



研究与开发

基于最大熵二值化时频图和DL-YOLOv5s的 跳周期估计和跳频频率估计

胡竹艳¹, 王首斌², 刘顺兰¹, 沈雷³

- (1. 杭州电子科技大学电子信息学院, 浙江 杭州 310018;
2. 中国电子科技集团公司第三十六研究所, 浙江 嘉兴 314033;
3. 杭州电子科技大学通信工程学院, 浙江 杭州 310018)

摘 要: 针对低信噪比 (signal-to-noise ratio, SNR) 下跳周期估计和跳频频率估计误差较大的情况, 提出了一种基于最大熵二值化时频图以及检测和定位 (detection and localization, DL)-YOLOv5s 的跳周期估计和跳频频率估计方法。首先, 利用最大熵阈值分割方法结合形态学滤波对时频图进行处理, 获得清晰的最大熵二值化时频图, 再通过提出的 DL-YOLOv5s 模型对最大熵二值化时频图中的跳频信号进行检测和定位, 通过增加 ASPP 模块和 BiFPN 模块, 提高跳频信号的边缘和角点检测精度, 并通过 BOT3 模块引入多头自注意力机制, 提高跳频信号的定位精度, 最后得到跳频信号的坐标位置, 通过坐标的对照关系完成跳周期估计和跳频频率估计。实验结果表明, 相较于 YOLOv5s 模型, 提出的 DL-YOLOv5s 模型精确率 P 提高了 5%, 召回率 R 提高了 2.2%, 平均精度 mAP 0.5 和 mAP 0.5:0.9 分别提高了 5.1% 和 4.2%, 相较于 YOLOv7、YOLOv8 等其他模型, 提出的 DL-YOLOv5s 模型体积更小, 更适用于跳频信号参数估计常用的嵌入式设备这类资源受限的环境, 且相较于传统跳频信号参数估计方法, 提出的方法可以有效降低低信噪比下跳周期估计和跳频频率估计的误差。

关键词: 跳频信号; 低信噪比; 参数估计; YOLOv5s

中图分类号: TN911.73

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2025114

Estimation of hop period and frequency hopping based on maximum entropy binarization of time-frequency maps and DL-YOLOv5s

HU Zhuyan¹, WANG Shoubin², LIU Shunlan¹, SHEN Lei³

1. School of Electronics and Information Engineering, Hangzhou Dianzi University, Hangzhou 310018, China
2. The 36th Research Institute of China Electronics Technology Group Corporation, Jiaxing 314033, China
3. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: In response to the significant estimation errors in hop period and hop frequency under low signal-to-noise

收稿日期: 2024-12-16; 修回日期: 2025-03-27

通信作者: 王首斌, 357513989@qq.com



ratio (SNR) conditions, a method for hop period and hop frequency estimation based on maximum entropy binarization of time-frequency maps and a detection and localization (DL)-YOLOv5s model was proposed. Firstly, the maximum entropy thresholding method combined with morphological filtering was utilized to process the time-frequency map, resulting in a clear maximum entropy binarized time-frequency map. Then, the proposed DL-YOLOv5s model was applied to detect and localize the hop frequency signals within the maximum entropy binarized time-frequency map. By incorporating the ASPP module and BiFPN module, the precision of edge and corner detection for hop frequency signals was enhanced. Additionally, a multi-head self-attention mechanism was introduced to improve the localization accuracy of hop frequency signals by the BOT3 module. Ultimately, the coordinates of the hop frequency signals were obtained, and through the correlation of these coordinates, the estimation of hop period and frequency was completed. The experimental results show that compared to the YOLOv5s model, the proposed DL-YOLOv5s model improves precision (P) by 5%, recall (R) by 2.2%, and the mean average precision (mAP) at 0.5 and mAP at 0.5:0.9 by 5.1% and 4.2% respectively. In comparison to other models such as YOLOv7 and YOLOv8, the proposed DL-YOLOv5s model is smaller in size, making it more suitable for resource-constrained environments like embedded devices commonly used for frequency-hopping signal parameter estimation. Additionally, compared to traditional methods for frequency-hopping signal parameter estimation, the proposed method effectively reduces the estimation errors of hopping period and hopping frequency under low signal-to-noise ratio conditions.

Key words: frequency-hopping signal, low signal-to-noise ratio, parameter estimation, YOLOv5s

0 引言

近年来,扩频通信因其独特的低截获概率、强抗干扰能力、高保密性等优点广泛应用^[1]。而跳频通信作为扩频通信的主要手段之一,拥有扩频通信的种种优势,在短波、超短波电台等领域被广泛采用。在通信对抗和无线电监控领域,跳频信号的检测与参数估计已成为研究重点,但随着电磁环境日益复杂,如何获得准确的跳频信号参数成了难题^[2]。

当前,跳频信号的参数估计方法可分为参数化和非参数化两种。其中,参数化方法往往需要信号的统计特性等先验信息,在非合作通信侦察中适用性不高。非参数化方法则不要求或仅要求少量先验信息,主要为时频分析法^[3]。文献[4-5]利用短时傅里叶变换(short-time Fourier transform, STFT)对跳频信号进行时频表示,但其受窗函数的影响,跳周期估计和跳频频率估计的精度不能同时达到最佳。文献[6]提出采用魏格纳-维尔分布(Wigner-Ville distribution, WVD)进行跳频信号的参数估计,它解决了STFT窗函

数的问题,但容易产生交叉项,对跳频信号的频率估计产生干扰。文献[7]提出采用平滑伪魏格纳-维尔分布(smoothed pseudo Wigner-Ville distribution, SPWVD)对跳频信号进行分析,SPWVD抑制了WVD中的交叉干扰项,但也降低了一定的时频分辨率。文献[8-10]将STFT和WVD或SPWVD相结合,在保持较高时频分辨率的同时抑制了交叉干扰项,但在低信噪比(signal-to-noise ratio, SNR)时,时频分布受噪声影响较大,导致低信噪比下跳频信号参数估计的精度仍然较低。为了提高跳频信号在低信噪比下的参数估计精度,文献[11]将二值化处理和形态学滤波进行结合,通过全局阈值法进行二值化处理,但全局阈值法容易丢失跳频信号的边缘信息。随着深度学习的发展,神经网络模型也被运用到通信领域,但在跳频信号参数估计领域仍然运用得较少。文献[12]利用单次多框检测器(single shot multibox detector, SSD)模型对跳频信号进行参数估计。SSD是一种单阶段目标检测器,能够在单个前向传播中同时进行目标分类和定位,实验结果显示,它对跳频信号进行参数估计时的精度

较高。

YOLOv5s 是 YOLO 系列中的一个轻量级版本，它也采用单阶段检测方法，但相比于 SSD，YOLOv5s 整体上推理速度更快，精度更高，漏检情况更少，尤其在小物体检测方面和实时应用上，YOLOv5s 更具竞争力。相较于 YOLOv7、YOLOv8 等其他模型，YOLOv5s 在精度和速度之间提供了良好的平衡，它是轻量级模型，具有较低的计算复杂度和内存占用，且模型结构相对简单，易于修改和拓展以及部署和集成到现有系统中。对于跳频信号参数估计等功能设备通常为嵌入式设备，YOLOv5s 在资源受限的环境中表现良好，适合实时应用。因此，为了提高在低信噪比下跳周期估计和跳频频率估计的精度，本文提出了一种基于最大熵二值化时频图和 DL-YOLOv5s 的跳周期估计和跳频频率估计方法。

首先，利用最大熵阈值分割方法对时频图进行二值化处理并结合形态学滤波，获得清晰的最高熵二值化时频图。其次，利用本文提出的 DL-YOLOv5s 模型，对最高熵二值化时频图中的跳频信号进行检测和定位，得到跳频信号的坐标。最后，通过 DL-YOLOv5s 得到的信号坐标位置和最高熵二值化时频图中坐标的对照关系，完成跳周期估计和跳频频率估计。

1 最大熵二值化时频图

1.1 跳频信号时频图

跳频信号是一种频率在伪随机序列的控制下不断跳变的非平稳信号，其数学模型为：

$$s(t) = \sum_{k=0}^M \text{rect}_T(t - kT - \tau) e^{j2\pi f_k(t - kT - \tau)} + v(t) \quad (1)$$

其中， T 表示跳频周期， $\text{rect}_T(t)$ 表示宽度为 T 的矩形窗， τ 表示起跳时间， f_k 表示跳变频率， t 表示连续时间变量， M 表示观测时间内跳变频率总数， $v(t)$ 表示高斯白噪声^[13]。

对信号在不同时间窗口上进行短时傅里叶变换，可以得到信号在时间和频率上的变化情况，再对其进行取模平方运算，可以得到时频图。为方便计算机计算，可将信号进行离散化处理，信号离散化后的离散 STFT 表达式如式 (2) 所示。时频图可以展示信号在不同时间和频率上的能量分布情况，帮助分析信号的时频特性，时频图如图 1 (a) 所示，时频图表达式如式 (3) 所示：

$$\text{STFT}_s(k, n) = \sum_{m=-\infty}^{+\infty} s(m)h(n-m)e^{-j2\pi mk/N} \quad (2)$$

$$\text{SPCE}_s(k, n) = |\text{STFT}_s(k, n)|^2 \quad (3)$$

其中， $h(n)$ 表示窗函数， m 是时间窗的离散索引变量， $k=1,2,3,\dots$ 表示离散频率点， $n=1,2,3,\dots,N$ 表示离散时间点。

1.2 最大熵二值化

为了消除噪声的影响，获得清晰的时频图，对其进行二值化处理^[14]。由于全局阈值法在分割图像时只考虑将前景和背景分割最大化，而忽略了边缘和弱对象等信息，本文选用最大熵阈值分割对时频图进行二值化处理。最大熵求阈值原理与天津法类似，天津法是通过最大化类间方差来确定最佳阈值，从而将图像分为前景和背景，而最大熵是通过最大化熵来确定最佳阈值，从而将图像分为前景和背景。时频图处理过程 (SNR = -1 dB) 如图 1 所示。

首先，将时频图通过加权平均法转化为灰度图，如图 1 (b) 所示，计算跳频信号时频图的灰度直方图，得到每个灰度级的频率分布，对于给定的阈值 T ，将时频图分为前景 (灰度值大于 T) 和背景 (灰度值小于 T)，前景和背景的概率分布可以用其直方图来表示。

背景概率分布：

$$P_B(i) = \frac{k(i)}{N_B} \quad (4)$$

其中， $k(i)$ 是灰度值 i 的出现频率， N_B 是背景总像素数。




图1 时频图处理过程(SNR=-1 dB)

前景概率分布:

$$P_F(i) = \frac{k(i)}{N_F} \quad (5)$$

其中, N_F 是前景总像素数。

根据前景和背景的概率分布, 计算它们的熵。

背景熵 H_B :

$$H_B = - \sum_{i=0}^T P_B(i) \log P_B(i) \quad (6)$$

前景熵 H_F :

$$H_F = - \sum_{i=T+1}^{L-1} P_F(i) \log P_F(i) \quad (7)$$

其中, L 是灰度级总数。

总熵 H 是前景熵和背景熵的加权和:

$$H(T) = H_B + H_F \quad (8)$$

通过遍历所有可能的阈值 T , 找到使得总熵 $H(T)$ 最大的阈值 T^* :

$$T^* = \arg \max_T H(T) \quad (9)$$

使用找到的最佳阈值 T^* 对时频图进行二值化处理:

$$I_{\text{binary}}(x, y) = \begin{cases} 1, & I(x, y) > T^* \\ 0, & I(x, y) \leq T^* \end{cases} \quad (10)$$

其中, $I(x, y)$ 是原始时频图的灰度值。

通过上述计算式对时频图进行二值化处理,

可在去除噪声的同时尽量保留跳频信号的边缘信息, 得到最大熵二值化时频图, 如图1(c)所示。但由于噪声的影响, 最大熵二值化时频图仍有一些问题, 可通过多尺度形态学滤波进一步去除噪声的影响。

1.3 多尺度形态学滤波

由于噪声的影响, 时频图转化为最大熵二值化图像后可能会存在有孤立于有用信号图像的噪声点, 或者有用信号图像内部存在空洞, 需要用形态学滤波进行处理, 修复有用信号图像, 主要通过开运算和闭运算。其中开运算主要去除最大熵二值化时频图中的小噪声点, 通过腐蚀操作去除小物体, 再通过膨胀恢复较大物体的形状, 从而帮助清理时频图中的小干扰, 同时保留跳频信号的主要特征。闭运算可以填补信号中的小空洞, 通过膨胀操作连接相邻的信号部分, 再通过腐蚀恢复物体的形状。

形态学滤波是通过设定的结构元素对图像进行运算来获取图像局部特征, 因此在形态学滤波中最重要的就是结构元素的选择, 包括结构元素形状和大小的设置。元素形状会影响对图像中不同形状目标的识别和分割效果, 选择合适的元素形状可以更好地突出目标的轮廓或边缘。最常见的噪声为高斯白噪声, 在最大熵二值化时频图上主要表现为孤立的点, 且时间宽度非常小, 因此本文先选用远小于单跳信号时间宽度的矩形结构元素进行开运算, 去除孤立的噪声点, 再选用尺寸适中且小于单跳信号时间宽度的矩形结构元素进行闭运算, 弥补信号中的空洞。开运算和闭运算的计算式分别如式(11)和式(12)所示:

$$A \circ B = (A \ominus B) \oplus B \quad (11)$$

$$A \cdot B = (A \oplus B) \ominus B \quad (12)$$

其中, A 是最大熵二值化图, B 是结构元素, $\oplus$ 表示膨胀操作, $\ominus$ 表示腐蚀操作。

经过最大熵二值化处理和形态学滤波后可以消除噪声的影响,得到清晰的时频图像,如图1(d)所示。

2 DL-YOLOv5s

2.1 DL-YOLOv5s 网络模型

DL-YOLOv5s 的网络结构如图2所示。主要分为输入端、骨干网络(DL-Backbone)、颈部网络(DL-Neck)和头部网络(Head)。与 YOLOv5s 模型相比, DL-YOLOv5s 在 DL-Backbone 部分用 ASPP 模块代替了原始结构中的空间金字塔池化(spatial pyramid pooling, SPP)模块,可以充分提取跳频信号的形状轮廓等全局特征和角点及边缘等局部特征;用 BOT3 代替了原始结构中最后一个 C3 模块(跨阶段部分网络模块),通过多头自注意力机制,帮助模型聚焦在跳频信号所在的区域,以提高跳频信号定位精度。在 DL-Neck 部分用 BiFPN 模块替换了原始结构中的 PANet 模块,将多尺度的浅层图形特征和用于分辨跳频信号的深层语义特征进行更好的融合,在提高跳频信号定位精度的同时提高跳频信号的边缘检测精度,减少跳频信号漏检情况,降低跳周期估计和跳频频率估计的误差。

DL-YOLOv5s 进行跳周期估计和跳频频率估计的流程如下。

(1) DL-Backbone 部分主要负责对输入(input)的最大熵二值化时频图进行跳频信号特征提取。通过切片聚焦(Focus)模块生成 $320 \times 320 \times 64$ 的跳频信号特征图;再通过卷积(convolution, Conv)模块和 C3 模块构建的深层卷积网络,每经过一个 Conv 与 C3 的组合模块后,特征图会变为原来尺寸的 $1/2$,从而得到不同尺度的跳频信号特征图;然后通过 ASPP 模块以不同采样率的空洞卷积并行采样,充分提取跳频信号的全局特征和局部特征并进行初步交互;最后通过 BOT3 模块提取深层网络中的跳频信号语义特征。

(2) DL-Neck 部分主要负责对不同尺度的跳频信号特征图进行融合。在左路通过上采样(upsample)的方式以及 BiFPN 模块,融合来自 DL-Backbone 中浅层的跳频信号图形特征,在右路通过 BiFPN 模块将浅层的跳频信号图形特征与深层的语义特征实现更高层次的特征融合。

(3) 最终在检测头(Head)端通过 3 个 1×1 卷积检测跳频信号并定位,根据信号坐标位置和时频参数的对照关系,可求得跳周期估计和跳频频率估计。




图2 DL-YOLOv5s的网络结构



2.2 ASPP模块

在跳周期估计和跳频频率估计的任务中,需要对最大熵二值化时频图提取的跳频信号特征具有较大的感受野,同时不降低跳频信号特征图的分辨率,但这两个要求是矛盾的。若想要获取较大的感受野则需要用较大的卷积核或池化时采用较大的步幅,但这一方面会增大计算量,另一方面会降低分辨率导致丢失跳频信号图像边缘的细节信息。而ASPP模块即空洞空间卷积金字塔池化,可以解决模型对于不同尺度的图像信息处理能力不足的问题。ASPP结构如图3所示,ASPP利用不同扩张率的空洞卷积并行采样,进行多尺度的跳频信号特征提取。包括一个 1×1 的卷积层,多个不同扩张率的 3×3 的卷积层以及池化层,池化后的特征信息经过 1×1 的卷积和上采样将最大熵二值化时频图图像尺寸恢复至预期值,最后将得到的所有结果进行拼接来扩大通道数,再通过 1×1 的卷积来将通道数降低到预期值进行输出。从而充分提取跳频信号的全局特征和局部特征并进行初步的交互,并在保持特征图分辨率大小不变的前提下增大感受野。由于全局特征可以反映跳频信号的形状轮廓等整体属性,局部特征更关注角点或边缘等特定关键点,将其进行交互后可进行两种特征之间的优势互补,可以提高跳频信号检测精度,降低跳周期估计和跳频频率估计的误差。




图3 ASPP结构

2.3 BOT3模块

BOT3模块由BOT (bottleneck transformer) 块和3个卷积层组成,其中BOT3模块中最重要的结构为多头自注意力机制 (multi-head self-attention mechanism, MHSA)。注意力机制的核心思想是根据输入序列中各个元素之间的关系来动态地调整对不同元素的关注程度,而多头自注意力机制的引入是为了让模型能够在不同的子空间中并行地学习信息。多头是指将查询、键和值分别线性变换为多个头 (head),每个头都有自己的权重矩阵,对每个头独立计算注意力,再将所有头的输出拼接在一起,并通过一个线性层进行变换和输出。由于多头自注意力机制允许模型在不同的表示子空间中学习信息,可以捕捉到输入数据的多种特征,并且可以并行处理,提高计算效率,通过多个注意力头,模型能够更好地理解输入序列中不同部分之间的关系^[15]。




图4 BOT3结构和BOT结构

本文模型在Backbone的末端通过BOT3模块替换原有的C3模块,因为此处的跳频信号特征映射是较低分辨率的,包含更多的高级语义信息,语义信息越强,模型分辨跳频信号和背景的能力越强,通过深层网络中的语义特征,可以最大程度地区分跳频信号和背景。但网络深度越

深, 关于跳频信号的位置信息越模糊。通过多头自注意力机制, 可以利用多个不同的注意力头对输入图像进行并行计算, 得到空间敏感的相似特征, 从而使模型更容易聚焦在跳频信号所在的区域上, 避免跳频信号位置信息的丢失, 并且可以和浅层网络输出的图形特征相融合, 提高模型对跳频信号的检测和定位精度, 减少跳频信号漏检情况, 降低跳周期估计和跳频频率估计的误差。

2.4 BiFPN 模块

YOLOv5s 在 Neck 网络提出路径聚合网络 (path aggregation network, PANet), 其结构是自顶向下和自底向上的双向融合骨干网络, 但采用该结构网络的信息流动是单向的, 只是自顶向下或自底向上的连接, 这会限制跳频信号特征信息的全局传递能力^[16]。所以本文 DL-YOLOv5s 采用加权特征金字塔网络 (bidirectional feature pyramid network, BiFPN) 替换原有 YOLOv5s 的 PANet 结构, BiFPN 和 PANet 结构对比如图 5 所示, 其中的 P3~P7 表示特征金字塔层级。BiFPN 首先删除对融合不同跳频信号特征性能贡献较小的部分输入边节点; 其次在同一尺度的输入节点到输出节点之间添加一个跳跃连接, 可以融合更多的跳频信号图像特征; 最后将每个双向 (自顶向下和自底向上) 路径看作一个特征网络层, 并多次重复同一层, 以实现更高层次的跳频信号特征融合^[17]。本文模型利用 BiFPN 实现双向特征传播和多分辨率下处理特征, 促进了更彻底、更细致的跨层次信息传递和融合, 即将浅层网络中用于鉴别跳频信号位置和尺度变化等的变性特征 (图形特征) 和深层网络中用于将跳频信号和背景进行分离的不变性特征 (语义特征) 更好地融合, 并引入可学习的权重来确定不同输入特征的重要性, 强化跳频信号特征融合的效果, 提高跳频信号检测和定位的精度, 降低跳周期估计和跳频频率估计的误差。




图 5 BiFPN 和 PANet 结构对比

3 跳周期估计和跳频频率估计

跳周期指跳频信号在相邻两次频率切换之间的时间间隔, 跳频频率指在信号时长内不断变化的频率值^[18]。通过上述 DL-YOLOv5s 网络模型对最大熵二值化时频图进行检测和定位, 可以得到每个跳频信号的坐标位置, 输出跳频信号左上角和右下角的角点位置坐标 $(x1, y1)$ 、 $(x2, y2)$ 。其中, $x1$ 代表跳频信号在时域上的起始位置, $x2$ 代表跳频信号在时域上的结束位置; $y1$ 是跳频信号频率的上边界, $y2$ 是跳频信号频率的下边界。由于需要计算跳周期, 即频率驻留时间和换频时间之和, 还需要下一跳的起始坐标位置, 将其定义为 $x3$, 再将信号坐标和时频参数的对照关系进行计算即可得到跳周期和跳频频率估计值。

$$T = (x3 - x1) / \text{img_long} \times t_size \quad (13)$$

$$F = (y1 + y2) / 2 / \text{img_width} \times f_size \quad (14)$$

其中, img_long 是指改进 YOLOv5s 输出图片的长度, 本文为 640, t_size 是指时频图中时域变量取样的大小, 本文为 0.02 s; img_width 是指 DL-YOLOv5s 输出图片的宽度, 本文为 480, f_size 是指时频图中频域变量取样的大小, 本文为 4.5×10^5 Hz。再将计算得到的结果求切尾均值, 即可得到利用 DL-YOLOv5s 网络估计的跳周期和跳频频率。



4 实验与结果分析

4.1 数据集

使用矩阵实验室 (MATLAB) 生成跳频信号, 用扩频码序列进行频移键控码调制, 并添加高斯白噪声, 信噪比分别为 -5 dB、-3 dB、-1 dB、1 dB、3 dB、5 dB。信号伪码长度为 32, 码速为 1 kbit/s, 采样率为 450 kHz, 跳周期为 1 ms, 频率集为 [100、104、108、112、116、120、124、128、132、136、140、144、148、152、156、160、164、168、172、176、180、184、188、192、196、200、204、208、212、216、220、224] kHz。

首先, 通过短时傅里叶变换对跳频信号进行处理, 得到跳频信号的时频图, 每个信噪比生成 600 张图片, 6 个信噪比共计生成 3 600 张图片, 再批量化对其进行最大熵二值化处理和形态学滤波。按 4:1:1 的比例将图片划分为训练集、测试集和验证集, 即每个信噪比的训练集为 400 张图片, 测试集为 100 张图片, 验证集为 100 张图片。再用 Labelme 制作标签, 将 .png 格式的图片转化为 .json 格式。最后, 利用代码将其转化为 .text 格式。

4.2 训练环境

实验服务器图形处理单元 (graphics processing unit, GPU) 为 NVIDIA TITAN RTX 3090, 使用的深度学习框架为 Pytorch, 模型由 Python 编程语言实现, 使用 Sublime Text3 进行编程。由于采用中央处理器 (central processing unit, CPU) 进行模型训练相对缓慢, 通过 GPU 对网络框架进行模型训练。GPU 采用 NVIDIA TITAN RTX 3090, 模型训练轮次为 100, 损失函数为交叉熵损失函数。

4.3 DL-YOLOv5s 网络模型性能

可以将改进后的 DL-YOLOv5s 模型与 YOLOv5s 模型进行对比。置信度在神经网络模型中指的是模型输出的概率值, 高置信度的预测通常意味着模型对该预测的信心较高, 可能反映出模型在该样本上的表现较好^[19]。模型改进前后置信

度对比如图 6 所示, 为信噪比 5 dB 下对同一张最大熵二值化时频图进行检测的置信度结果输出, 图 6 (a) 表示 YOLOv5s 模型, 图 6 (b) 表示改进后的 DL-YOLOv5s 模型, 可以看出改进后的 DL-YOLOv5s 模型置信度有较大幅度的提高。

除去置信度, 网络模型性能通常通过精确率 P 、召回率 R 、平均精度 mAP 0.5 和 mAP 0.5:0.95 来体现, 这些参数值越高, 说明网络性能越好。计算式如下所示:

$$P = \frac{TP}{TP + FP} \quad (15)$$

$$R = \frac{TP}{TP + FN} \quad (16)$$


$$AP = \int_0^1 P(R) dR \quad (17)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (18)$$

其中, TP 表示正样本预测为正样本的数量, FP 表示负样本预测为正样本的数量, FN 表示正样本预测为负样本的数量, AP 表示平均精度, $P(R)$ 表示在达到召回率 R 时, 模型预测为正样本的数量中有多少是正确的^[20]。

信噪比为 5 dB 下的改进后的 DL-YOLOv5s 模型和 YOLOv5 系列的其他模型以及 YOLOv7、YOLOv8、SSD 模型的性能对比见表 1。

由表 1 可知, 相较于 SSD 模型, YOLOv5 系列模型在精确率、召回率和平均精度方面都要优于 SSD。相较于 YOLOv5s 模型, 改进后的 DL-YOLOv5s 的精确率 P 提高了 5%, 召回率 R 提高了 2.2%, 平均精度 mAP 0.5 和 mAP 0.5:0.9 分别提高了 5.1% 和 4.2%, 可以有效提高模型对跳频信号检测和定位的精度, 降低跳周期估计和跳频频率估计的误差。除此之外, 从表 1 中的模型参数量和模型每秒处理的帧数 (FPS) 可知, 除了 YOLOv5s, 改进后的 DL-YOLOv5s 相较于 YOLOv7、YOLOv8 和 YOLOv5 系列的其他模型, 具有更小的模型体积和更快的推理速度, 且对比



(a) YOLOv5s模型置信度



(b) DL-YOLOv5s置信度

图6 模型改进前后置信度对比

表1 模型性能对比

模型	P	R	mAP 0.5	mAP 0.5:0.95	模型参数量/ $\times 10^6$	FPS
SSD	74.3%	76.4%	73.7%	44.6%	23.1	35
DL-YOLOv5s	87.7%	99.7%	97.1%	56.7%	10.2	101.8
YOLOv5s	82.7%	97.5%	92%	52.5%	7.2	112.6
YOLOv5m	88.3%	96.3%	96.8%	56.4%	21.2	81.6
YOLOv5l	90.7%	99.5%	97.6%	58.1%	46.5	67.9
YOLOv7	89.5%	98.4%	97.3%	57.9%	37.2	77.1
YOLOv8s	88.6%	98.1%	96.8%	56.4%	11.2	95.3

YOLOv7 和 YOLOv8 模型, DL-YOLOv5s 的召回率也更高, 使得跳频信号的漏检率降低, 可以大大降低跳频信号的跳周期估计误差。从表1可以看出, DL-YOLOv5s 的精度和速度以及模型大小之间有一个良好的平衡, 这使得它比较适合于资源受限且需要实时处理的嵌入式设备, 例如在参

数估计的应用场景中。

为了验证不同模块对模型检测效果的影响, 进行了消融实验, 消融实验结果见表2。

由表2可知, 加入了ASPP模块后, 精确率 P 提高了1.8%, 通过充分提取跳频信号的形状轮廓等全局特征和角点及边缘等局部特征, 使得模型



表2 消融实验结果

模型	ASPP	BOT3	BiFPN	P	R	mAP 0.5	mAP 0.5:0.95
1	×	×	×	82.7%	97.5%	92%	52.5%
2	√	×	×	84.5%	97.7%	93.2%	53.4%
3	×	√	×	85.2%	98.5%	94.9%	54.2%
4	×	×	√	85.4%	97.9%	93.9%	53.7%
5	√	√	×	85.8%	98.9%	95.7%	55.8%
6	√	√	√	87.7%	99.7%	97.1%	56.7%


在识别跳频信号时更加准确；加入BOT3模块后，精确率 P 提高了1.3%，召回率 R 提高了1.2%，通过帮助模型聚焦在跳频信号所在的区域，提高模型对跳频信号的定位精度，大大减少信号漏检的情况；加入BiFPN模块后，精确率 P 和召回率 R 分别提高了1.9%和0.9%，通过双向连接，融合多尺度的浅层图形特征和分辨跳频信号的深层语义特征，在提高跳频信号定位精度的同时提高跳频信号的边缘检测精度，降低跳周期估计和跳频频率估计的误差。

4.4 实验结果


将本文提出的方法与传统方法（基于STFT的跳周期估计和跳频频率估计^[4]、基于SPWVD的跳周期估计和跳频频率估计^[7]）以及深度学习方法（基于SSD的跳周期估计和跳频频率估计^[11]和基于YOLOv5s的跳周期估计和跳频频率估计）进行比较，跳周期估计和跳频频率估计实验结果如图7所示。

从实验结果可以看出，在低信噪比情况下，本文提出的基于最大熵二值化时频图和DL-YOLOv5s的跳周期估计和跳频频率估计方法与其他方法相比可以更有效地降低误差。在信噪比为-5 dB时，本文提出的方法相比于基于STFT的跳周期估计和跳频频率估计方法误差降低了约2个数量级；在信噪比为-3 dB时，本文提出的DL-YOLOv5s模型与SSD模型相比降低了约1个数量级，大大降低了信号漏检导致的跳周期估计误差；在信噪比为-1 dB时，与基于SPWVD的跳周期估计和跳频频率估计

方法相比误差也有大幅降低；与YOLOv5s模型相比，本文提出的DL-YOLOv5s检测精度更高，跳周期估计和跳频频率估计误差也更小。



(a) 跳周期估计误差



(b) 跳频频率估计误差

图7 跳周期估计和跳频频率估计实验结果

5 结束语

本文提出了基于最大熵二值化时频图和DL-

YOLOv5s 的跳周期估计和跳频频率估计方法。通过最大熵阈值分割方法对时频图进行二值化处理,并结合形态学滤波消除噪声的影响,提出了 DL-YOLOv5s 模型进行跳周期估计和跳频频率估计,通过 ASPP 模块充分提取跳频信号的形状轮廓等全局特征和角点及边缘等局部特征;通过 BOT3 模块引入多头自注意力机制,帮助模型聚焦在跳频信号所在的区域,提高跳频信号定位精度和减少漏检情况;通过 BiFPN 模块引入双向连接,融合多尺度的浅层图形特征和分辨跳频信号的深层语义特征,在提高跳频信号定位精度的同时提高跳频信号的边缘检测精度,降低跳周期估计和跳频频率估计的误差。实验表明,与其他方法相比,本文提出的方法在低信噪比下可以有效降低跳周期估计和跳频频率估计的误差,具有较好的鲁棒性。

参考文献:

- [1] 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. Research on detection, parameter estimation and sorting algorithm of frequency hopping signal[D]. Chengdu: University of Electronic Science and Technology of China, 2016.
- [2] 沙志超, 黄知涛, 周一宇, 等. 基于稀疏重构的跳频信号时频分析方法[J]. 通信学报, 2013, 34(5): 107-112.
SHAZ C, HUANG Z T, ZHOU Y Y, et al. Time-frequency analysis of frequency-hopping signals based on sparse recovery[J]. Journal on Communications, 2013, 34(5): 107-112.
- [3] 周磊. 复杂噪声中跳频信号参数估计研究[D]. 西安: 西安电子科技大学, 2018.
ZHOU L. Research on parameter estimation of frequency hopping signal in complex noise[D]. Xi'an: Xidian University, 2018.
- [4] YU L. Research on parameter blind estimation algorithm of Costas frequency hopping signals[J]. Systems Engineering and Electronics, 2012, 3: 444-450.
- [5] MA Y K, YAN Y C. Blind detection and parameter estimation of single frequency-hopping signal in complex electromagnetic environment[C]//Proceedings of the 2016 Sixth International Conference on Instrumentation & Measurement, Computer, Communication and Control (IMCCC). Piscataway: IEEE Press, 2016: 370-374.
- [6] 王忠仁, 林君, 李文伟. 基于 Wigner-Ville 分布的复杂时变信号的时频分析[J]. 电子学报, 2005, 33(12): 2239-2241.
WANG Z R, LIN J, LI W W. Time-frequency analysis for complex time-varying signals based on Wigner-Ville distribution[J]. Acta Electronica Sinica, 2005, 33(12): 2239-2241.
- [7] CHEN T C. Joint signal parameter estimation of frequency-hopping communications[J]. IET Communications, 2012, 6(4): 381-389.
- [8] 付卫红, 王璐, 贾坤, 等. 基于 STFT 与 SPWVD 的跳频参数盲估计算法[J]. 华中科技大学学报(自然科学版), 2014, 42(9): 59-63.
FU W H, WANG L, JIA K, et al. Blind parameter estimation algorithm for frequency hopping signals based on STFT and SPWVD[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2014, 42(9): 59-63.
- [9] 钱怡, 马庆力, 路后兵. 基于改进 SPWVD 的 DS/FH 信号跳频参数估计方法[J]. 舰船电子对抗, 2015, 38(1): 50-53, 79.
QIAN Y, MA Q L, LU H B. Estimation method of frequency hopping parameter of DS/FH signal based on improved SPWVD[J]. Shipboard Electronic Countermeasure, 2015, 38(1): 50-53, 79.
- [10] 申艳妮. 非平稳信号的频谱感知方法研究[D]. 成都: 电子科技大学, 2018.
SHEN Y N. Research on spectrum sensing method of non-stationary signal[D]. Chengdu: University of Electronic Science and Technology of China, 2018.
- [11] 席有猷, 李志刚, 王苗. 结合图像处理与时频分析的直扩/跳频信号参数估计[J]. 电讯技术, 2014, 54(8): 1071-1076.
XI Y Y, LI Z G, WANG M. Parameters estimation of DS/FH signal based on image processing and time-frequency analysis[J]. Telecommunication Engineering, 2014, 54(8): 1071-1076.
- [12] 王宇阳, 黄浩, 陶建军. 基于图像处理的跳频信号参数估计和双网台分选[J]. 通信技术, 2023, 56(5): 604-610.
WANG Y Y, HUANG H, TAO J J. Parameter estimation and dual-network station sorting of frequency hopping signal based on image processing[J]. Communications Technology, 2023, 56(5): 604-610.
- [13] 刘佳敏, 赵知劲, 尚俊娜, 等. 基于时频矩阵局部对比度的跳频信号参数估计[J]. 电信科学, 2021, 37(10): 126-135.
LIU J M, ZHAO Z J, SHANG J N, et al. Parameter estimation of frequency hopping signal based on time-frequency matrix LCM[J]. Telecommunications Science, 2021, 37(10): 126-135.



- [14] 曾诚, 宋燕. 改进的OTSU和最大熵结合的迭代图像分割算法[J]. 智能计算机与应用, 2020, 10(12): 121-125.
ZENG C, SONG Y. An improved image segmentation algorithm based on OTSU and maximum entropy[J]. Intelligent Computer and Applications, 2020, 10(12): 121-125.
- [15] 李卫. 视觉Transformer模型设计及其轻量化研究[D]. 成都: 电子科技大学, 2023.
LI W. Design of visual Transformer model and its lightweight research[D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [16] 黄文才. 复杂环境下跳频信号的提取与参数估计[D]. 成都: 电子科技大学, 2021.
HUANG W C. Extraction and parameter estimation of frequency hopping signal in complex environment[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [17] 侯公羽, 陈钦煌, 杨振华, 等. 基于改进YOLOv5的安全帽检测算法[J]. 工程科学学报, 2024, 46(2): 329-342.
HOU G Y, CHEN Q H, YANG Z H, et al. Helmet detection method based on improved YOLOv5[J]. Chinese Journal of Engineering, 2024, 46(2): 329-342.
- [18] 王川川, 张宽桥, 王满喜. 基于时频变换和波形整形的跳频信号参数估计方法[J]. 强激光与粒子束, 2024, 36(9): 157-163.
WANG C C, ZHANG K Q, WANG M X. Parameter estimation method for frequency hopping signal based on time-frequency transform and waveform shaping[J]. High Power Laser and Particle Beams, 2024, 36(9): 157-163.
- [19] 崔昊杨, 杨可欣, 葛海华, 等. 面向电力开关柜的轻量型GB-YOLOv5m状态检测方法[J]. 电子与信息学报, 2022, 44(11): 3777-3787.
CUI H Y, YANG K X, GE H H, et al. Lightweight GB-YOLOv5m state detection method for power switchgear[J]. Journal of Electronics & Information Technology, 2022, 44(11): 3777-3787.

- [20] 王硕凡. 复杂场景下多视角行人重识别与跟踪研究[D]. 南京: 东南大学, 2023.
WANG S F. Research on pedestrian re-recognition and tracking from multiple perspectives in complex scenes[D]. Nanjing: Southeast University, 2023.

[作者简介]



胡竹艳 (2000-), 女, 杭州电子科技大学电子信息学院硕士生, 主要研究方向为数字信号处理。



王首斌 (1984-), 男, 博士, 中国电子科技集团公司第三十六研究所高级工程师, 主要研究方向为电子战系统总体技术。



刘顺兰 (1965-), 女, 杭州电子科技大学电子信息学院教授, 主要研究方向为无线通信、通信信号处理。



沈雷 (1979-), 男, 博士, 杭州电子科技大学通信工程学院教授, 主要研究方向为图像处理和信号处理。