



研究与开发

基于镜像填充谱与 LA-ResNet50 的超短波卫星信道分类识别算法

吴尚^{1,2}, 沈雷¹, 王李军^{1,2,3}, 张如栩¹, 胡鑫¹

(1. 杭州电子科技大学通信工程学院, 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 314000;

3. 通信信息控制和安全技术重点实验室, 浙江 嘉兴 314000)

摘要: 针对超短波频段中存在的 5 kHz 信道、25 kHz 信道、宽带干扰信道、窄带干扰信道和单音干扰信道的分类识别问题, 提出了一种基于镜像填充谱与局部二值模式的注意力机制残差网络 (LBP attention ResNet50, LA-ResNet50) 的超短波信道分类识别方法, 有效解决了低信噪比下卫星信道与底噪难以区分, 信号信道与特征相近的干扰信道识别困难的问题。首先, 所提方法对超短波的频谱进行镜像对称并填充, 同时对频谱边缘进行描黑处理, 构成镜像填充谱, 提高不同类型信道频谱图的区分度; 然后, 在 ResNet50 中引入通道注意力机制, 使网络模型关注度集中在信道上; 最后, 提出了基于交叉熵和局部二值模式 (local binary pattern, LBP) 的损失函数, 提高对信号信道和干扰信道图像边缘细微纹理特征的提取效果。所提基于镜像填充谱和 LA-ResNet50 的方法, 对比利用快速傅里叶变换 (fast Fourier transform, FFT) 频谱门限阈值分类的传统方法与基于镜像填充谱的 YOLOv5s 目标检测分类法, 以及基于镜像填充谱的注意力机制残差网络 (Attention-ResNet50)、Transformer 网络方法, 在 10 dB 信噪比下对超短波信道的分类识别率分别提高了 19.8%、8.2%、1.8%、0.8%。

关键词: 超短波信道; 注意力机制; 分类识别; ResNet50

中图分类号: TN911.73

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023185

Ultrashort wave satellite channel classification and recognition algorithm based on mirror filled spectrum and LA-ResNet50

WU Shang^{1,2}, SHEN Lei¹, WANG Lijun^{1,2,3}, ZHANG Ruxu¹, HU Xin¹

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

2. The 36th Research Institute of China Electronics Technology Corporation, Jiaxing 314000, China

3. Key Laboratory of Communication Information Control and Security Technology, Jiaxing 314000, China

Abstract: In response to the classification and identification problems of 5 kHz channels, 25 kHz channels, broadband interference channels, narrowband interference channels, and single tone interference channels in the ultrashort wave frequency band, a classification and identification method for ultrashort wave channels based on mirror filled

收稿日期: 2023-06-08; 修回日期: 2023-10-10

基金项目: 国家自然科学基金资助项目 (No.62072121); 浙江省尖兵领雁项目 (No.2023C01143)

Foundation Items: The National Natural Science Foundation of China (No.62072121), The "Pioneer" and "Leading Goose" Research and development Program of Zhejiang (No.2023C01143)

spectrum and LA-ResNet50 (LBP attention ResNet50) was proposed. The problem of difficulty in distinguishing between satellite channels and background noise under low signal-to-noise ratio, as well as the identification of signal channels and interference channels with similar characteristics, has been effectively solved. Firstly, the proposed method performs mirror symmetry on the ultrashort wave spectrum and fills it in, while blackening the edges of the spectrum to construct a mirror-filled spectrum, which improves the discrimination of different types of channel spectra. Then, channel attention was introduced into ResNet50 to focus the attention of the network model on the channel. Finally, a loss function based on cross entropy and local binary pattern (LBP) was proposed to improve the extraction effect of subtle texture features on signal channels and interference channels images. The proposed method based on mirror-filled spectrum and LA-ResNet50 has shown an improvement of 19.8%, 8.2%, 1.8%, and 0.8% in classification accuracy for ultrashort wave channels compared to the traditional method utilizing fast Fourier transform (FFT) spectrum thresholding, the YOLOv5s target detection and classification method based on mirror-filled spectrum, the Attention-ResNet50 method with attention mechanism based on mirror-filled spectrum, and the Transformer network method under a signal-to-noise ratio (SNR) of 10 dB.

Key words: ultrashort wave channel, attention mechanism, classification and identification, ResNet50

0 引言

超短波通信具有优异的性能,其优点包括通信简单可靠、机动灵活、抗毁性较强等^[1]。超短波频段是通信系统的常用频段,一方面由于超短波有一定的绕射能力,能够在城市、山区等复杂场景下提供远距离传输;另一方面,与短波相比,超短波可提供较大带宽进行信息传输^[2]。随着无线通信技术的不断发展,工业、生活中电子通信设备的广泛应用,电磁环境变得越来越复杂,电磁环境日益恶劣,通信可靠性和稳定性受到严重影响,使得超短波频段中存在各类异常干扰^[3]。超短波卫星信道分类识别不仅要目标信道识别,也要对非法占用频谱资源的异常干扰信道分类识别^[4]。同时超短波频谱易受地形、天线、天气等影响,底噪起伏不定,存在信噪比降低的情况,给信道分类识别带来困难。

传统方法中,信道分类识别通常从频谱能量和形状特征上出发,通过频谱中能量起伏结合信道带宽形状在频域上判断信道有无,计算量较低,实现较为简单,有利于工程部署。在稳定的底噪环境中,文献[5]和文献[6]研究了一种新型的能量双门限联合频谱的信道分类方法,与传统的单一地利用频谱

能量特征的分类识别方法相比,显著提高了识别率。文献[7]研究了基于频谱上信号能量的分类识别技术,提出了改进型频谱能量检测算法,在能量检测器和能量比检测器的基础上,提出了一种混合频谱能量检测算法,该算法不仅考虑了噪声不确定性对系统性能的影响,而且有效克服了传统频谱能量探测器的感知故障和大计算问题。文献[8]研究了不同信噪比信号下的最优相关窗口尺寸和最优谱相关比,提出了一种自适应相关窗口频谱能量检测算法,可以解决检测低信噪比信号时检测性能差的问题,但是,以上传统方法大多是判断信道的有无,针对信号信道在异常干扰信道存在的情况,传统的分类识别方法难以区分信号信道和干扰信道,且超短波信道能量波动受天线以及环境影响较大,分类识别性能对环境以及噪声较为敏感,在低信噪比下适用性较低。

深度学习方法给传统的调制方式识别问题带来了新的解决方案,可以利用深度学习训练这些信号频谱图来获得自动分类识别调制方式的能力。文献[9]通过信号短时傅里叶变换的时频图与卷积神经网络相结合的超短波特定信号识别方法,自动依据信号特征进行调制方式分类识别,但低信噪比下特征不明显,识别率较低。文献[10]



提出了一种利用 ResNet-50 深度学习模型, 基于星座密度矩阵的调制分类识别算法, 在调制方式识别上有较好的效果。文献[11]提出了一种将时域和频域进行压缩构成频谱图的方法, 使图片有更丰富的信号特征, 再将图片输入卷积神经网络进行调制方式的分类识别, 有效地提高了识别率。

目标检测是深度学习领域的一个基础任务和研究热点, YOLO 的网络模型将目标检测概括为一个回归问题, 实现端到端的训练和检测, 由于其良好的速度-精度平衡, 近几年一直处于目标检测领域的领先地位, 被成功地研究、改进运用到超短波信道的目标检测中^[12]。文献[13]提出基于频谱叠加的处理方式构成频谱图, 突出频谱与噪声的差异, 从而扩充图片中的信道特征, 再通过 YOLOv5s 网络模型分类识别宽带频谱中不同的信道类型, 但频谱叠加处理需要大量的数据, 计算量较大。

近年来 Transformer 网络的改进利用给分类识别带来了巨大的优势, 文献[14]提出了一种采用基于注意力机制的 Transformer 网络对信号进行进一步的特征提取并分类。针对任意形状的场景文本检测与识别, 均表现出了优秀的性能。文献[15]提出了一种融合 Transformer 编码器和变分自编码器的随机 Transformer 多维时间序列异常检测模型, 该网络模型对分类检测的时间效率具有一定的优势, 但是, Transformer 网络在全局特征的融合上具有较好的能力, 但忽视了局部特征的处理, 因此在信道分类识别上性能略有不足。

综上所述, 目前深度学习的方法在超短波信道的分类上使用较少, 多集中在调制方式上, 而忽视了信号信道以及干扰信道的分类识别, 同时存在低信噪比下频谱特征不明显导致深度学习方法分类识别率较低的问题。

本文在残差网络的基础上提出了一种基于镜像填充谱与 LA-ResNet50 网络超短波信道分类识别方法, 将传统的超短波信道分类识别问题, 转化为图像分类处理问题, 可以得到较好的分类识别效果。所提算法首先通过快速傅里叶变换处理天线采集的超短波宽带信号, 将处理后得到的频谱进行镜像对称并填充, 同时对频谱外部边缘做描黑处理, 构成镜像填充谱, 扩大图片中信道信息部分相对背景底色的占比。接着, 利用 YOLOv5s 网络模型对超短波宽带镜像填充谱上的信号信道以及干扰信道进行检测获取目标图片, 最后通过 LA-ResNet50 网络进行分类识别训练。

LA-ResNet50 在 ResNet50 中引入通道注意力机制, 注意力机制显式地建模特征通道之间的相互依赖关系, 通过学习的方式获取每个通道的重要程度, 对各个通道上的镜像填充频谱图像特征进行加权, 从而突出超短波频谱中信道特征而减少对底噪特征的关注度, 解决低信噪比下噪声和信号信道以及干扰信道区分不明显的问题。同时提出一种通过基于交叉熵和局部二值模式 (local binary pattern, LBP) 的损失函数度量和提取镜像填充频谱图中信道的局部纹理信息, 提高对不同类型信道特征差异的提取效果, 从而提升分类识别率。

1 基于 LA-ResNet50 的超短波信道分类识别算法

超短波天线接收到的目标卫星频段中主要存在 5 kHz 信道、25 kHz 信道、宽带干扰信道、窄带干扰信道、单音干扰信道。通过本文提出的基于镜像填充谱与 LA-ResNet50 的超短波信道分类识别方法, 对上述 5 类信道进行分类识别, 其流程如图 1 所示。




图1 基于镜像填充谱与 LA-ResNet50 的超短波信道分类识别方法流程

首先,通过超短波天线采集目标卫星信号数据,信号数据通过快速傅里叶变换后得到超短波信号宽带频谱,并对频谱进行上下对称翻转,通过颜色填充空白区域部分,将对称的频谱边缘进行描黑处理得到宽带镜像填充谱;然后,利用YOLOv5s目标检测模型获取宽带镜像填充谱中的5类信道,制作图片数据集;再次,构建引入通道注意力机制并采用交叉熵和LBP损失函数的残差网络模型,构成本文提出的LA-ResNet50;最后,将获取的不同信道类型的镜像填充谱数据集输入LA-ResNet50得到分类识别结果。

1.1 超短波信号接收处理

目标卫星超短波信号通过双单元螺旋天线和超短波接收机实地采集并进行处理。天线采用圆极化方式,增益为15 dBi。采集的超短波信号通过接收机对目标频段滤波,得到中心频率为255 MHz、带宽为40.96 MHz的宽带超短波信号数据。天线架设地点为浙江省杭州市杭州电子科技大学,具体方位为东经120°20'24",北纬30°18'52"。天线采集超短波信号来自两个方向的同步轨道卫星,一是太平洋方向,具体位置为东经78.5°;二是印度洋方向,具体位置为东经172°。

1.2 镜像填充谱图片生成

3种类型频谱图对比如图2所示。传统的方式通过快速傅里叶变换(fast Fourier transform, FFT)得到频谱图片,信号频谱数据占比整张图片面积较少,相对而言,大部分面积为无效的白色底色背景信息,如图2(a)所示,为此提出通过对原始频谱进行上下反转对称处理,丰富图片信息,得到对称频谱,如图2(b)所示。再对上下翻转后的镜像谱线间通过填充的方式覆盖白色底色背景,进一步增大了频谱信息占比面积,同时对填充以后的上下谱线边缘通过描黑的处理方式,勾勒出频谱边缘信息得到镜像填充谱,如图2(c)所示。




图2 3种类型频谱图对比

通过以上图片处理方式得到的镜像填充谱,频谱信息占比扩大到原始频谱的两倍以上,进一步提高了5类不同信道的图片特征,同时通过边缘勾勒描黑处理,把频谱中存在的信道与底噪边缘信息体现出来,有效地增加了噪声与信道的区分度,有利于后续卷积神经网络对图片中的特征提取。

1.3 使用YOLOv5s进行信道捕获且归一化处理

为了获取超短波信号中存在的5类不同信道,采用了YOLOv5s目标检测模型,标记并检测宽带镜像填充谱中存在的信道,对信号信道以及干扰信道特征图片进行获取。由于捕获后得到的图片尺寸大小不一致,为了保证数据的一致性和可比性,统一将图像分辨率归一化为三通道224 pixel×224 pixel大小,捕获后不同类型信道镜像填充谱如图3所示。

捕获且归一化后得到的5类信道图片,有效频谱面积得到放大,无效底色背景信息占比较少,信道特征更加明显。

1.4 LA-ResNet50 框架结构

LA-ResNet50结构见表1。




图3 捕获后不同类型信道镜像填充谱

表1 LA-ResNet50 结构

层名称	输出特征图大小/pixel	LA-ResNet50
Conv1	112×112	7×7,64,stride 2
Conv2	56×56	[3×3 max pool ,stride 2] [1×1,64;3×3,64;1×1,256]×3
Conv3	28×28	[1×1,128;3×3,128;1×1,512]×4
Conv4	14×14	[1×1,256;3×3,256;1×1,1 024]×6
Conv5	7×7	[1×1,512;3×3,64;1×1,2 048]×3
	1×1	Average pool,5-d fc, softmax

表1中 $[\cdot]$ 代表一个残差块,残差块内部网络结构如图4所示。




图4 残差块内部网络结构

其中,5- d 代表5种不同类型的输入图片,输入经过3个不同大小的卷积层和激活函数 ReLU 映射后,再经过残差函数 $F(x)$ 和通道注意力机制的计算与原输入相加后得到残差块的输出。网络中通

过多个残差块的反馈计算有效地提高网络模型的性能^[16]。LA-ResNet50 采用残差模块避免了堆叠网络层数带来的网络梯度消失和网络退化问题^[17],具有较好的特征提取和分类识别能力。

1.5 通道注意力机制

加入通道注意力机制使网络模型更倾向于关注图片中信号信道与干扰信道的镜像填充谱特征而非背景底噪区域,有利于网络模型的特征提取^[18],解决低信噪比下信道特征不明显特征提取能力较差的问题。通道注意力机制示意图如图5所示。




图5 通道注意力机制示意图

图5中,通道注意力机制模块包含3个部分:压缩、激励以及加权操作。假设输入特征图为 x ,其尺寸为 $W \times H \times C$ 。第一步是压缩操作,对输入 x 进行全局平均池化,将每个通道上的特征值空间特征均压缩为一个实数,此时,特征图尺寸变为 $1 \times 1 \times C$,每一个实数均代表各自通道上具备全局感受野的全局特征;第二步为激励操作,包含两个全连接层,第一个全连接层对压缩操作的输出进行降维,达到减少参数数量的目的,第二个全连接层用来恢复原始维度,学习不同特征通道之间的非线性关系并得到表示每个通道重要性的权

重矩阵；第三步是加权操作，将激励操作输出的通道重要性权重矩阵与输入特征图对应通道相乘进行加权，从而实现对重要特征的增强和对无用特征的抑制^[19]。

1.6 交叉熵和 LBP 损失函数设计

为了增强网络模型对底噪和信号信道以及干扰信道的区分度上差异的关注，提高不同类型图像在细微边缘的对比度，本文提出了交叉熵损失和 LBP 损失对网络模型进行约束。损失函数表达式如式 (1) 所示。

$$L_{\text{total}} = L_s + L_{\text{lbp}} \quad (1)$$

其中， L_{total} 为网络模型训练过程中的总损失， L_s 为交叉熵损失， L_{lbp} 为 LBP 损失。 L_s 增加了各类图像之间的差异，使实际分类结果更接近预期的分类结果。 L_s 的计算式如式 (2) 所示。

$$L_s = -\frac{1}{N} \sum_{i=1}^N \ln \left(\frac{e^{w_{yi}^T f_i + b_{yi}}}{\sum_{j=1}^n e^{w_{yj}^T f_i + b_{yj}}} \right) \quad (2)$$

其中， N 为训练集中的一批图像的个数， n 为训练集中分类的类别数， f_i 为特征值直方图 i 的特征向量， y_i 为对应的 f_i 类别， w_j 为权重矩阵 W 的第 j 列， b_j 为偏置项。

为了关注信道中信号起伏毛刺的精细纹理特征，添加了 LBP 损失作为网络模型的纹理损失约束。 L_{lbp} 的计算式如式 (3) 所示。

$$L_{\text{lbp}} = \frac{1}{N} \sum_{i=1}^N \left[\left\| f_{\text{lbp}}(x_i^a) - f_{\text{lbp}}(x_i^p) \right\|_2^2 - \left\| f_{\text{lbp}}(x_i^a) - f_{\text{lbp}}(x_i^n) \right\|_2^2 + \alpha \right] \quad (3)$$

其中， x_i^a 和 x_i^p 为同一类别的第 i 个不同特征图， x_i^n 为来自 x_i^a 不同类别的第 i 个不同特征图， α 为正负之差常数， $f_{\text{lbp}}(\cdot)$ 为 LBP 纹理特征提取函数。计算式如式 (4) 所示。

$$f_{\text{lbp}}(x) = \sum_{d=0, (p_i, q_i) \in \Omega_c}^7 s(x(p_c, q_c) - x(p_i, q_i)) \cdot 2^d, \quad (4)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

其中， Ω_c 为中心点 (p_c, q_c) 的邻域，值域为 1， $s(\cdot)$ 为符号函数。LBP 值的计算过程如下：将目标像素点值与周围像素点值进行比较。如果当前像素点值大于邻域的目标像素点值，将当前像素点值设为 1，否则设为 0，则得到 8 个像素点的决策值。将 8 位二进制数转换为十进制数，得到邻域的 LBP 值。

2 实验与结果分析

实验服务器 GPU 为 NVIDIA TITAN RTX 3090，使用的深度学习框架为 Pytorch。输入图像分辨率为 224 pixel×224 pixel 的 3 通道的图像，模型训练使用批处理大小为 64，训练迭代次数为 50，初始学习率为 3×10^{-4} ，每次训练的学习率衰减系数为 0.7，模型解冻参数为 2，正则化项的系数为 8。

2.1 实验数据集

由于当前没有公开的超短波信道分类的数据集可以使用，故本实验数据集来自实验室的超短波双单元螺旋天线采集。实际每类图片通过 MATLAB 2022a 添加加性高斯白噪声，信噪比为 -10~25 dB，跨度为 5 dB，5 类不同类型信道，8 种不同的信噪比的图片数据，图片训练集合每种类型不同信噪比下 4 000 张，验证集合每种类型不同信噪比下 1 000 张。训练测试信号样本数据见表 2。

2.2 模型性能评价指标

本文将模型提取的超短波信道频谱特征进行可视化，从可视化的特征图中可以直观看出模型对于图像的关注点，以及模型是否学习到频谱中不同于底噪的信道特征。

本文也使用相同信噪比下不同类型信道的



表2 训练测试信号样本数据

训练集			测试集		
信道类型	信噪比范围/dB	图片数量/张	信道类型	信噪比范围/dB	图片数量/张
5 kHz	-10~25	4 000	5 kHz	-10~25	1 000
25 kHz	-10~25	4 000	25 kHz	-10~25	1 000
宽带干扰	-10~25	4 000	宽带干扰	-10~25	1 000
窄带干扰	-10~25	4 000	窄带干扰	-10~25	1 000
单音干扰	-10~25	4 000	单音干扰	-10~25	1 000

识别准确率, 以及不同信噪比下各个网络模型平均识别准确率的曲线图比较模型性能。识别率通过 Top1 排序统计比较, 比较当前识别结果与正确结果进行验证, 将验证图像与模板和类外图像进行比对, 统计模板排序为第一的比例。各个模型准确率通过统计 5 类信号识别准确率的平均值绘制曲线图直观反映各个模型的性能效果。

2.3 特征图可视化

使用 ResNet50、Attention-ResNet50 和 LA-ResNet50 3 种不同的网络框架模型分别对 15 dB 下 5 kHz 信道、25 kHz 信道以及 3 种不同带宽的干扰信道图像进行测试, 通过可视化模型分别提取特征, 并绘制可视化热力图。分类识别特征图可视化如图 6 所示, 热力图中的深色区域是模型学习到的超短波频谱中不同类别信道的特征, 即模型在识别时关注的区域。

图 6 (a) 中分别为 5 kHz 信道、25 kHz 信道、宽带干扰信道、窄带干扰信道以及单音干扰信道的镜像填充频谱图片。通过在 3 种不同网络模型下提取特征的可视化热力图对比得到各个网络模型对信道的关注度。从图 6 (b)、图 6 (c)、图 6 (d) 中矩形框区域可以明显看出针对 5 类信道不同网络模型的效果。在原始的 ResNet50 中模型关注度发生偏移且集中在信道边缘部分, 还存在关注区域错误的问题, 如图 6 (b) 所示。在 Attention-ResNet50 中, 模型关注区域得到有效扩大, 但是存在关注较少且分散、关

注区域不够集中的问题, 如图 6 (c) 所示。本文提出的 LA-ResNet50 中, 有效地增大了网络模型对信道的关注区域, 且关注区域集中在信道上, 减少了存在关注偏移、错误的问题, 如图 6 (d) 所示。LA-ResNet50 大幅度提高对目标信道的关注效果, 而不关注背景以及底噪的无效信息, 从而能更加准确地关注目标图像中的信道特征。

2.4 信道分类识别性能仿真分析

对比基于频谱门限阈值的传统方法、YOLOv5s、ResNet50、Attention-ResNet50、Transformer 以及 LA-ResNet50 5 种算法在信噪比为 15 dB 的数据集上进行的分类识别仿真测试, 统计每种类别信道的识别准确率, 不同算法在数据集上的性能对比见表 3。

从表 3 可以看出, 在 15 dB 下, 相对于传统基于频谱门限阈值的算法, 基于深度学习的分类识别算法在各个类别信道下均有 8% 以上的提高。本文提出的方法相较于基于频谱门限阈值的传统方法平均识别率提高了 15.4%, 相比 YOLOv5s 目标检测网络模型提高了 4.14%, 对比经典 ResNet50 提高了 3.24%, 相比仅加入通道注意机制的 Attention-ResNet50 提高 1.8%, 相比于 Transformer 网络识别率提高了 0.31%。同时本文方法在每种类型信道上对比原始经典的 ResNet50 方法对 5 kHz 信道识别率提高了 2.9%, 对 25 kHz 信道提高了 2.6%, 对宽带干扰信道提高 4.9%, 对窄带干扰信道提高 2.5%, 对单音干扰信道提高 3.3%。




图6 分类识别特征图可视化

表3 不同算法在数据集上的性能对比

算法	5 kHz	25 kHz	宽带干扰	窄带干扰	单音干扰	平均识别率
基于频谱门限阈值 ^[5]	80.5%	83.5%	78.3%	80.2%	85.2%	81.54%
YOLOv5s ^[13]	93.5%	93.3%	91.5%	91.6%	94.1%	92.8%
ResNet50 ^[10]	94.5%	94.6%	91.2%	92.7%	95.5%	93.7%
Attention-ResNet50	95.3%	95.8%	93.5%	93.9%	97.2%	95.14%
Transformer ^[14]	96.55%	96.1%	96.8%	97.1%	96.6%	96.63%
LA-ResNet50	97.4%	97.2%	96.1%	95.2%	98.8%	96.94%

2.5 不同信噪比下分类识别能仿真分析

使用本文提出的超短波信道分类识别算法 (LA-ResNet50)、基于频谱门限阈值的传统算法、

YOLOv5s 目标检测分类算法、经典 ResNet50 算法和 Attention-ResNet50 算法, 在 5 类不同信道类型的测试集中仿真, 分别测试在不同信噪比下



的分类识别效果,统计 5 类不同信号下的平均识别率。

不同信噪比下各个方法平均识别率如图 7 所示。相比于传统算法,基于深度学习的分类识别方法在不同信噪比下均有很大提升,在低信噪比下基于深度学习的方法相比于传统方法有明显的提高。信噪比为 0 的情况下本文提出的方法平均分类识别率相比基于频谱门限阈值的方法提高了 26.4%,相比 YOLOv5s 目标检测网络提高了 8.9%,相比原始 ResNet50 提高了 4.0%,相比 Attention-ResNet50 提高了 1.8%,相比经典的 Transformer 网络提高了 1.3%,且在 15 dB 以上的高信噪比下本文提出的方法能达到 95%以上的分类识别率。




图 7 不同信噪比下各个方法平均识别率

2.6 镜像填充谱与原始频谱分类识别效果仿真分析

采用本文提出的镜像填充谱对比原始频谱,分别在 YOLOv5s、ResNet50 和本文提出的 LA-ResNet50 模型中对测试集中 5 类不同的信号类型,在不同信噪比下进行仿真测试分类识别效果,统计 5 类不同信号的平均识别率。

原始频谱和镜像填充谱在不同网络模型下平均识别率如图 8 所示,采用原始信号频谱图片作为输入对比本文提出的镜像填充谱作为输入网络的

图片,在不同的信噪比下镜像填充谱对不同的网络识别效果均有一定程度的提升。在 10 dB 的信噪比下使用本文提出的镜像填充谱,在 YOLOv5s 目标检测网络中提高了 2.5%,在 ResNet50 中提高了 3.0%,在 LA-ResNet50 算法中提高了 3.0%。




图 8 原始频谱和镜像填充谱在不同网络模型下平均识别率

3 结束语

本文提出了一种基于镜像填充频谱与 LA-ResNet50 的超短波信道的分类识别算法,利用镜像填充谱有效提高了图片中有效信息占比,提高了后续网络模型训练时对图片中信道的特征提取效果。LA-ResNet50 模型构建时在主干网络 ResNet50 中引入通道注意力机制,在各个通道上的频谱图像进行加权提取特征,增强关注信道的特征而非背景特征。同时在训练模型时提出交叉熵和 LBP 加权损失函数,增强网络模型对底噪、信道以及干扰的镜像填充谱图像特征的差异提取能力,提高不同类型信号图像在细微边缘的计算度量效果。实验结果表明,本文方法相比传统基于频谱门限阈值方法、YOLOv5s 目标检测网络方法,以及经典的 ResNet50 方法分类识别率均有较大提升。

参考文献:

- [1] 张洋,毛忠阳,刘锡国,等.海上超短波超视距对流层散射信道模型研究[J].电波科学学报,2022,37(2):238-243.

- ZHANG Y, MAO Z Y, LIU X G, et al. Study on tropospheric scattering channel model of ultra short wave over the horizon at sea[J]. Chinese Journal of Radio Science, 2022, 37(2): 238-243.
- [2] 孔凌劲, 刘月玲, 张校晨, 等. 超短波频段复杂城区场景的信道测量与建模[J]. 电波科学学报, 2020, 35(4): 542-550.
- KONG L J, LIU Y L, ZHANG X C, et al. Channel measurement and modeling for VHF bands in typical urban scenarios[J]. Chinese Journal of Radio Science, 2020, 35(4): 542-550.
- [3] 陈柯威, 刘宏波, 马俊凯. 超短波信道模型的仿真与分析[J]. 舰船电子工程, 2022, 42(2): 87-90, 129.
- CHEN K W, LIU H B, MA J K. Simulation and analysis of ultrashort wave channel model[J]. Ship Electronic Engineering, 2022, 42(2): 87-90, 129.
- [4] 张玉波, 李志达, 沈延峰. 虚拟短波/超短波通信系统的关键技术研究[J]. 中国新通信, 2016, 18(7): 92.
- ZHANG Y B, LI Z D, SHEN Y F. Research on key technologies of virtual shortwave/ultrashort wave communication system[J]. China New Telecommunications, 2016, 18(7): 92.
- [5] 黄超. 无线射频信号的能量检测与特征识别[D]. 北京: 北京邮电大学, 2016.
- HUANG C. Energy detection and feature recognition of radio frequency signals[D]. Beijing: Beijing University of Posts and Telecommunications, 2016.
- [6] SMRITI, CHHAGAN C. Double threshold-based energy detection spectrum sensing scheme by considering the sensing history in confusion region[C]//Proceedings of 2018 5th International Conference on Signal Processing and Integrated Networks (SPIN). Piscataway: IEEE Press, 2018: 518-521.
- [7] WANG W Y, WANG J M, LI C Q. A signal detection method based on hybrid energy detection[C]//Proceedings of 2022 4th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP). Piscataway: IEEE Press, 2022: 695-700.
- [8] LI P J, HOU D Y, ZHAO J, et al. Research on adaptive energy detection technology based on correlation window[C]//Proceedings of 2021 IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Piscataway: IEEE Press, 2021: 836-840.
- [9] 姚朋. 基于频谱特征的深度学习信号检测方法研究[D]. 武汉: 华中科技大学, 2019.
- YAO P. Research on deep learning signal detection method based on spectral features[D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [10] KUMAR Y, SHEORAN M, JAJOO G, et al. Automatic modulation classification based on constellation density using deep learning[J]. IEEE Communications Letters, 2020, 24(6): 1275-1278.
- [11] BHATTI F A, KHAN M J, SELIM A, et al. Shared spectrum monitoring using deep learning[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(4): 1171-1185.
- [12] 邵延华, 张铎, 楚红雨, 等. 基于深度学习的 YOLO 目标检测综述[J]. 电子与信息学报, 2022, 44(10): 3697-3708.
- SHAO Y H, ZHANG D, CHU H Y, et al. A review of YOLO object detection based on deep learning[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3697-3708.
- [13] 周宇航, 侯进, 李嘉新, 等. 基于频域叠加和深度学习的频谱信号识别[J]. 计算机应用研究, 2023, 40(3): 874-879.
- ZHOU Y H, HOU J, LI J X, et al. Spectrum signal identification based on frequency-domain superposition and deep learning[J]. Application Research of Computers, 2023, 40(3): 874-879.
- [14] 郑金志, 汲如意, 张立波, 等. 基于 Transformer 解码的端到端场景文本检测与识别算法[J]. 通信学报, 2023, 44(5): 64-78.
- ZHENG J Z, JI R Y, ZHANG L B, et al. End-to-end scene text detection and recognition algorithm based on Transformer decoders[J]. Journal on Communications, 2023, 44(5): 64-78.
- [15] 霍纬纲, 梁锐, 李永华. 基于随机 Transformer 的多维时间序列异常检测模型[J]. 通信学报, 2023, 44(2): 94-103.
- HUO W G, LIANG R, LI Y H. Anomaly detection model for multivariate time series based on stochastic Transformer[J]. Journal on Communications, 2023, 44(2): 94-103.
- [16] 李宝奇. 深度卷积神经网络及其在地面图像目标识别中的应用[D]. 西安: 西北工业大学, 2019.
- LI B Q. Depth convolution neural network and its application in ground image target recognition[D]. Xi'an: Northwestern Polytechnical University, 2019.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2016: 770-778.
- [18] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.




- [19] 徐文贵. 基于融合全局与局部特征网络的指静脉识别算法及其轻量化研究[D]. 杭州: 杭州电子科技大学, 2022.

XU W G. Finger vein identification algorithm based on global and local feature networks and its lightweight research[D].

Hangzhou: Hangzhou Dianzi University, 2022.

[作者简介]




吴尚(1997-), 男, 杭州电子科技大学通信工程学院硕士生, 中国电子科技集团公司第三十六研究所联合培养硕士生, 主要研究方向为数字信号图像处理。



沈雷(1979-), 男, 博士, 杭州电子科技大学教授、博士生导师, 主要研究方向为数字图像处理、模式识别。



王李军(1978-), 男, 博士, 杭州电子科技大学硕士生导师, 中国电子科技集团公司第三十六研究所博士后工作站研究员, 通信信息控制和安全技术重点实验室常务副主任, 主要研究方向为卫星导航技术、信号与信息处理。



张如栩(1999-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为数字信号处理。



胡鑫(1999-), 男, 杭州电子科技大学通信工程学院硕士生, 主要研究方向为数字信号处理。