based on NYFR[D]. Tianjin: Hebei University of Technology, 2023.
- [19] Qiu Z Y, Li T P, Wang Y M. Parameter estimation of multiple mono-pulse radar signals intercepted by Nyquist folding receiver using periodic chirp local oscillator based on periodic fractional autocorrelation[J]. Chinese Journal of Electronics, 2022, 31(1): 181-189.
- [20] Jiang K L, Wang D C, Tiang K L, et al. Wideband power spectrum sensing: a fast practical solution for Nyquist folding receiver[J]. IEEE Internet of Things Journal, 2024, 11(13): 24098-24108.
- [21] Wang T, Jiang K L, Ji H, et al. Deep learning-based LPI radar signals analysis and identification using a Nyquist folding receiver architecture[J]. Defence Technology, 2023, 19: 196-209.
- [22] 刘丽娇. 机动目标参数估计方法研究[D]. 西安: 西安电子科技大学, 2014.  
Liu L J. Research on parameter estimation methods for maneuvering targets[D]. Xi'an: Xidian University, 2014.
- [23] 苏汉宁. 基于深度学习的LFM信号参数估计算法研究[D]. 长沙: 国防科技大学, 2020.  
Su H N. Research on parameter estimation algorithms of linear frequency modulation signal based on deep learning[D]. Changsha: National University of Defense Technology, 2020.
- [24] Patrick M J, Field C R, Grae L H L, et al. A comparative analysis of YOLOv8 and U-Net image segmentation approaches for transmission electron micrographs of polycrystalline thin films[J]. APL Machine Learning, 2025, 3(3): 036105.
- [25] Dhar P, Dutta S, Mukherjee V. Cross-wavelet assisted convolution neural network (AlexNet) approach for phonocardiogram signals classification[J]. Biomedical Signal Processing and Control, 2021, 63: 102142.
- [26] Hou Y T, Wu Z Q, Cai X H, et al. The application of improved DenseNet algorithm in accurate image recognition[J]. Scientific Reports, 2024, 14(1): 8645.
- [27] Majib M S, Rahman M M, Sazzad T M S, et al. VGG-SCNET: A VGG net-based deep learning framework for brain tumor detection on MRI images[J]. IEEE Access, 2021, 9: 116942-116952.
- [28] Gordienko Y, Gordienko N, Taran V, et al. Effect of natural and synthetic noise data augmentation on physical action classification by brain-computer interface and deep learning[J]. Frontiers in Neuroinformatics, 2025, 19: 1521805.

## [作者简介]



袁子杰 (2001-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为超宽带频谱感知。

仇兆炀 (1987-), 男, 博士, 杭州电子科技大学通信工程学院副教授, 主要研究方向为信号采样、信号处理和宽带感知。

王佩 (1988-), 男, 博士, 南京电子设备研究所高级工程师, 主要研究方向为电磁频谱数据智能分析处理技术。

李博文 (1999-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为雷达信号参数估计等。

汤嘉城 (2000-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为超宽带频谱感知和信号处理。