



·前沿技术与交叉科学·

基于谱图分解的宽带通信信号智能检测算法*

易 冬¹, 马瑞鹏², 胡 涛¹, 成凯鑫¹, 吴 迪¹, 田志富¹, 王艳云¹

(1. 信息工程大学 数据与目标工程学院, 郑州 450001; 2. 郑州大学 网络空间安全学院, 郑州 450002)

摘 要: 对于宽带通信信号检测问题, 针对目前基于深度学习的信号检测算法不适应于处理大带宽和大时宽的宽带信号以及对信号时频参数估计存在的固有偏差问题, 提出基于谱图分解的宽带通信信号智能检测算法, 完成对大带宽接收信号中窄带信号的高效准确检测。首先将由宽带信号转化而来的灰度时频谱图通过谱图分解得到适合于目标检测网络输入大小的子谱图, 然后使用改进的无锚框 YOLOx 目标检测算法对子谱图中的窄带信号进行检测, 最后将子谱图的信号检测结果融合得到窄带信号的时频参数等检测结果。经过实验测试得出, 该算法能够适应复杂的噪声环境, 与其他深度学习算法和传统算法相比, 具有较高的信号检测概率, 较低的虚警概率, 较小的信号参数估计平均误差, 其检测精度更高, 鲁棒性、实用性、通用性更强。

关键词: 谱图分解; 宽带多信号检测; YOLOx; 时频谱图; 短时傅里叶变换

中图分类号: TN911

文献标志码: A

doi: 10.11884/HPLPB202335.230024

Intelligent detection algorithm of broadband communication signal based on spectral decomposition

Yi Dong¹, Ma Ruipeng², Hu Tao¹, Cheng Kaixin¹, Wu Di¹, Tian Zhifu¹, Wang Yanyun¹

(1. School of Data and Target Engineering, University of Information Engineering, Zhengzhou 450001 China;

2. School of Cyberspace Security, Zhengzhou University, Zhengzhou 450002 China)

Abstract: For broadband communication signal detection problem, as the current signal detection algorithm based on deep learning is not suitable for dealing with large bandwidth and large wide broadband signals, and there is the inherent deviation in signal frequency parameter estimation, we put forward intelligent broadband communication signal detection algorithm based on spectrum decomposition, thus to complete highly accurate detection of narrow-band signal in large bandwidth receiving signal. First, the broadband signal is transformed into a grayscale time-frequency spectrum which is subsequently decomposed into a sub-spectrum suitable for the input size of the target detection network. Then, the anchor-free YOLOx target detection algorithm is used to detect the narrowband signal targets in the sub-spectrum. Finally, the signal detection results of the sub-spectrum are fused to obtain the detection results of the time-frequency parameters of the narrow-band signal. Experimental results show that the proposed algorithm can adapt to the complex noise environment. Compared with other deep learning algorithms and traditional energy detection algorithms, the proposed algorithm has higher signal detection accuracy, lower false alarm probability, smaller average error of signal parameter estimation, and stronger robustness, practicability and versatility.

Key words: spectral decomposition, wide-band signal detection, YOLOx, time-frequency diagram, short time Fourier transform

通信信号检测^[1-2], 是通信信号处理领域的经典问题, 一直以来都是研究热点。在战场环境当中, 为了获取更多的通信情报, 需要掌握足够宽的频带范围, 并利用有效的宽带信号检测技术发现有用信号^[3]。在无线电监测等大带宽信号检测场景中, 准确的宽带信号检测技术可以实现对非法授权用户的准确发现, 保护合法用户对无线电频谱资源的安全使用, 具有十分重要的现实意义^[4]。

目前经典有效的宽带信号检测方法大多是基于频谱的信号检测方法^[5-6]。张超等人对形态学滤波算法进行改

* 收稿日期: 2023-01-11; 修订日期: 2023-03-02

联系方式: 易 冬, yidong2021@sina.cn。

通信作者: 马瑞鹏, 13164351610@163.com。

进并得到了更为平滑的噪声基底,但是该算法中估计的噪声基底存在信号成分,在低信噪比下检测性能较差^[7]。蒋天立等人提出了多尺度形态学滤波下的宽带信号检测方法,该方法能够有效估计噪声基底,使修正后的频谱能够更好地用于信号的检测^[8]。但是该算法仍然难以有效检测一些弱信号和突发信号,同时也只能粗略得到信号个数、载波频率、信号带宽等简单参数,仍然难以精确获取信号的出现时刻和带宽等相关参数。

随着深度学习的快速发展,以及其在诸多领域的优越性能^[9-10],许多学者将其应用于通信信号处理领域,并解决了信号检测方面的一部分难题^[11-12]。O'Shea等人将宽带无线电信号转化为时频谱图,利用YOLOv1网络检测时频谱图中的信号,效果优于传统的基于能量检测的方法^[13]。查雄等人先将宽带信号转化为灰度时频谱图,之后将目标检测网络SSD与YOLOv3先后应用于灰度时频谱图中的信号检测,不但可以估计窄带信号时频等参数还可以估计其调制样式^[14-15]。李润东等人同样利用YOLOv3网络检测时频谱图当中的信号^[16],对YOLOv3网络做了一些微小的改进,在提高训练速度的同时达到了较高的信号检测精度。基于YOLOv3和SSD网络的宽带信号检测,可直接对宽带数据进行处理,能够在低信噪比条件下检测出信号的中心频率和起止时间等,且对时频混叠和色噪声不敏感,适合工程应用。

目前基于深度学习的信号检测算法,一是大多是基于固定锚框的,当对时频谱图中的窄带信号进行检测时,由于窄带信号尺度多样,先验锚框并不通用,以致目标检测网络对窄带信号定位不够准确。二是为了有效区别出宽带信号中的每一个窄带信号,在实际当中往往需要产生大分辨率时频谱图,这种时频谱图与固定的网络的输入大小相比是较大的,这种时频谱图输入目标检测网络当中首先会被压缩。许多窄带信号的谱图信息会被大量压缩,以致目标检测网络无法有效提取到谱图中的窄带信号特征,造成训练后的目标检测网络无法有效检测谱图中的窄带信号,出现漏检现象。

本文提出基于谱图分解的宽带通信信号智能检测算法,首先将大分辨率的时频谱图进行谱图分解,生成多个子谱图。然后对每一个子谱图进行信号检测,最后将所有子谱图的信号检测结果融合,得到大分辨率时频谱图的信号检测结果,以此适应各种带宽和时宽的宽带信号检测。同时通过使用无锚框的YOLOx目标检测算法,提高了信号定位精度,达到了对大瞬时带宽、大时宽,大动态范围内信号的准确检测,加强了算法的鲁棒性,更具实用价值。

1 信号模型

设宽带接收机接收的宽带信号频段范围为 $B_s = [f_L, f_R]$,接收信号的起止时间为 $T_s = [t_L, t_R]$,在频段范围 B_s 内存在 N_s 个窄带信号。设第 i 个信号占用的频段范围为 $B_i = [f_i^L, f_i^R]$,且时间范围为 $T_i = [[t_i^{L_1}, t_i^{R_1}], \dots, [t_i^{L_{M_i}}, t_i^{R_{M_i}}]]$,其中 $i \in [1, N_s]$, $f_L < f_1^L < f_1^R < \dots < f_{N_s}^R < f_R$, $t_L < t_1^L < t_1^R < t_R$, $t_1^L < t_1^R < t_2^L < \dots < t_i^{R_{M_i}}$, M_i 表示第 i 个信号在时间范围 T_s 内存在的时间片段数。本文算法最终的目的是获得频段范围 B_s 内各个窄带信号的频段范围 B_i 以及其信号时间范围 T_i 。

设接收的宽带信号离散化的时域数据为 $x(n)$,则通过短时傅里叶变换(STFT)可得到其二维时频矩阵

$$\mathbf{A}(n, k) = \sum_{m=0}^{N-1} [x(n+m)w(m)]e^{(-j2\pi mk/N)} \quad (1)$$

式中: n 和 k 分别是时间和频率变量; $w(n)$ 是长度为 N 的滑动窗函数,为了适应复杂的信号环境,一般选择主瓣能量较高且旁瓣抑制明显的海明窗作为窗函数。

在得到时频矩阵 $\mathbf{A}(n, k)$ 之后,需要对其灰度化得到灰度时频谱图,如式(2)所示,用 \mathbf{Y} 表示时频谱图灰度化后的矩阵,其中函数 $\text{unit8}(\cdot)$ 具有将括号里面矩阵的每个数四舍五入取整到0到255这256个整数上的功能,恰好对应灰度图中像素值的范围。

$$\begin{cases} X_0 = 20 \times \lg(|\mathbf{A}(n, k)|) \\ \mathbf{Y} = \text{unit8} \left(\frac{X_0 - \frac{\max(X_0) - \min(X_0)}{2}}{\max(X_0) - \min(X_0)} \times 255 + 128 \right) \end{cases} \quad (2)$$

图1为某一宽带信号时频谱图,从时频谱图中可以清晰的观察出接收带宽内各窄带信号的时频分布,各窄带信号的




Fig. 1 Signal time spectrum diagram

图1 信号时频谱图

调制方式包括 {2FSK, 4FSK, 8FSK, MPSK}。因此本文以时频谱图作为宽带信号检测的基本数据模型。

2 算法结构

本文提出了一种基于谱图分解的宽带通信信号智能检测算法,其算法结构如图2所示,主要分为三个部分:信号预处理部分、信号智能检测部分和信号检测结果融合部分。

2.1 信号预处理

在信号预处理阶段,经过STFT和灰度化可得到时频谱图。若直接将分辨率比较大的时频谱图作为目标检测网络的输入,由于目标检测输入大小一般较小,所以原图需要压缩之后再输入到目标检测网络。如图3所示,原图压缩后输入到目标检测网络,会有大量的目标信息丢失,导致目标检测网络对原图中的目标特征信息学习不充分或者无法学习,使得目标检测网络无法有效的检测到原图中的目标。

如图4所示,设目标检测网络的实际输入大小为 $W_{input} \times H_{input}$,目标检测网络可检测实际输入图像中的最小目标尺寸为 $a_{input} \times b_{input}$,子图中的最小目标尺寸为 $a_{subgraph} \times b_{subgraph}$,那么谱图分解窗的大小 $W_{subgraph} \times H_{subgraph}$ 应满足

$$\begin{cases} W_{subgraph} \leq W_{input} \times \frac{a_{subgraph}}{a_{input}} \\ H_{subgraph} \leq H_{input} \times \frac{b_{subgraph}}{b_{input}} \end{cases} \quad (3)$$

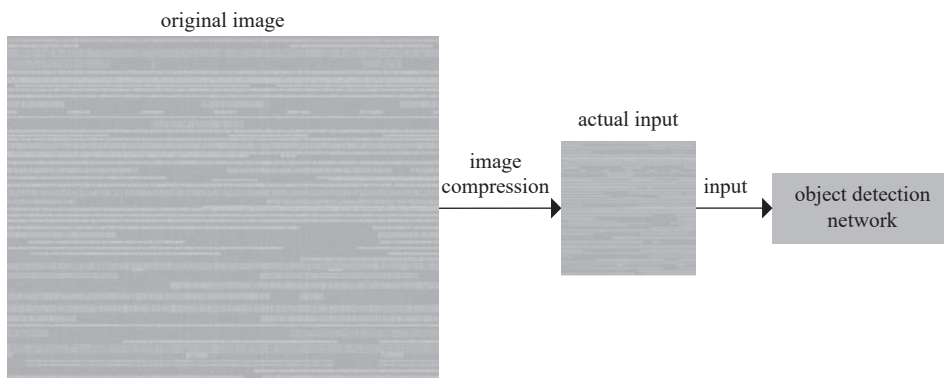


Fig. 3 Original image is directly fed into the target detection network

图3 原图直接输入目标检测网络




Fig. 4 Original image is decomposed and input into the target detection network

图4 原图经分解后输入目标检测网络

当对目标检测网络训练时,在生成子谱图的时候,同时需要将原时频谱图中窄带信号的标签转换为对应为子谱图中的标签,便于网络训练。为了合理保留标签,如式(4)所示,本文定义带宽保留率(Bandwidth Retention, BR),

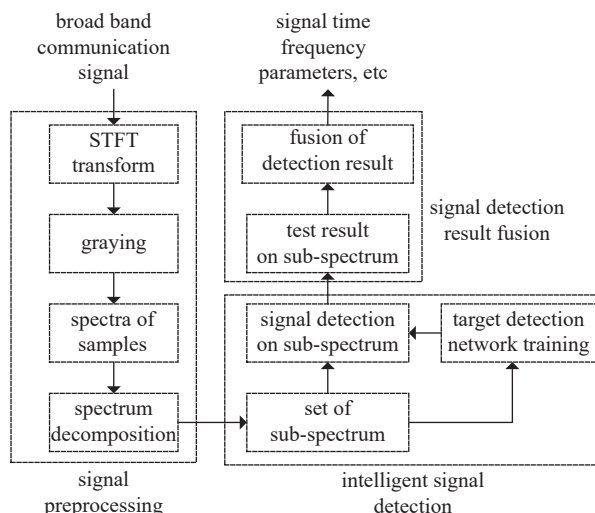


Fig. 2 Structure of intelligent detection algorithm for large bandwidth time-width communication signal based on spectral decomposition

图2 基于谱图分解的大带宽时宽通信信号智能检测算法结构

重叠时宽 (Overlap Time, OT) 并根据它们的大小决定如何转换标签。

$$\begin{cases} R_b = \frac{h_1 \cap h_2}{h_2} = \frac{h_3}{h_2} \\ T_o = w_1 \cap w_2 = w_3 \end{cases} \quad (4)$$

式中: h_1, w_1 是谱图分解窗的高度与宽度; h_2, w_2 是窄带信号的高度与宽度; h_3, w_3 是二者交集的高度与宽度。

设谱图分解窗当前位置为 $W = (W_{xmin}, W_{ymin}, W_{xmax}, W_{ymax})$, 某一窄带信号在时频谱图中的位置坐标框为 $T = (T_{xmin}, T_{ymin}, T_{xmax}, T_{ymax})$, 其转换到对应子谱图的新坐标为 $N = (N_{xmin}, N_{ymin}, N_{xmax}, N_{ymax})$ 。如图 5 所示, 当窄带信号与谱图分解窗存在重叠时, 计算 BR 与 OT。如式(5)所示, 若重叠时宽不小于最小可识别目标的宽度时, 且有一定的带宽保留率, 本文设其保留阈值为 0.1, 则考虑转换后窄带信号在子谱图中的位置坐标 N 。可得新坐标 $N = (N_{xmin}, N_{ymin}, N_{xmax}, N_{ymax}) = (T_{xmin} - W_{xmin}, T_{ymin} - W_{ymin}, T_{xmax} - W_{xmin}, T_{ymax} - W_{ymin})$ 。

$$\begin{cases} R_b > 0.1 \\ T_o > H_{input} \times \frac{b_{subgraph}}{b_{input}} \end{cases} \quad (5)$$

2.2 信号智能检测

在信号智能检测阶段, 利用 YOLOx 目标检测网络逐一对所有子谱图进行信号检测。

YOLOx 算法^[17], 由刘松涛等人于 2021 年提出, 属于一阶段算法中的无锚框的算法, 适用于实时多尺度目标检测, 是目前性能较好的目标检测算法。图 6 展示了 YOLOx 算法检测流程。

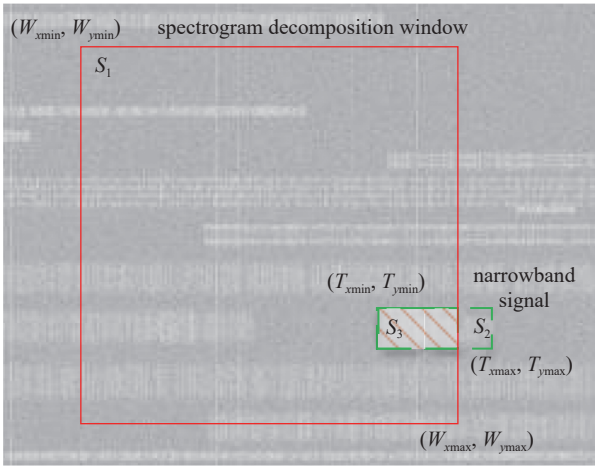


Fig. 5 Relative distribution of narrowband signal and spectral decomposition window

图 5 窄带信号与谱图分解窗口的相对分布情况

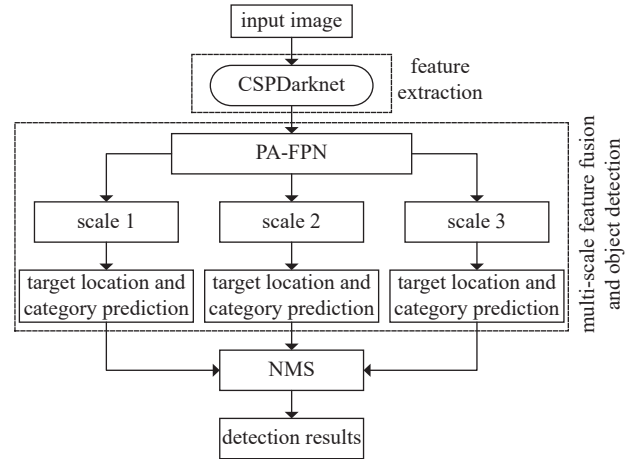


Fig. 6 YOLOx algorithm detection process

图 6 YOLOx 算法检测流程

首先通过 CSPDarknet 网络提取输入图像的特征; 然后通过 PA-FPN 结构进行特征融合, 得到 3 个尺度的特征层; 之后在 3 个特征层上分别通过解耦头实现对目标位置的回归预测与类别的分类预测; 最后通过非极大值抑制 (Non Maximum Suppression, NMS) 算法^[18] 对上一步的输出进行筛选, 得到最优检测结果。

为了更好地适应宽带信号检测任务, 本文从定位损失方面对 YOLOx 算法进行改进。标准的 YOLOx 算法使用的是交并比 (Intersection over Union, IOU) 损失^[19], 其计算式如式(6), 其中 $\hat{b} = [x', y', w', h']$ 和 $b = [x, y, w, h]$ 分别是预测和真实边框的坐标值, $S_b \cap S_b$ 为两个边框交集区域的面积, $S_b \cup S_b$ 为两个边框并集区域的面积。

$$\begin{cases} I_{ou}(b', b) = \frac{S_b \cap S_b}{S_b \cup S_b} \\ L_{IOU} = 1 - I_{ou}(b', b) \end{cases} \quad (6)$$

L_{IOU} 存在两个问题: 一是预测框和真实框不相交时, 不能反映出二者的距离的远近, 此时 L_{IOU} 等于 1, 没有梯度的回传无法进一步学习训练。二是预测框和真实框相交时, 无法反映二者是如何相交的, 如图 7 所示, 三者具有相同的 L_{IOU} , 但实际上它们的重合程度是不一样的。




Fig. 7 The same IOU border overlapping situation contrast

图 7 IOU 相同的边框交叠情况对比

为了解决标准 IOU 函数不可导与难以表征边框位置差异的问题,采用了一种 CIOU(Complete IOU)函数^[20]作为训练时的坐标回归误差函数,计算公式为

$$L_{\text{CIOU}} = 1 - I_{\text{ou}}(b', b) + \frac{\rho^2(b', b)}{c^2} + \alpha v \quad (7)$$

式中: $\rho^2(\hat{b}, b)$ 表示两个边框中心点的欧式距离; c 为包含两个边框的最小矩形边框的对角线距离; α 是权重参数; v 用来度量两个边框长宽比的相似性, v 的定义为

$$v = \frac{4}{\pi^2} \left[\arctan\left(\frac{w}{h}\right) - \arctan\left(\frac{w'}{h'}\right) \right]^2 \quad (8)$$

该代价函数兼顾了边框的重叠面积、中心点距离和长宽比等边框回归中的重要几何关系,训练时可以实现更快的收敛速度,实际用于检测时可以达到更高的检测精度。

2.3 信号检测结果融合

在信号检测结果融合阶段,需要将子谱图的信号检测结果融合,得到大分辨率时频谱图的窄带信号预测标签。

首先将各个子谱图的预测框坐标映射到原时频谱图中。第 j 张子谱图的坐标为 W^j , 设第 j 张子谱图中预测的第 i 个窄带信号的坐标为 $P^i = (P_{x\min}^i, P_{y\min}^i, P_{x\max}^i, P_{y\max}^i)$, 映射到原时频谱图中的坐标设为 $T^{i,j} = (T_{x\min}^{i,j}, T_{y\min}^{i,j}, T_{x\max}^{i,j}, T_{y\max}^{i,j})$, 则 $T^{i,j}$ 满足

$$\begin{cases} T_{x\min}^{i,j} = P_{x\min}^i + W_{x\min}^j, & T_{y\min}^{i,j} = P_{y\min}^i + W_{y\min}^j \\ T_{x\max}^{i,j} = P_{x\max}^i + W_{x\max}^j, & T_{y\max}^{i,j} = P_{y\max}^i + W_{y\max}^j \end{cases} \quad (9)$$

子谱图坐标映射到原时频谱图之后,将会出现一个信号有不同位置的多个预测框,如图 8 上图所示,一个频点的信号出现 A 至 F 六个预测框,其中 A 是特定位置处的子谱图中的预测框, B、E 是其右相邻子谱图中的预测框, C 是其下相邻子谱图中的预测框, D、F 是其右下相邻子谱图中的预测框,由于该频点处的信号为突发信号,因此会出现一个频点信号,对应多个时间片段。最后结果的输出,需要将这些预测结果融合起来,如图 8 所示。




Fig. 8 Diagram of prediction box fusion process

图 8 预测框融合过程示意图

本文通过定义带宽重叠率(Bandwidth overlap rate, BOR),并通过设置阈值找出属于同一个频点信号的预测框。设图 8 中框 A 与框 B 的高度范围为 h_A, h_B 。则框 A 与框 B 的带宽重叠率为

$$R_{\text{BO}} = \frac{h_A \cap h_B}{\min\{h_A, h_B\}} \quad (10)$$

设同一时频谱图的所有子谱图筛选后的预测框集合为 PreBoxes, 预测框的融合过程为:

Step1. 新建一个空集合 NewSignal, 在集合 PreBoxes 中随机挑选一个预测框, 将其转移到 NewSignal 当中, 转 Step2。

Step2. 设 BOR 阈值 TH_{BOR} , 集合 PreBoxes 中遍历预测框, 若遍历到的预测框与集合 NewSignal 中的任一预测框的 BOR 大于 TH_{BOR} , 则将其转移到集合 NewSignal 中, 转 Step3。

Step3. 集合 NewSignal 中的所有预测框在空间位置上取并集, 如图 8 下图所示, 得到新的预测框集合, 将其作为同一个信号的各个片段集合保留下来, 转 Step4。

Step4. 若集合 PreBoxes 不为空则转 Step1, 若集合 PreBoxes 为空则融合完毕。

3 实验

本节中, 将利用仿真生成的包含噪声和多径衰落的宽带信号数据对本文提出的算法、基于能量检测的传统方法和同类深度学习方法进行对比分析, 同时还通过实验分析了信号预分类和使用 CIOU 损失对算法检测性能的影响。

3.1 数据集与实验条件

为了快速分析算法性能和保证数据样本的多样性和标注窄带信号信息的简便性, 仿真生成宽带信号, 并将宽带信号转化为时频谱图。数据集的主要构建参数如表 1 所示。

表 1 仿真数据集主要参数
Table 1 Results of experiments

parameter	values	parameter	values
bandwidth range	0~3200 kHz	signal types	wideband real signal
sampling frequency	6400 kHz	time range	2000 ms
time-frequency spectrum frequency resolution	1 kHz	time-frequency spectrum time resolution	1 ms
size of time-frequency spectrum	3200×3999	the number of narrowband signals in a wideband signal	40~70
target signal frequency range	5~3115 kHz	target signal bandwidth range	5~100 kHz
target signal modulation pattern	2FSK, 4FSK, 8FSK, MPSK	whether there is a burst signal	yes
burst signal burst interval	10~1500 ms	burst signal duration	10~1500 ms
parameter	values	parameter	values
channel environment	Rayleigh fading channel + non-stationary undulation noise + α -stabilized noise		
number of target signals in training set	800 time-frequency spectrums, a total of 40 854 signals, 75% for training, 25% for validation		
number of target signals in test set	0~20 dB stepped at 2 dB, and 100 time-frequency spectrums under each SNR, with a total of 61 373 signals		

按照表 1 参数构造的信号时频谱图样本示例如图 1 所示。可以看出,时频谱图中部分窄带信号因为衰落严重,或调制指数过大等原因产生了严重的带内分裂,同时部分信号在一定程度上产生了时频混叠。这种接近真实接收条件的恶劣信道情况,更有利于测试算法在复杂电磁环境下的检测效能。

训练和测试之前,需要将时频谱图通过谱图分解生成 640×640 的子谱图集合,训练时将子谱图输入网络,设置学习率衰减方式为周期余弦退火,利用 Adam 优化算法进行训练,最大训练周期数(epochs)设为 200,前 50 个周期冻结主干网络训练,特征提取网络不发生改变,每次更新的批大小为 16,学习率初始值设置为 0.000 1,后 150 个周期模型的主干不被冻结了,特征提取网络会发生改变,每次更新的批大小为 8,学习率初始值设置为 0.000 01。训练中使用早停止(early stopping)正则化策略,早停止周期数设为 10。实验中使用 NVIDIA RTX6000 GPU 训练和测试算法,利用 Python 语言在 TensorFlow2.4.0 框架上实现算法模型。

3.2 检测性能指标

在进行实验之前,先将算法对比采用的性能指标介绍如下。

(1) 检测概率 P_d : 假设待检测的实际窄带信号总数为 N , 检测出的窄带信号个数为 M , 其中真实有窄带信号的个数为 M_d , 虚假结果个数为 M_f 。 P_d 为检测到的真实窄带信号个数占实际窄带信号总数的比例, 计算 P_d 的表达式为

$$P_d = \frac{M_d}{N} \quad (11)$$

评判检出的窄带信号是否为真实窄带信号的标准为: 窄带信号在时频图中的预测边框与真实边框的 IOU 值大于 0.8 时, 则认为检测到了真实信号, 否则为虚假结果。对于能量检测的方法, 无法检测到信号的起止时间, 只能检测信号在某个频率范围内有无信号, 因此能量检测方法评判检出的窄带信号是否为真实窄带信号的标准为: 当该信号带宽范围与真实信号带宽范围的 IOU 值大于 0.8 时, 则认为检测到了真实信号, 否则为虚假结果。

(2) 虚警概率 P_f : P_f 为检测出的虚假窄带信号个数占检测出的窄带信号总数的比例, 计算 P_f 的表达式为

$$P_f = \frac{M_f}{M_d + M_f} = \frac{M_f}{M} \quad (12)$$

(3) 信号参数平均误差 E_{avg} : E_{avg} 是针对检测到的所有真实窄带信号, 统计其频率、带宽和突发起止时刻参数 $f_c^i, B_w^i, t_s^i, t_e^i$ 与对应真实参数 $f_c^i, B_w^i, t_s^i, t_e^i$ 之间的平均相对误差, 其计算公式为

$$E_{avg} = \sum_{i=1}^{M_d} \frac{|f_c^i - f_c^i| + |B_w^i - B_w^i|}{4M_d B_w^i} + \sum_{i=1}^{M_d} \sum_{j=1}^{N^i} \frac{|t_s^j - t_s^j| + |t_e^j - t_e^j|}{4M_d N^i T^j} \quad (13)$$

其中, 若检测到的第 i 个信号为连续信号, 则 $N^i = 1$, 且 $1 \leq j \leq N^i$, 若检测到的第 i 个信号为突发信号, N^i 为检测到的突发个数, T^j 为其相应的信号时长。对于能量检测的算法, 无法检测到信号的突发起止时刻, 因此在统计该方法的 E_{avg} 指标时, 仅对频率和带宽的平均相对误差进行统计。

3.3 检测性能对比分析

开展实验对本文检测算法,基于能量检测的传统算法和其他深度学习检测算法进行性能对比分析。能量检测采用文献 [8] 介绍的方法,称其为 SDE(Signal Detection based on Energy)方法;其他深度学习检测采用文献 [15] 提出的基于 YOLOv3 的检测方法。

从图 9(a)中可以看出文献 [15] 算法的检测概率在几乎为零,基本上检测不到有用信号。主要是因为文献 [15] 算法直接对未经谱图分解的时频谱图进行信号检测,未经谱图分解的时频谱图输入检测网络时,时频谱图会被压缩,对于本文时频谱图,其大小由 3200×3999 压缩至 640×640 ,即约原图大小的 $1/31$,大量窄带信号特征在压缩过程中丢失,以致目标检测网络无法有效提取到窄带信号特征,也无法对时频谱图中的窄带信号进行有效的检测。

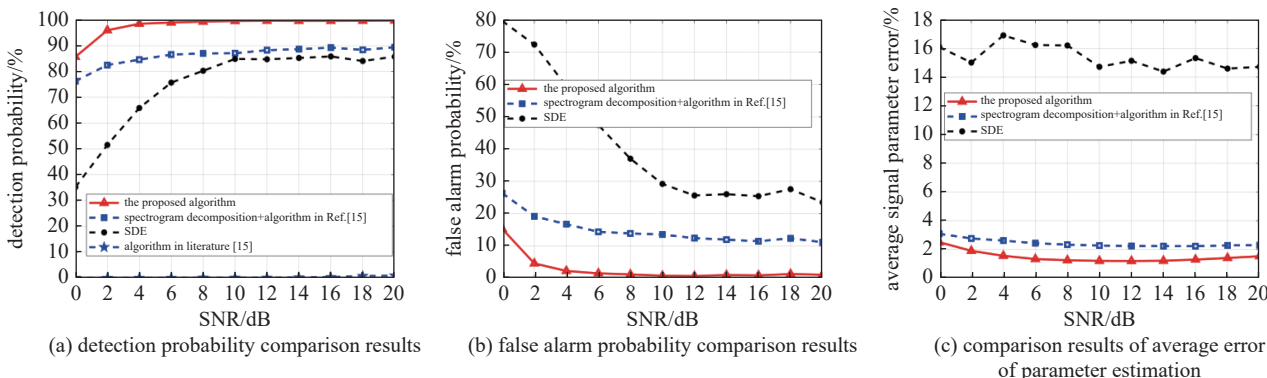


Fig. 9 Performance comparison of detection algorithms

图 9 各检测算法性能对比

要使目标检测网络有效提取到窄带信号特征,就需要对时频谱图进行分解,得到适合于网络输入的子谱图,再将子谱图输入目标检测网络中进行信号检测。

从图 9(a)可以看出时频谱图进行谱图分解之后再使用文献 [15] 的信号检测算法,最后在进行检测结果的融合,其检测性能有一个明显的提升,其检测性能要优于能量检测的算法,低于本文算法。实验采用的仿真信号引入了较严重的起伏噪声、信号衰落、信号混叠等不利影响,导致信号质量较差。虽然 SDE 方法进行了一定程度的自适应噪声抵消处理,但是仍然难以适应衰落的信道条件和较强噪声的影响。同时由于很多 FSK 等信号的调制指数过大,产生了明显的带内分裂,从而将一个信号误检为多个,导致其检测性能较差,低于采用谱图分解与深度学习体制的算法。本文算法使用无锚框的 YOLOx 目标检测算法,使得本文算法无论是在检测精度上、虚警概率上还是参数估计平均误差上,都优于谱图分解结合文献 [15] 的算法。

本文算法有较高的信号检测精度,但是更高的精度是否会带来处理速度的下降。为此进一步对相同条件下两种深度学习算法对单张子谱图的平均检测时间进行了对比,结果如表 2 所示。由表 2 可知本文算法的检测速度优于谱图分解结合文献 [15] 的算法,因此本文算法兼顾了检测精度与实时性的要求,更利于工程部署。

表 2 检测网络对单子谱图的检测时间

Table 2 Detection time of monad spectra detected by the network

detection algorithm	single sub-spectrum detection time/ms
proposed algorithm	45.0
spectrogram decomposition combined with Ref. [16]	50.1

3.4 信号预分类对检测性能的影响分析

由于不同调制样式的信号在时频图上表现出了不同的图形差异,因此一些基于深度学习的信号检测算法在对宽带中的窄带信号进行检测的同时,还能够对窄带信号的调制样式进行粗分类。本小结将通过实验探讨窄带信号预分类对宽带信号智能检测性能的影响。

根据信号在时频图上表现出来的图形差异,本小结将仿真产生的数据集的信号预分类集合设置为 {2FSK, 4FSK, 8FSK, MPSK}。图 10 展示了谱图分解结合文献 [15] 的算法和本文算法在仿真数据集是否预分类下,经过网络训练,对测试集的测试结果。对窄带信号进行预分类可以使得检测算法在检测到信号的同时,对检测到的信号




Fig. 10 Performance comparison of intelligent detection algorithms under preclassification of signal targets

图 10 窄带信号是否预分类下的智能检测算法性能对比

的调制样式进行一定的粗分类,这对后续的调制识别有一定的帮助,但从图 10 中可以看出,无论是对于谱图分解结合文献 [15] 的算法以及本文的算法,对信号进行预分类,一定程度上降低了信号检测性能,特别是在低信噪比的条件下,这种降低更加明显。因此若对宽带信号的低信噪比检测精度要求不高,同时不需要获得信号较为准确的调制样式的信息,可以对待检测的信号进行预分类。如果对信号检测精度要求比较高,特别是低信噪比下的信号检测精度,建议将检测待检测的窄带信号统一归为一类。

3.5 检测性能对比分析

由于 IOU 损失的一系列缺点,本文采用 CIOU 损失替换算法当中的 IOU 损失,以实现算法性能上的提升。图 11 中可以看出无论是在检测概率、虚警概率还是参数估计平均误差上,算法采用 CIOU 损失的性能要好于算法采用 IOU 损失。这是因为标准 IOU 函数不可导且难以表征边框位置差异的问题,而 CIOU 解决了这些问题,使得算法的性能得以提升。




Fig. 11 Comparison of detection performance of the proposed algorithm under CIOU loss and IOU loss

图 11 采用 CIOU 损失与 IOU 损失下的本文算法检测性能对比

4 结论

本文指出目前基于深度学习的信号检测算法存在的两个问题:不适应于处理大带宽大时宽的宽带信号和对参数估计不够准确的问题;通过对上述两个问题的分析,提出了基于谱图分解的宽带通信信号智能检测算法:首先,通过谱图分解将原时频谱图分解生成多个子谱图;然后,使用 YOLOx 目标检测算法对子谱图中的窄带信号进行检测得到初步信号检测结果;最后,通过检测结果融合算法,得到大分辨率时频谱图的信号检测结果。

实验表明,本文算法能适应复杂的信号噪声环境,能够处理大带宽大时宽的通信信号,同时具有较高的检测精度,较低的虚警概率,较小的信号参数估计平均误差,有利于实际工程应用。

参考文献:

- [1] Green D M, Swets J A. Signal detection theory and psychophysics[M]. New York: Wiley, 1966.
- [2] Abdzadeh-Ziabari H, Champagne B. Signal detection algorithms for single carrier generalized spatial modulation in doubly selective channels[J]. *Signal Processing*, 2020, 172: 107539.
- [3] 胡涛. 宽带侦察接收机前端研制[D]. 成都: 电子科技大学, 2018. (Hu Tao. Development of wideband reconnaissance receiver front end[D]. Chengdu:

University of Electronic Science and Technology of China, 2018)

- [4] Joykuttu A M, Baranidharan B. Cognitive Radio Networks: Recent advances in spectrum sensing techniques and security[C]//2020 International Conference on Smart Electronics and Communication (ICOSEC). 2020.
- [5] Cheng Qian, Gong Kexian, Zhang Min, et al. An efficient wide-band signal detection and extraction method[J]. *MATEC Web of Conferences*, 2021, 336: 04011.
- [6] 魏东兴, 殷福亮. 采用离散小波变换的认知无线电频谱能量检测[J]. *信号处理*, 2014, 30(3):306-313. (Wei Dongxing, Yin Fuliang. Spectrum energy detection using discrete wavelet transform for cognitive radios[J]. *Journal of Signal Processing*, 2014, 30(3): 306-313)
- [7] 李敏乐, 毕大平, 韩佳辉. 基于形态学运算的子带频谱检测算法[J]. *探测与控制学报*, 2017, 39(4): 49-53,60. (Li Minle, Bi Daping, Han Jiahui. Sub-band spectrum detection algorithm based on morphological operation in complicated noise environment[J]. *Journal of Detection & Control*, 2017, 39(4): 49-53,60)
- [8] 蒋天立, 彭华, 巩克现. 多尺度形态学滤波下的宽带信号检测方法[J]. *信号处理*, 2014, 30(9): 1055-1063. (Jiang Tianli, Peng Hua, Gong Kexian. Signal detection in wideband reconnaissance using multi-scale morphological filter[J]. *Journal of Signal Processing*, 2014, 30(9): 1055-1063)
- [9] Du Xuedan, Cai Yinghao, Wang Shuo, et al. Overview of deep learning[C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC). 2016.
- [10] Mathew A, Amudha P, Sivakumari S. Deep learning techniques: an overview[C]//International Conference on Advanced Machine Learning Technologies and Applications. Singapore: Springer, 2020.
- [11] Dörner S, Cammerer S, Hoydis J, et al. Deep learning based communication over the air[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 132-143.
- [12] O'Shea T J, Roy T, Clancy T C. Over-the-air deep learning based radio signal classification[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 168-179.
- [13] O'Shea T, Roy T, Clancy T C. Learning robust general radio signal detection using computer vision methods[C]//2017 51st Asilomar Conference on Signals, Systems, and Computers. 2017: 829-832.
- [14] Zha Xiong, Peng Hua, Qin Xin, et al. A deep learning framework for signal detection and modulation classification[J]. *Sensors*, 2019, 19(18): 4042.
- [15] 查雄. 基于神经网络的数字调制信号检测, 识别与解调算法[D]. 郑州: 战略支援部队信息工程大学, 2020. (Zha Xiong. Research on digital modulation signal detection, recognition and demodulation based on neural network [D]. Zhengzhou: Information Engineering University, 2020)
- [16] Li Rundong, Hu Jianhao, Li Shaoqian, et al. Blind detection of communication signals based on improved YOLO3[C]//2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP). 2021: 424-429.
- [17] Ge Zheng, Liu Songtao, Wang Feng, et al. YOLOX: Exceeding YOLO series in 2021 [DB/OL]. arXiv preprint arXiv: 2107.08430, 2021.
- [18] Shepley A, Falzon G, Kwan P. Confluence: A robust non-IoU alternative to non-maxima suppression in object detection[DB/OL]. arXiv preprint arXiv: 2012.00257, 2020.
- [19] Yu Jiahui, Jiang Yuning, Wang Zhangyang, et al. UnitBox: An advanced object detection network[C]//Proceedings of the 24th ACM International Conference on Multimedia. 2016.
- [20] Zheng Zhaohui, Wang Ping, Liu Wei, et al. Distance-IoU loss: Faster and better learning for bounding box regression[C]//Proceedings of the Thirty-Fourth AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020.