

# 一种改进YOLOv8的跳频网台分选算法

朱政宇<sup>1,2,3</sup>, 赵航冉<sup>1</sup>, 王梓暄<sup>1</sup>, 王忠勇<sup>1</sup>, 巩克现<sup>1</sup>, 梁 静<sup>1</sup>

(1. 郑州电气与信息工程学院, 河南郑州 450001; 2. 东南大学移动通信国家重点实验室, 江苏南京 210018;  
3. 河南省智能网络和数据分析国际联合实验室, 河南郑州 450001)

**摘 要:** 针对传统跳频网台分选技术在低信噪比条件下检测效果不佳且实时性差的问题, 本文提出一种基于YOLOv8(You Only Look Once version 8)的跳频信号分选算法. 首先, 对接收到的混叠信号进行短时傅里叶变换生成灰度时频图作为YOLOv8网络模型的输入. 其次, 针对混叠信号中扫频、定频信号以及跳频信号之间发生频率碰撞对检测精度的影响, 在C2f层中引入可变形卷积核(Deformable Convolutional Networks v2, DCNv2)提高网络特征提取的泛化能力. 再次, 在Backbone层中加入SimAM注意力机制, 解决低信噪比下背景噪声易与跳频信号混淆影响检测精度的问题. 最后, 将Detect检测头的卷积核替换为局部卷积核(Partial Convolution, PConv), 在mAP@0.5精度损失不超过0.37%的情况下使网络计算复杂度降低32.18%, 提高网络模型的推理速度. 实验结果表明, 本文所提算法在信噪比为-5 dB时分选率达到97.68%, 且模型收敛快, 鲁棒性强.

**关键词:** 跳频信号分选; YOLOv8; DCNv2; SimAM机制; PConv

**基金项目:** 国家重点研发计划(No.2022YFD2001200); 国家自然科学基金(No.61922072); 河南省高校科技创新人才支持计划(No.23HASTIT019); 河南省自然科学基金(No.232300421097); 东南大学移动通信国家重点实验室开放课题(No.2023D11); 西安电子科技大学空天地一体化综合业务网全国重点实验室(No.ISN25-24)

**中图分类号:** TN91 **文献标识码:** A **文章编号:** 0372-2112(2025)02-0385-10  
**电子学报URL:** <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20240487

## A Frequency Hopping Network Station Sorting Algorithm Based on Improved YOLOv8

ZHU Zheng-yu<sup>1,2,3</sup>, ZHAO Hang-ran<sup>1</sup>, WANG Zi-xuan<sup>1</sup>, WANG Zhong-yong<sup>1</sup>, KONG Ke-xian<sup>1</sup>, LIANG Jing<sup>1</sup>

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou, Henan 450001, China; 2. National Mobile Communications Research Laboratory, Southeast University, Nanjing, Jiangsu 210018, China; 3. Henan International Joint Laboratory of Intelligent Network and Data Analysis, Zhengzhou, Henan 450001, China)

**Abstract:** Aiming at the problem that traditional frequency hopping network station sorting technology is ineffective under low signal-to-noise ratio conditions and has poor real-time detection performance, this paper proposes a shortwave frequency hopping signal sorting algorithm based on the improved YOLOv8 (You Only Look Once version 8). First, the short-time Fourier transform is performed on the received aliasing signal to generate a grayscale time-frequency image as the input of the YOLOv8 network model. Secondly, in view of the impact of frequency collisions between aliasing signals such as sweep frequency signals, fixed frequency signals and frequency hopping signals on detection accuracy, the Deformable Convolutional Networks v2 is introduced in the C2f layer to improve the generalization ability of network feature extraction. Thirdly, the Simam attention mechanism is added to the backbone layer to solve the problem that background noise is easily confused with frequency hopping signals and affects detection accuracy under low signal-to-noise ratio. Finally, the convolutional kernel of Detect module is replaced by Partial Convolution kernel, which reduces the computational complexity of the network by 32.18% without the accuracy loss of mAP@0.5 exceeding 0.37%, and improve the inference speed of the network model. Experimental results show that the improved YOLOv8 algorithm proposed in this paper has a separation rate of 97.68% at -5 dB signal-to-noise ratio, and the model has fast convergence and strong robustness.

**Key words:** frequency hopping signal sorting; YOLOv8; DCNv2; SimAM mechanism; PConv

**Foundation Item(s):** National Key Research and Development Program of China (No.2022YFD2001200); National

Natural Science Foundation of China (No.61922072); Program for Science & Technology Innovation Talents in Universities of Henan Province (No.23HASTIT019); Natural Science Foundation of Henan Province (No.232300421097); Open Research Fund of National Mobile Communications Research Laboratory Southeast University (No.2023D11); Program for Science & Technology Innovation Talents in Universities of Henan Province (No.ISN25-24)

## 1 引言

作为一种被广泛应用的扩频通信技术,跳频通信在军事与商业领域内展现出显著的实际应用价值及研究意义.该技术以其卓越的抗干扰性能、对抗信号衰落的能力、较低的被截获概率以及强大的组网能力,在通信领域的抗干扰解决方案中占据了极其重要的位置.对于非合作方通信,跳频信号的载波频率是由发射端生成的伪随机序列所决定的,对外界而言跳频序列是未知的.此外,在面对复杂多变的电磁环境时,信号传输过程中极易受到诸如扫频或定频信号等干扰,这给跳频通信侦察带来了严峻考验.跳频通信侦察技术由检测、参数估计、分选、解调4个部分组成<sup>[1]</sup>.跳频信号分选是指将不同跳频网台的信号进行提取和筛选,从混叠信号中恢复出原始跳频信号数据,是实施跳频信号参数估计和解调的重要前提,具有重要的军事研究价值.

目前,实现跳频网台分选的方法主要有2种:(1)基于无先验知识的盲源分离、独立分量分析(Independent Component Analysis, ICA)算法等;(2)基于不同网台的参数特征进行分选.文献[2]利用信源间的独立性解决变速跳频信号盲分离问题,实现分选.文献[3]对非线性函数进行改进,加快收敛速度,降低运算量,但基于独立分量分析的分选方法只在正定或超定情况下适用.在实际情况中,受跳频网台个数的影响,正定或超定情况通常难以保证,实用性较低.稀疏分量分析(Sparse Component Analysis, SCA)是目前解决独立分量分析算法受超定条件限制的有效方法.文献[4]提出了一种基于稀疏聚类的矩阵估计方法,有较高的分选精度和较低的计算量,但是受特定稀疏条件的限制,应用范围较小.文献[5,6]提出一种基于平行因子分析模型与子空间投影法的跳频信号分离方法,通过求得混合矩阵完成跳频信号的分选,但当信噪比(Signal-to-Noise Ratio, SNR)较低时,混合矩阵估计误差变大,信号分离准确度下降.文献[7,8]提出一种基于稀疏贝叶斯跳频参数盲估计的方法,可完成多网台跳频信号的分选,解决了时频信息聚集度低的问题,但对重构算法参数优化效果不佳,还需作进一步研究探讨.文献[9]提出了一种基于帧重叠的变速跳频信号分析,通过频率相似性完成不同时间帧信号的分析.文献[10]利用时频单源点估计出跳频信号波达方向,实现盲源分离.上述算法在低SNR条件下分选效果不佳,且计算复杂度较高,其跳频信号分选的实时性较差.

传统的跳频网台分选技术以跳频信号特征参数的提取为前提,根据不同跳频网台的跳周期、载波频率、跳时、波达方向和功率等特征之间的差异完成分选.文献[11]通过时频脊线法对跳频参数进行估计,用K-means聚类算法对跳频参数进行聚类,完成跳频信号分选.文献[12]对谱图变化进行了非相干积累处理,用多重差分的方法完成特征参数估计,对于同步跳频网台则仅通过信号波达方向和功率的差异进行分选,因此仅在较高SNR条件下表现良好.上述分选方法性能依赖于算法对参数估计的准确性,且无法解决跳频信号经短时傅里叶变换后时间分辨率与频率分辨率之间相互制约的问题.

随着深度学习算法的不断发展,越来越多神经网络算法应用于信号处理领域.文献[13]利用神经网络对跳频特征参数进行分类,相比于普通的聚类算法有着更快的收敛速度,适用于更低的信噪比环境.文献[14]提出一种基于卷积神经网络(Convolutional Neural Networks, CNN)和循环神经网络(Recurrent Neural Network, RNN)的混合方案,从不同窗长的频谱图中提取特征参数,解决了传统时频分析方法时频分辨率无法兼顾和频谱泄露的问题.文献[15]使用CenterNet神经网络识别时频图中的跳频信号的形状和位置,完成信号检测和参数估计,该网络有着较低的计算量和较高的识别精度.相比于传统跳频信号分选方法,深度学习算法能在更低的SNR条件下较好地完成信号特征提取.YOLOv8(You Only Look Once version 8)是一种目标检测算法,它在YOLO系列的基础上做出了改进和优化,相较于现有目标检测算法有着更快的推理速度、更高的检测精度和更广泛的应用场景.因此,为了提高低信噪比下跳频信号的分选正确率,本文将YOLOv8网络应用于跳频信号的分选,提出一种基于改进型YOLOv8的跳频信号分选方法,具体研究工作如下:

(1)为了抑制背景噪声,提高算法低SNR条件下检测性能,在Backbone层加入SimAM注意力机制强化跳频信号特征信息.

(2)为了解决定频信号和扫频信号对跳频信号的遮盖从而导致部分跳频信号漏检的问题,使用可变形卷积核替换C2f层中卷积核.

(3)为了满足实际工程应用需要,降低算法计算复杂度,在检测头中引入局部卷积核,在保证检测精度的同时降低网络模型参数量,浮点运算数,满足实际工程

应用实时性的要求。

### 2 跳频信号预处理

跳频信号的频率由一个伪随机序列确定,载波频率会在短时间内进行快速的切换,信息由不同频率的载波进行传输.传统的傅里叶变换无法完整描述信号的时间与频率之间关系,因此使用短时傅里叶变换(Short-Time Fourier Transform, STFT)对接收到的信号进行处理.对于接收到的信号 $f(t)$ 进行短时傅里叶变换,其公式为

$$STFT_z(f, \tau) = \int_{-\infty}^{+\infty} [f(t)g(\tau-t)]e^{-j2\pi t} dt \quad (1)$$

假设在观测时间 $T$ 内接收到多个跳频网台信号,其数学模型可表示为

$$r(t) = s(t) + i(t) + n(t), 0 \leq t \leq T \quad (2)$$

其中, $s(t)$ 为不同网台跳频信号, $i(t)$ 是各种干扰信号.本文考虑2种典型的干扰信号类型,即扫频干扰和定频干扰信号.定频干扰在观测期间内聚焦于某一特定频率上,该频率与通信系统所用的频率重叠,造成对该特定频段的有效干扰.相比之下,扫频干扰覆盖了更宽广

的带宽范围,其频率能够在一个较宽区间内连续变化,因此,对跳频信号构成了显著威胁. $s(t)$ 可表示为

$$s_k(t) = A_k \sum_{i=1}^n \text{rect}_{T_{hk}}(t - nT_{hk} - \theta_k) e^{-j2\pi f_{ik}(t - iT_{hk} - \theta_k)} \quad (3)$$

其中, $\text{rect}_{T_{hk}}$ 为矩形窗, $T_{hk}$ 表示第 $k$ 个跳频信号的跳频周期, $f_{ik}$ 和 $\theta_k$ 分别是第 $k$ 个跳频信号的跳频频率和相位.

### 3 YOLOv8模型结构

YOLO是一种只需对图像进行1次扫描即可完成检测与识别的网络模型,属于单阶段(One-stage)模型.2023年,Ultralytics发布了最新的YOLOv8算法,该算法在先前版本的基础上进行了优化,并引入了新的特性.YOLOv8的架构由Backbone、Neck和Head3个主要部分构成,如图1所示.根据具体应用环境及网络层的数量差异,YOLOv8进一步细分为n(nano)、s(tiny)、m(medium)、l(large)、x(extra large)5种配置模型.鉴于跳频信号分选需要满足较高的实时性要求,本文选择了参数量较少且计算复杂度较低的YOLOv8n作为目标检测的基础模型.

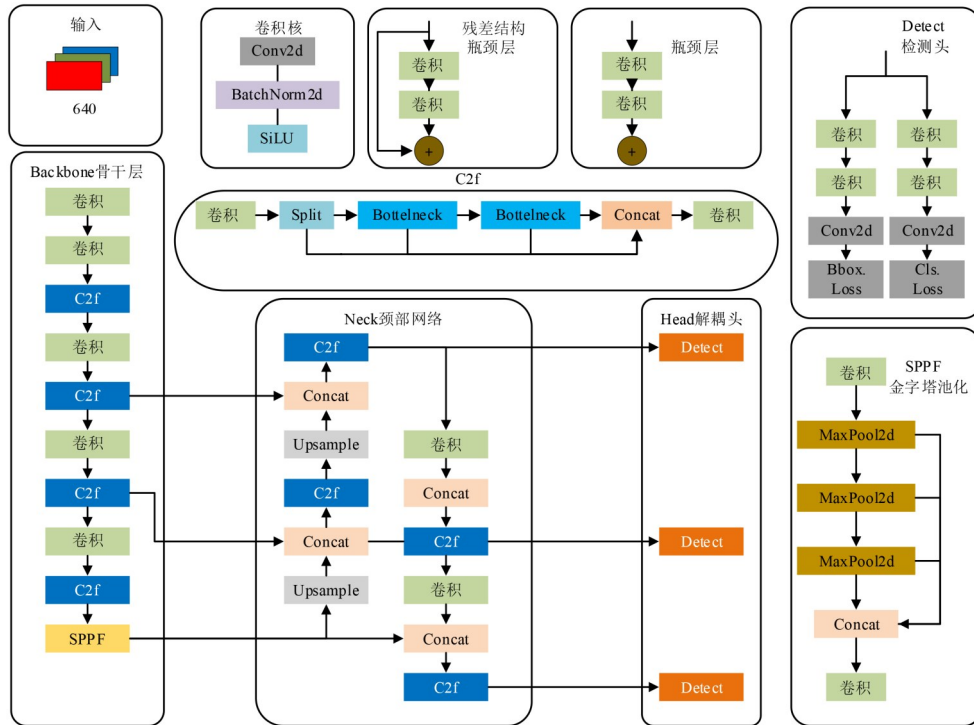


图1 YOLOv8网络模型结构图

Backbone与Neck的设计理念沿用了YOLOv7中的ELAN框架;而Backbone主要包含了Conv、C2f以及SPPF等功能单元.特征提取任务主要是通过标准卷积块CBL(包含卷积、归一化及ReLU激活函数)来实现的,经过多轮次的操作后能够深入挖掘出图像特征.相

较于YOLOv5所采用的C3结构,C2f模块通过引入跨层级连接增加了梯度流动的信息量,在简化模型的同时增强了其特征学习的能力.此外,SPPF模块旨在增强网络处理多种尺度对象的能力,从而提升整体的检测精度和泛化性能.通过整合不同尺寸的特征并捕捉上

下文信息, SPPF有助于更精准地识别各种大小的目标.

颈部网络(Neck)其核心作用在于处理多尺度特征,从而增强网络对图像内目标的理解能力. 通过融合不同层级的特征图,颈部网络能够构建一个包含来自多种尺度信息的特征金字塔,这一设计有助于捕捉到大小各异的目标所特有的视觉属性. PANet架构是此类网络设计中的典型代表之一,它利用双向路径实现特征的有效整合:自上而下的路径负责将高层级特征图的信息传递给较低层级,以丰富后者对于全局上下文的认知;相反地,自下而上的路径则侧重于从低层级向高层级输送更加精细的局部细节,以此提升特征表示的准确性.

## 4 YOLOv8改进

### 4.1 可变形卷积DCNv2

在复杂的电磁环境中,接收到的信号往往包含了大量定频干扰及扫频干扰信号. 这些干扰信号与跳频信号之间存在着严重的遮挡现象,同时,不同跳频信号间也可能发生频率碰撞,导致关键信息的丢失,这极大地增加了跳频信号检测的难度<sup>[16]</sup>. 为了解决跳频信号频率碰撞以及干扰信号造成的遮蔽问题,引入了可变形卷积DCNv2.

在传统的神经网络架构中,卷积核的采样点遵循均匀分布原则,且其形状固定不变. 这意味着,当卷积层处理输入特征图时,只能在预设的位置上执行采样操作,从而限制了模型对于多样化特征的识别能力. 为了克服这一局限性,文献[17,18]提出了一种可变形卷积网络,它通过引入能够自适应改变形状与采样点位置的卷积核来增强传统卷积过程. 这种改进使得模型能够在特征图的不同区域获得不同尺寸和形状的感受野,进而更有效地应对目标对象的空间变化. 在DCNv2中,每个卷积核的具体采样位置都是通过训练过程中学习得到的,并能依据当前输入图像的特点灵活调整,这样就能够捕捉到目标物体的非刚性形变,提高对目标的感知能力;除了可变形卷积核的采样点位置,DCNv2还引入了位移量(offsets),用来描述相对于初始设定位置而言各采样点发生的偏移程度. 这些位移值同样是经过学习迭代获得的,用于进一步微调卷积核的实际作用范围. 如图2所示,其中图2(a)展示了常规卷积核采样点位置. 图2(b)~图2(d)为可变形卷积核,2类卷积的卷积核大小相同,但采样点位置不同.

可变形卷积核的实现过程如图3所示. 该过程通过一个独立的网络分支来执行,对输入特征图实施卷积操作,从而生成一个具有 $2N$ 个通道的偏移量特征图,采用双线性插值反向传播算法对特征图中像素点




图2 标准卷积和可变形卷积采样点位置

的偏移量进行优化更新,偏移量通常为浮点数;将输入特征图与更新后的偏移量进行卷积,以获得输出特征图.




图3 3×3可变形卷积核图

可变形卷积核采样的特征值输出公式为

$$y(p) = \sum_{k=1}^K w_k \cdot x(p + p_k + \Delta p_k) \cdot \Delta m_k \quad (4)$$

其中, $y(p)$ 表示输出; $x$ 代表输入特征图; $w_k$ 代表 $k$ 位置的权重; $p_k$ 代表预偏移量; $p$ 是特征图上采样点的中心位置; $\Delta p_k$ 为相对于中心点 $p$ 的偏移量,偏移量 $\Delta p_k$ 标记为0则对应于标准卷积核; $\Delta m_k$ 表示可学习权重,范围0~1,对于不需要调整的采样点,其权重被设置为0,使卷积核的变形更加灵活. 传统YOLO检测模型在处理跳频信号发生频率碰撞、目标尺寸较小且分布密集时,其检测性能会有所下降. 通过引入可变形卷积核,卷积层可以获取到更加丰富和完整的采样信息,从而增强了模型对小目标的适应能力,显著提升了针对密集型、小型以及部分被遮盖目标的检测效果,进而提高了整体目标检测任务的精度与鲁棒性. 因此,为了改善小目标跳频信号的检测精度,本文将Backbone和Head层中C2f模块采用DCNv2卷积替换原有的卷积方式,以增强模型对跳频信号特征的学习能力.

### 4.2 SimAM注意力机制

在较低信噪比条件下,跳频信号容易与背景噪声相混淆,导致神经网络难以从特征图中提取深层次信息,进而影响检测精度. 为有效抑制背景噪声并增强目标特征的提取能力,本文引入一种无参数注意力机制SimAM<sup>[19]</sup>. SimAM注意力机制的设计灵感源自神经科学领域,是一种三维、加权、无参数的注意力机制. 不同于传统上分别对通道和空间重要性进行评估的做法,SimAM通过定义一个能量函数来衡量每个神经元的重

要性,并据此生成了一种综合考虑所有维度(包括不同通道和空间位置)的加权注意模块,实现了通道与空间注意力机制的同时存在而不增加模型复杂度,展现出高效、灵活和评估全面等优势,具体结构如图4所示。




图4 SimAM注意力机制模块结构

SimAM注意力机制通过计算神经元之间的线性可分性度量不同神经元的重要性。因此,每个神经元的最小能量函数为

$$e_i(z_i, b_i, y_s, x_q) = (y_q - x_i)^2 + \frac{1}{M-1} \sum_{q=1}^{M-1} (y_o - x_q)^2 \quad (5)$$

其中,  $y_s$  表示  $y_q$  和  $y_o$  的二值标签,  $y_q$  和  $y_o$  为目标神经元和其他神经元的真实值,  $x_q$  为目标神经元的估计值,  $M$  代表能量函数数量,  $b_i$  和  $z_i$  分别为偏移和权重。求出相同通道神经元  $x_i$  与其他神经元的线性可分性的过程就是能量函数最小化的过程,对能量函数引入正则项并进行简化:

$$e_i(z_i, b_i, y_s, x_q) = \frac{1}{M-1} \sum_{q=1}^{M-1} \left( -1 - (z_i x_q + b_i) \right)^2 + \left( 1 - (z_i x_i + b_i) \right) + \lambda z_i^2 \quad (6)$$

对上式求解得

$$z_i = -\frac{2(x_i - \mu_i)}{(x_i - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (7)$$

$$b_i = -\frac{1}{2}(x_i + \mu_i)z_i \quad (8)$$

其中,  $\mu_i = \frac{1}{M-1} \sum_{q=1}^{M-1} x_q$ ,  $\sigma_i^2 = \frac{1}{M-1} \sum_{q=1}^{M-1} (x_q - \mu_i)^2$ 。因此,最小能量即为

$$e_i^* = \frac{4(\sigma_i^2 + \lambda)}{(t - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (9)$$

由式(9)分析可知,能量越低则代表与相邻的神经元的区分度越高,重要性越高。采用Sigmoid激活函数对输入特征进行增强处理,式如下:

$$X = \text{sigmoid}\left(\frac{1}{E}\right) \odot X \quad (10)$$

其中,  $E$  为能量函数,  $X$  为输入特征层,能量函数  $E$  经过Sigmoid激活函数后可实现注意力机制。添加过SimAM注意力机制后的YOLOv8的backbone模块结构如图5所示,其中  $r$  为缩放因子。

### 4.3 PConv 模块

为了提升跳频信号的检测速度,实现模型结构的轻量化设计,本文引入一种新的局部卷积替换Detect检测




图5 添加SimAM注意力机制的backbone层

头中3x3大小的卷积核。

PConv是一种由Chen等人<sup>[20]</sup>在2023年3月提出的卷积核变体。这种新型的卷积方法通常用来替代传统的深度可分离卷积(Depthwise Separable Convolution, DSCConv)或GhostNet中的卷积模块,能够显著减少网络模型所需的浮点运算量(Floating Point Operations, FLOPs),即减少了计算负担。然而,尽管FLOPs有所下降,实际的网络计算时间并未因此而缩短。这主要是由于深度卷积操作过程中频繁地访问内存所带来的负面影响,导致了每秒浮点运算次数(Floating Point Operations Per Second, FLOPS),也就是模型的计算速度反而降低了,从而无法有效提升模型推理的速度。PConv模块只对输入的部分通道进行卷积,使剩下的输入通道保持不变,降低了不同通道的计算冗余,其结构如图6所示。其中,  $c_{\text{PConv}}$  为卷积部分通道数,  $k$  是卷积核大小,  $h$  和  $w$  均为输入特征尺度,此时PConv的FLOPs为  $h \times w \times k^2 \times c_{\text{PConv}}^2$ ,若假设  $c_{\text{PConv}}$  为总通道数的1/4,则参数量为常规Conv的1/16,内存访问量为  $h \times w \times 2c_{\text{PConv}}$ ,仅为常规Conv的1/4。PConv相比普通卷积更好地利用了设备的计算能力,具有更低的FLOPs和更高的FLOPS,同时由于所需内存读写次数减少,进一步释放了设备的处理潜能,从而实现了更低的数据处理延迟以及更高的数据吞吐能力。

PConv卷积的Detect检测头结构如图7所示,该检测头由2个功能不同的分支组成。其中一个分支采用Bbox损失函数来评估目标定位的效果;另一个则利用二分类交叉熵损失函数来进行类别判断。每个分支分别通过2个PConv卷积和1个Conv2d卷积算出分类损失




图6 PCConv模块结构图

和边界框回归损失。在YOLOv8的整体架构中配置了3个这样的 Detect 检测头,即共有12个标准卷积模块被使用,12个 $3 \times 3$ 大小的卷积核经过多层叠加会产生较大的参数规模,使得 Detect 检测头部分占据了整个模型约41.83%的参数量。因此对 Detect 检测头的普通卷积核进行优化替换,可在保证原有检测性能的基础上显著减少网络模型所需的计算资源。

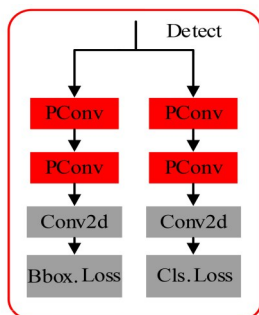


图7 引入PCConv卷积的 Detect 检测头结构

## 5 实验分析

### 5.1 数据集与实验环境参数配置

本研究采用的实验条件包括:采样频率设置为10 MHz,每个样本的观测时间为4 s。FH1~FH8代表了8种具有不同周期和频率集合特征的信号类型,具体参数详情如表1所示。同时,这些跳频信号中可能出现频率重叠现象;此外,在整个观察时段内,定频干扰与扫频干扰持续存在。数据集构建基于上述8种跳频信号之间随机组合叠加而成。模型输入形式为包含完整跳变周期信息的混合信号灰度时频图像,其分辨率为 $640 \times 640$ 像素(参见图8)。在 $-15 \sim -5$  dB信噪比条件下生成了共计10 480幅时频图像,并按照8:1:1的比例将整体数据集划分为训练、验证及测试3个子集。

本实验采用 Windows1164 位的计算机操作系统, CPU 采用 i5-12400F, GPU 采用 NVIDIA GeForce RTX 4060Ti8 GB 内存,模型训练以 Pytorch1.13.1 为框架, Python3.10.13 为编译环境,使用 Cuda11.7.1 进行训练加速。经过不断的实验优化,最终网络模型的训练参数设置如表2所示。




图8 数据集混叠信号示例图

表1 跳频信号参数

源信号	跳周期/s	跳数/个	频率集/MHz
FH1	0.500	8	[0.50~4.00]
FH2	0.800	5	[2.60~4.60]
FH3	0.400	10	[2.00~2.90]
FH4	1.000	4	[4.05~4.95]
FH5	0.200	20	[3.05~4.00]
FH6	0.250	16	[1.40~4.40]
FH7	0.160	25	[2.80~4.70]
FH8	0.125	32	[2.90~4.45]

表2 训练参数

参数	设置	参数	设置
optimizer	SGD	lr0	0.010 0
epochs	300	lrf	0.010 0
batchsize	16	momentum	0.937 0
imgsz	640	weight_decay	0.000 5

### 5.2 性能评价指标

准确率(Precision)、召回率(Recall)和平均准确率(Average Precision, AP)是机器学习目标检测领域评估网络模型性能的重要指标。

准确率表示分类器预测为正样本中,实际也为正样本的比例。其计算公式为

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (11)$$

其中,TP(True Positives)表示被分类器正确判断为正例的样本数量,FP(False Positives)表示实际上是负例但被分类器错误判断为正例的样本数量。

召回率表示所有实际为正的样本中,分类器成功识别出的正样本所占的比例。计算公式为

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (12)$$

其中,FN(False Negatives)表示实际上是正样本但被分类器错误判断为负样本的样本数量。

AP值表示了PR曲线下方的面积,它作为精度与召回率之间关系的一个度量指标,其数值范围限定于0~1。AP越高,代表模型越好。如果PR曲线下的面积为1,则代表模型的性能最佳,平均准确率(mean Average Preci-

sion, mAP)即为 AP 的平均值.

分选正确率用于评价算法的有效性,其公式为

$$\text{分选正确率} = \frac{\text{正确分选的跳数}}{\text{信号总跳数}} \times 100\% \quad (13)$$

模型轻量化是指通过降低神经网络模型的复杂度和参数量,减少计算资源和存储空间的需求,从而使模型能够在资源受限的设备上高效运行的过程. 其中,浮点运算次数 FLOPs 和参数量(Parameters)是模型轻量化的评价指标. FLOPs 是指处理 1 张图像所需要的浮点运算数量,是比较不同算法直接检测速度的重要指标,在网络进行训练推理过程中的每一个加、减、乘、除操作都算 1FLOPs 操作;Parameters 参数量指的是模型所包含的参数的数量,模型中使用到的卷积、全连接里面的权值矩阵对应的每一个数字,都是参数量的组成,Parameters 是模型结构复杂度的直观反映. 其中 GFLOPS (Giga Floating Point Operations Per Second)代表每秒 10 亿次的浮点运算数. 1 个 GFLOPS 等于每秒 10 亿次的浮点运算. FLOPs 的计算在神经网络模型的卷积操作和全连接层中有所不同,在卷积层中和全连接层中 FLOPs 的计算公式如下:

$$\begin{aligned} \text{FLOPs(卷)} &= 2 \times K^2 \times C_{in} \times C_{out} \times h_{out} \times w_{out} \\ \text{FLOPs(全)} &= (2I - 1)O \end{aligned} \quad (14)$$

其中,  $K$  代表卷积核的大小,  $C_{in}$  和  $C_{out}$  分别是输入和输出特征图的通道数,  $h_{out}$  和  $w_{out}$  分别是输出特征图的高度和宽度,因为每次卷积操作都包含了 1 次乘法法和 1 次加法运算,所以要乘以 2,  $I$  和  $O$  分别代表全连接层的输入和输出维数.

### 5.3 改进实验分析

为了验证本文基于 YOLOv8n 网络模型改进算法的合理性和有效性,将原 YOLOv8n 网络模型与本文算法在相同实验环境配置和数据集进行实验对比,实验结果如图 9 所示. 以 0.5:0.95IoU 下的平均准确率 mAP 和召回率作为评价指标,由图 9 可看出,在训练达到 250 轮后,平均准确率趋于平稳,模型收敛,本文算法相较于原 YO-

LOv8 网络模型 mAP@0.5、mAP@0.95 分别提升了 1.72 个百分点和 5.83 个百分点. 由图 10 可以看出,经过对 YOLOv8n 网络模型各模块改进,其召回率由 83.93% 提升至 86.25%,能够有效解决干扰信号对跳频信号的遮盖问题.

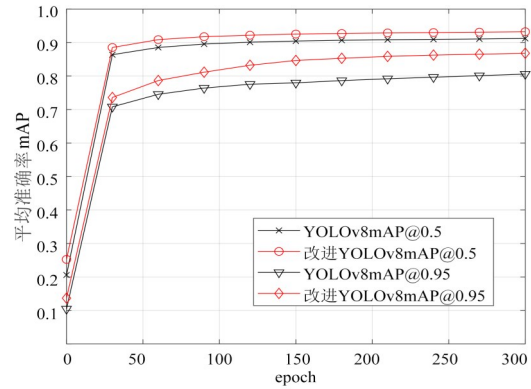


图 9 mAP 对比图

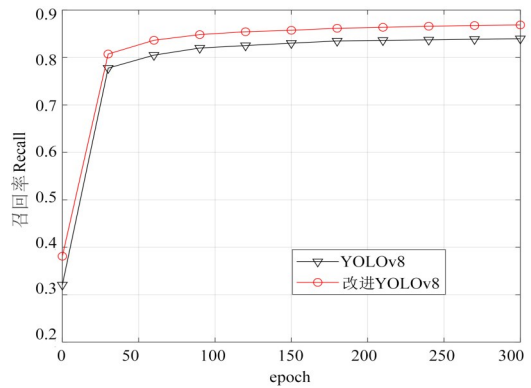


图 10 召回率对比图

### 5.4 对比实验分析

如表 3 所示,为验证本文算法的优势,将本文算法与当前热门目标检测模型 CenterNet<sup>[21]</sup>、YOLOv5<sup>[22]</sup>、YOLOv6<sup>[23]</sup>、YOLOv7-Tiny<sup>[24]</sup>和 YOLOv8 进行仿真实验对比,所有网络模型均采用统一的实验配置和相同数据集.

表 3 不同目标检测网络模型对比

Models	Precision/%	Recall/%	mAP@0.5/%	mAP@0.95/%	Parameters/MB	GFLOPS
CenterNet <sup>[15,21]</sup>	93.45	81.35	89.30	78.42	125 000 000	69.90
YOLOv5 <sup>[22]</sup>	94.22	82.01	89.46	74.50	2 504 504	7.10
YOLOv6 <sup>[23]</sup>	94.75	83.71	90.91	77.99	4 234 536	11.80
YOLOv7-Tiny <sup>[24]</sup>	92.89	78.37	87.32	69.29	6 033 930	13.20
YOLOv8	94.88	83.96	91.23	80.59	3 151 888	8.70
Ours	95.65	86.25	92.95	86.42	3 065 702	5.90

本文算法的检测效果在不同评价指标上均有显著提升. 其中 mAP@0.5 比 CenterNet、YOLOv5、YOLOv6、YOLOv7-Tiny 和原 YOLOv8 模型分别提高了 3.65、3.49、2.04、5.63 和 1.72 个百分点. 由表 3 可得,相较于其他模

型,本文在准确率、召回率以及不同交并比下的平均精度都有不同程度的提升. 同时,改进 YOLOv8 网络模型在 FLOP 指标上的表现明显优于其他网络结构模型,相较于 YOLOv5n 网络模型,改进 YOLOv8 在参数量上略

高于YOLOv5n网络模型,但是运算次数减少了12亿次,有着更快的模型运算速度,且更为重要的是,其在不同检测评价指标都得到了显著的提升,其中在Recall、mAP@0.5和mAP@0.95上分别提升了4.24、3.49和11.92个百分点,有效解决了低SNR条件下跳频信号检测精度不高、模型针对小目标检测困难的问题,同时有着更低的参数量和计算复杂度,保证了跳频信号检测的高实时性。

表4 消融实验分析

DCNv2	SimAM	PConv	Precision/%	mAP@0.5/%	mAP@0.5:0.95/%	GFLOPS	参数量
×	×	×	94.88	91.23	80.59	8.7	3 151 888
√	×	×	95.33	92.45	84.51	7.7	3 160 358
√	√	×	95.53	93.32	86.81	7.7	3 160 358
√	√	√	95.65	92.95	86.42	5.9	3 065 702

根据表4所示,引入可变形卷积DCNv2之后,网络对于小目标信号特征的提取能力得到了显著增强,网络模型在Precision、mAP@0.5以及mAP@0.5:0.95这3项指标上分别提升了0.45、1.22和3.92个百分点.此外,通过采用SimAm注意力机制有效减少了背景噪声对目标信号识别过程中的干扰影响,使得上述3个评价标准又进一步提高了0.2、0.37和2.3个百分点.采用PConv代替Detect检测头部原有的普通卷积核时,尽管在mAP@0.5与mAP@0.5:0.95上略有牺牲(分别下降了0.37个百分点和0.41个百分点),但模型的GFLOPS降低了23%,从而极大地提升了运算效率,更好地适应了跳频信号实时检测的需求。

### 5.6 分选性能评估

为了评估所提算法对跳频信号分选性能的影响,使用本文算法网络模型对不同SNR下的跳频信号进行分选,并由公式(13)计算其跳频信号分选率.本文算法与文献[11]、文献[13]、文献[15]和文献[25]算法对比结果如图11所示,信号分选率随着SNR的增大不断提高,当SNR=-5 dB时,本文算法分选率达到97.68%,SNR=0 dB时,分选率达到98.38%,明显优于对比算法.文献[15]采用anchor-free结构的CenterNet网络模型对跳频信号进行检测,其网络结构对跳频数据集的泛化能力较弱,且会产生大量数据冗余,影响检测精度,其分选率在0 dB时可达95.45%,分选效果不如本文算法.文献[11]、文献[13]和文献[25]以跳频特征参数的估计作为跳频信号分选基础,其中文献[11]和文献[25]采用传统的聚类算法对跳频特征参数进行分类,文献[13]使用BP神经网络对特征参数完成分类,但其分选正确率受到跳频信号特征提取准确性的制约.尤其在低SNR情况下,跳频信号的能量特征与背景噪声的能量特征难以区分,导致分选正确率显著下降.因此,本文提出的分选算法在抗噪性能方面优于其他算法,能够在低SNR

### 5.5 消融实验分析

为了验证各改进方法对实验结果的影响,本文分别设置消融实验对各个改进模块进行分析.首先,使用DCNv2替换C2f层中所有卷积核,提升模型特征提取泛化能力,其次,在Backbone层引入SimAM注意力机制,最后在Detect检测头使用PConv卷积完成轻量化设计.如表4所示,“√”表示引用该模块,“×”表示未引入该模块。

条件下有效完成跳频信号的分选.该算法具有更强的鲁棒性,适用于复杂的噪声环境。




图11 不同算法跳频信号分选性能对比

### 5.7 跳频信号检测可视化

为验证本文算法对跳频信号分析的有效性,使用训练好的改进型YOLOv8网络模型对测试集中未知跳频信号进行检测,得到可视化图像如图12所示,尽管跳频信号受到扫频、定频信号遮盖和噪声干扰,本文算法仍可在混叠信号中正确分选出不同跳频信号。




图12 跳频信号分选结果可视化

## 6 结论

针对复杂电磁环境下不同网台跳频信号分选的问题,本文提出一种基于改进 YOLOv8 网络模型的跳频信号分选算法. 本文算法在原 YOLOv8n 网络模型中引入 DCNv2 卷积核,增强了网络对深层特征的提取能力,解决干扰信号对目标信号的遮盖问题;在 Backbone 层加入了 SimAM 无参注意力机制,在未增加网络参数的同时提高了算法的抗噪性能;使用 PConv 卷积替换 Detect 检测头中卷积核,加快了网络模型的推理速度,实现了轻量化检测网络. 实验结果表明,本文所提算法的 mAP@0.5 达到了 92.95%, SNR=0 dB 时分选正确率达到了 98.38%,模型浮点计算量相比于原 YOLOv8n 网络模型降低了 32.18%. 相较于传统跳频信号分选算法,本文所提算法具有更高的分选正确率,能够在更低的信噪比下完成跳频信号的分选. 在未来研究中,针对跳频信号时频动态变化范围大,噪声基底波动明显,时频域能量分散,时频图仍存在大量雾状噪声的问题,需要优化网络结构,进一步增强目标特征提取能力,同时在确保检测精度的基础上提升检测速度.

## 参考文献

- [1] 李青华, 韩岱洪, 唐柯, 等. 跳频网台分选方法概述[J]. 中国无线电, 2022(5): 87-90.  
LI Q H, HAN D H, TANG K, et al. Overview of sorting methods for frequency hopping network stations[J]. China Radio, 2022(5): 87-90. (in Chinese)
- [2] 王森, 蔡晓霞, 雷迎科. 一种基于独立分量分析的变速跳频信号盲分离方法[J]. 空军工程大学学报(自然科学版), 2019, 20(5): 58-63.  
WANG M, CAI X X, LEI Y K. A blind separation of variable frequency hopping signals based on independent component analysis[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(5): 58-63. (in Chinese)
- [3] 杨芸丞, 孙雪丽, 钟兆根, 等. 一种改进的独立分量分析跳频网台分选方法[J]. 中国电子科学研究院学报, 2018, 13(4): 452-459.  
YANG Y C, SUN X L, ZHONG Z G, et al. An improved independent component analysis frequency-hopping network station sorting method[J]. Journal of China Academy of Electronics and Information Technology, 2018, 13(4): 452-459. (in Chinese)
- [4] 郭凌飞, 张林波. 一种改进的 FCM 聚类算法的混合矩阵估计[J]. 应用科技, 2019, 46(2): 47-52.  
GUO L F, ZHANG L B. Mixing matrix estimation based on an improved FCM clustering algorithm[J]. Applied Science and Technology, 2019, 46(2): 47-52. (in Chinese)
- [5] 王少波, 郭英, 睦萍, 等. 欠定条件下同步组网跳频信号盲源分离方法[J]. 计算机工程, 2020, 46(10): 166-172, 181.  
WANG S B, GUO Y, SUI P, et al. Blind source separation method for frequency-hopping signal in synchronous networking under underdetermined condition[J]. Computer Engineering, 2020, 46(10): 166-172, 181. (in Chinese)
- [6] 于欣永, 郭英, 张坤峰, 等. 基于盲源分离的多跳频信号网台分选算法[J]. 信号处理, 2017, 33(8): 1082-1089.  
YU X Y, GUO Y, ZHANG K F, et al. A network sorting algorithm based on blind source separation of multi-FH signal[J]. Journal of Signal Processing, 2017, 33(8): 1082-1089. (in Chinese)
- [7] LIU S H, ZHANG Y D, SHAN T, et al. Structure-aware Bayesian compressive sensing for frequency-hopping spectrum estimation with missing observations[J]. IEEE Transactions on Signal Processing, 2018, 66(8): 2153-2166.
- [8] FU W H, JIANG T. A parameter estimation algorithm for multiple frequency-hopping signals based on compressed sensing[J]. Physical Communication, 2019, 37: 100892.
- [9] 王森, 蔡晓霞, 雷迎科. 基于帧重叠的变速跳频信号分选算法[J]. 探测与控制学报, 2020, 42(4): 63-68.  
WANG M, CAI X X, LEI Y K. Variable speed hopping signal sorting algorithm based on frame overlap[J]. Journal of Detection & Control, 2020, 42(4): 63-68. (in Chinese)
- [10] 王森, 蔡晓霞, 雷迎科. 基于改进时频检测的欠定变速跳频信号盲分离算法[J]. 计算机工程, 2020, 46(8): 172-177, 183.  
WANG M, CAI X X, LEI Y K. Blind separation algorithm for underdetermined variable speed frequency hopping signals based on improved time frequency detection[J]. Computer Engineering, 2020, 46(8): 172-177, 183. (in Chinese)
- [11] 任珂. 跳频电台分选关键技术研究[D]. 成都: 电子科技大学, 2020.  
REN K. Research on Key Technology of Frequency Hopping Radio Sorting[D]. Chengdu: University of Electronic Science and Technology of China, 2020. (in Chinese)
- [12] 郭海召. 跳频信号的检测、参数估计与分选算法研究[D]. 成都: 电子科技大学, 2016.  
GUO H Z. Study on Detection, Parameters Estimation and Separation Algorithm for Frequency-Hopping Signals[D]. Chengdu: University of Electronic Science and Technology of China, 2016. (in Chinese)
- [13] WANG Z Y, ZHANG B B, ZHU Z Y, et al. Signal sorting algorithm of hybrid frequency hopping network station based on neural network[J]. IEEE Access, 2021, 9: 35924-35931.
- [14] LEE K G, OH S J. Detection of frequency-hopping signals with deep learning[J]. IEEE Communications Letters, 2020, 24(5): 1042-1046.
- [15] CHEN Z Y, SHI Y W, WANG Y W, et al. Unlocking sig-

- nal processing with image detection: A frequency hopping detection scheme for complex EMI environments using STFT and CenterNet[J]. IEEE Access, 2023, 11: 46004-46014.
- [16] 张盛魁, 姚志成, 范志良, 等. 基于局部自适应阈值的跳频信号提取和检测[J]. 电光与控制, 2020, 27(1): 68-72.  
ZHANG S K, YAO Z C, FAN Z L, et al. Frequency hopping signal extraction and detection based on local adaptive threshold[J]. Electronics Optics & Control, 2020, 27(1): 68-72. (in Chinese)
- [17] DAI J F, QI H Z, XIONG Y W, et al. Deformable convolutional networks[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 764-773.
- [18] ZHU X Z, HU H, LIN S, et al. Deformable ConvNets V2: More deformable, better results[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 9300-9308.
- [19] YANG L X, ZHANG R Y, LI L D, et al. SimAM: A simple, parameter-free attention module for convolutional neural Networks[C]//38th International Conference on Machine Learning, New York: PMLR, 2021: 11863-11874.
- [20] CHEN J R, KAO S H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 12021-12031.
- [21] ZHOU X Y, WANG D Q, KRÄHENBÜHL P. Objects as points[EB/OL]. (2019-04-25)[2024-05-27]. <https://arxiv.org/abs/1904.07850v2>.
- [22] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2024-05-27]. <https://arxiv.org/abs/2004.10934v1>.
- [23] LI C Y, LI L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications[EB/OL]. (2022-09-07)[2024-05-27]. <https://arxiv.org/abs/2209.02976>.
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2023: 7464-7475.
- [25] 朱政宇, 王家政, 梁静, 等. 复杂环境下基于联合特征聚类的多跳频网台分选[J]. 通信学报, 2023, 44(9): 218-227.  
ZHU Z Y, WANG J Z, LIANG J, et al. Multi frequency hopping network station sorting based on joint feature clustering in complex environment[J]. Journal on Communications, 2023, 44(9): 218-227. (in Chinese)

### 作者简介



**朱政宇** 男, 1988年5月出生, 河南周口人. 郑州大学电气与信息工程学院副教授、硕士生导师. 主要研究方向为无线通信和信号处理、5G/6G、智能反射面、通感一体化、无线携能传输、毫米波通信、机器学习、物理层安全、凸优化技术和等.

E-mail: [iezyzhu@zzu.edu.cn](mailto:iezyzhu@zzu.edu.cn)



**赵航冉** 男, 2000年1月出生, 河南洛阳人. 郑州大学研究生. 主要研究方向为跳频信号检测与分选.

E-mail: [zhr000124@163.com](mailto:zhr000124@163.com)



**王梓暉** 男, 1998年1月出生, 河南周口人. 郑州大学博士研究生. 主要研究方向为通信信号分析与智能处理.

E-mail: [wzx1356466179@163.com](mailto:wzx1356466179@163.com)



**王忠勇** 男, 1965年8月出生, 江苏遂州人. 郑州大学教师、博士生导师. 主要研究方向为通信信号处理、嵌入式系统.

E-mail: [iezywang@zzu.edu.cn](mailto:iezywang@zzu.edu.cn)



**巩克现** 男, 1976年8月出生, 山东泰安人. 郑州大学教授、博士生导师. 主要研究方向为无线通信信号分析与处理、信道编码、无线接入、目标监测及电子对抗等.

E-mail: [ggkx@163.com](mailto:ggkx@163.com)



**梁静** 女, 1981年6月出生, 河南兰考人. 郑州大学教授、博士生导师. 主要研究方向为演化计算及应用等.

E-mail: [liangjing@zzu.edu.cn](mailto:liangjing@zzu.edu.cn)