

文章编号: 2095-4980(2022)01-0040-07

基于时频特征的跳频信号调制识别

张 静, 于 蕾, 侯长波*, 张 结, 林佳昕

(哈尔滨工程大学 信息与通信工程学院, 黑龙江 哈尔滨 150001)

摘 要: 跳频信号在抗干扰方面具有良好的性能。准确识别跳频信号的调制方式, 能够为判断敌我目标属性、干扰敌方信号等军事信息战提供有力支撑, 但国内外对于跳频信号的调制识别仍存在很大空缺。本文提出一种基于时频特征的跳频信号调制识别方法, 通过平滑伪魏格纳-维利分布(SPWVD)时频变换获取不同调制类型的跳频信号时频图像, 将时频图像送入卷积神经网络(CNN)中进行特征提取及分类识别。仿真实验证明, 本文CNN在低信噪比下取得了较好的识别效果。

关键词: 跳频信号; 调制识别; 时频分析; 卷积神经网络; 特征提取

中图分类号: TN913.3

文献标识码: A

doi: 10.11805/TKYDA2021152

Frequency-hopping signal modulation recognition based on time-frequency features

ZHANG Jing, YU Lei, HOU Changbo*, ZHANG Jie, LIN Jiaxin

(College of Information and Communication Engineering, Harbin Engineering University, Harbin Heilongjiang 150001, China)

Abstract: Frequency-hopping signal shows good performance in anti-interference. Accurately identifying the modulation methods of frequency-hopping signals can provide strong support for military information warfare such as judging the attributes of enemy and enemy targets and interfering with enemy signals. Nevertheless, there is still a big gap in the modulation recognition of frequency hopping signals at home and abroad. A frequency-hopping signal modulation recognition method based on time-frequency features is proposed. Through Smoothed Pseudo Wigner-Ville Distribution(SPWVD) time-frequency transformation, time-frequency images of frequency-hopping signals of different modulation types are obtained, and the time-frequency images are sent to a Convolutional Neural Network(CNN) for feature extraction and classification recognition. Simulation experiments prove that the proposed CNN model has achieved better recognition results under low Signal-to-Noise Ratios(SNRs).

Keywords: frequency-hopping signal; modulation recognition; time-frequency analysis; Convolutional Neural Network; feature extraction

通信信号的调制识别作为数字信号处理领域的一项重要研究课题, 在军事和民用领域都得到了广泛应用。跳频为常见的扩频方式之一, 将传输带宽分为很多互不重叠的频率点, 即载波在多个频率点上发送信号, 根据伪随机发生器的输出, 传输信号选择相应的频率点, 即载波在跳变。与定频通信相比, 具有较好的隐蔽性, 难以被截获, 因此跳频信号具有较强的抗干扰性能。但跳频通信的这些优良性能也给信号接收方带来了挑战, 如在无线电监管、军事通信侦察及对抗中, 接收方缺少跳频图案及调制方式等先验信息^[1]。准确识别跳频信号的调制方式, 能够为判断敌我目标属性、干扰敌方信号等军事信息战提供有力支撑, 因此研究跳频信号的调制识别对通信系统侦察及信号干扰具有重要应用价值。

目前国内外的信号调制识别方法可分为传统方法与基于深度学习的识别方法。传统方法包括基于假设检验的最大似然估计方法^[2]及基于模式识别的特征提取方法^[3], 但其计算较为复杂, 在实际中很难应用。随着人工智能的快速发展, 深度学习以其优越的性能被广泛用于信号调制识别领域中^[4]。文献[5]提出了图形星座和深度置信

收稿日期: 2021-04-15; 修回日期: 2021-06-15

基金项目: 国家自然科学基金资助项目(62001137)

*通信作者: 侯长波 email:houchangbo@hrbeu.edu.cn

网络识别的调制方案；随着深度学习模型的研究不断深入与成熟，多模态深度学习成为多模态机器学习的主流。Zhang Z 等^[6]提出了一种基于卷积神经网络(CNN)的多模态调制识别方案，该研究工作结合了图像特征和手工特征形成关联特征，并利用多模态融合两种不同模态的关联特征以进一步提高性能。神经网络虽具有强大的学习能力，但其运算量相比于传统方法大得多，文献[7]提出了一种可部署于资源受限的边缘设备上的轻量化智能电磁信号识别模型，在不损失识别精确度的前提下实现了高效调制识别。

目前对通信信号调制识别的研究已日渐成熟，但大多是关于定频信号的研究，而关于跳频信号的研究多集中于跳频信号检测^[8-9]及参数估计^[10-11]等领域。针对跳频调制信号识别，Huang X 等^[12]使用拓扑分析方法进行跳频信号调制识别，在高信噪比下取得了显著效果。文献[13]提出一种对扩频信号和常规通信信号分别提取瞬时特征和高阶累积量进行调制识别的算法；文献[14]提出了一种基于时频能量谱纹理特征的方法对跳频信号进行调制识别，通过将每跳信号的时频能量谱转化为时频灰度图进行处理，最后通过支持向量机分类器对特征集进行训练、分类和识别；文献[15]通过对跳频信号进行短时傅里叶变换(Short-Time Fourier Transform, STFT)和 Cohen 分布(Choi-Williams Distribution, CWD)组合时频变换，利用卷积神经网络进行特征提取和分类识别，在信噪比为-4 dB 条件下，对 8 种调制方式的跳频信号平均识别率达到 92.54%。虽然该文在较低信噪比条件下达到了较好的识别效果，但其通过提取跳频信号的单跳时频图进行分类识别，相对于整体跳频时频图，会存在特征丢失的情况。

上述研究取得了不错的结果，但国内外对跳频信号的调制识别研究仍存在很大空缺，因此本文提出了一种基于时频特征的跳频信号调制识别算法。跳频信号在时频图像上表现为时间轴上首尾相连的连续线段形式，在频率轴上表现为大小不同的跳变形式，在一定程度上拓宽了频带，因此具有丰富的时频域特征。本文对进行不同类型调制后的跳频信号作平滑伪魏格纳-维利分布(SPWVD)时频变换，将获取的时频图像送入卷积神经网络模型中进行分类识别，并在低信噪比下达到了较好的识别效果。

1 原理分析

1.1 跳频信号

跳频信号作为常见的扩频方式之一，其载波频率受伪随机码控制，随时间进行跳变，载频可看作按照一定规律变化的多频频移键控(Multi-Frequency Shift Keying, MFSK)，因此具有丰富的频域信息。其数学模型可表示为：

$$s(t) = \sum_{i=0}^{N-1} s_i(t) = \sum_{i=0}^{N-1} \text{rect}_{T_h}(t - kT_h - T_0) e^{j2\pi f_i(t - kT_h - T_0)} \quad (1)$$

式中： $s_i(t)$ 为第 i 个跳频信号分量， $0 \leq t \leq T$ ， T 为跳频信号的总长度； T_h 为跳频周期， $1/T_h$ 则为跳频速率； T_0 为起跳时间； f_i 为第 i 跳的频率； $\text{rect}_{T_h}(t)$ 表示宽度为 T_h 的矩形脉冲，其数学表达式为：

$$\text{rect}_{T_h}(t) = \begin{cases} 1, & t \in [0, T_h] \\ 0, & \text{others} \end{cases} \quad (2)$$

1.2 时频分析

对于非平稳信号，傅里叶变换只能显示信号当中有哪些频率成分，各个成分出现的时间并不能被观测到。通过对信号进行时频变换，可以知道信号频率随时间变化的情况及各个时刻的瞬时频率及其幅值，从而直观地将信号时域及频域的关系关联起来。因此对于调制识别，时频分析是一种十分有利的信号分析和处理工具。目前常用的时频分析方法主要有 STFT、魏格纳威利分布(Wigner-Village Distribution, WVD)及其改进算法、CWD。

1.2.1 短时傅里叶变换(STFT)

给定一维信号：

$$\text{STFT}(t, f) = \int_{-\infty}^{+\infty} x(\tau)g(\tau-t)e^{-j2\pi f\tau}d\tau = \langle x(\tau), g(\tau-t) \rangle \quad (3)$$

式中： t, τ 为时间因子； f 为频率因子；窗函数 $g(\tau)$ 为对称的实函数且满足 $\|g(\tau)\|=1$ ， $\|g_{t,f}(\tau-t)\|=1$ 。短时傅里叶变换的时频分辨力相互制约，且不同窗函数及不同窗口尺寸大小会对时频分析产生不同程度的影响，如图 1 所示。




Fig.1 Time-frequency diagram of STFT with different window lengths

图 1 不同窗长的 STFT 时频图

1.2.2 魏格纳威利分布(WVD)及其改进算法

给定一维信号 $x(t)$:

$$W(t, f) = \int_{-\infty}^{+\infty} x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f \tau} d\tau \quad (4)$$

WVD 可看作使用信号本身作为窗函数进行的 STFT 变换, 窗函数具有自适应性, 但当多个信号叠加时, WVD 变换会产生交叉项, 使多个信号的分布不再是信号各自分布的和, 这意味着在处理叠加信号时无法直接反映时频特征, 因此采用 PWVD 变换将 WVD 在时域中进行平滑处理:

$$PWVD_x(t, f) = \int_{-\infty}^{+\infty} h(\tau) x\left(t + \frac{\tau}{2}\right) x^*\left(t - \frac{\tau}{2}\right) e^{-j2\pi f \tau} d\tau \quad (5)$$

式中 $h(\tau)$ 为窗函数。此种算法只能平滑 τ 方向上的交叉项干扰, 抑制效果不够明显, 需要对该种时频变换方法进行改进。将窗函数从 t, τ 两个方向展开, 对 WVD 变换同时加时间窗和频率窗, 即可得到 SPWVD 变换:

$$SPWVD_x(t, f) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(u) h(\tau) x\left(t - u + \frac{\tau}{2}\right) x^*\left(t - u - \frac{\tau}{2}\right) e^{-j2\pi f \tau} du d\tau \quad (6)$$

式中 $h(\tau), g(u)$ 为两个窗函数, 且相互独立, 因此可单独设计时间和频率窗长, 从而获得较高的时频分辨力。

WVD 及其改进算法的时频变换如图 2 所示, 从图中可以发现, WVD 变换和 PWVD 变换都存在明显的交叉项干扰, SPWVD 算法对交叉项抑制较为明显。




Fig.2 Time-frequency transformation of WVD and its improved algorithms

图 2 WVD 时频变换及其改进的算法时频变换

1.2.3 CWD

除了 WVD 分布, 近几十年来人们还提出了很多其他具有双线性形式的时频分布, 1966 年 Cohen 给出了时频分布的更一般表示形式:

$$C_x(t, f; g) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x\left(u + \frac{\tau}{2}\right) x^*\left(u - \frac{\tau}{2}\right) g(\theta, \tau) e^{-j2\pi(\theta t + f\tau - u\theta)} du d\tau d\theta \quad (7)$$

式中 $g(\theta, \tau)$ 为核函数, 也可以理解为加在原 WVD 分布上的窗函数, 不同的核函数可得到不同的时频分布, 导致时频聚集性和交叉项抑制相互制约。不同核函数下的时频变换图像如图 3 所示。

经过对比分析, 本文最终选择 SPWVD 时频分布对本文信号进行时频分析。

1.3 卷积神经网络(CNN)

随着人工智能领域的快速发展, 深度学习作为机器学习的一大分支, 具有强大的学习能力, 广泛

用于通信信号的调制识别中。CNN 是一种基于监督学习的模型, 对不同特征具有较强的适应能力, 可用来提取数据局部特征进行全局特征训练和分类。CNN 在提取图像特征方面表现出良好的性能, CNN 提取特征的过程可看作输入到输出的映射, 通过学习大量的输入与输出之间的映射关系进行识别, 其在模式识别各个领域都取得了很好的成果。如图 4 所示, CNN 结构包括卷积层、池化层和全连接层。每个卷积层由若干卷积单元组成, 通过一种卷积滤波器提取输入的一种特征。卷积层是卷积运算的一个重要特点, 通过卷积运算, 增强了原数据特征, 并降低了噪声; 池化层根据图像局部相关性的原理, 对图像进行子采样, 减少卷积层提取到的特征维度, 从而减小运算量, 同时保持图像旋转不变性; 采用 Softmax 全连接, 得到的激活值即 CNN 提取到的图片特征。




Fig.3 CWD time-frequency transformation of different kernel functions

图 3 不同核函数的 CWD 时频变换

CNN 为部分连接网络，其卷积层用来进行特征提取，池化层用来对数据进行采样降维，全连接层把所有局部特征结合变成全局特征，用来计算最后每一类的得分。一个 CNN 可以包含多个卷积层、池化层和全连接层。用于分类识别的 CNN 通常在最后加上 Softmax 层，Softmax 层对神经网络的输出结果进行一次换算，将输出结果用概率的形式表现出来。卷积神经网络可被看作自动合成其自身的特征抽取器。

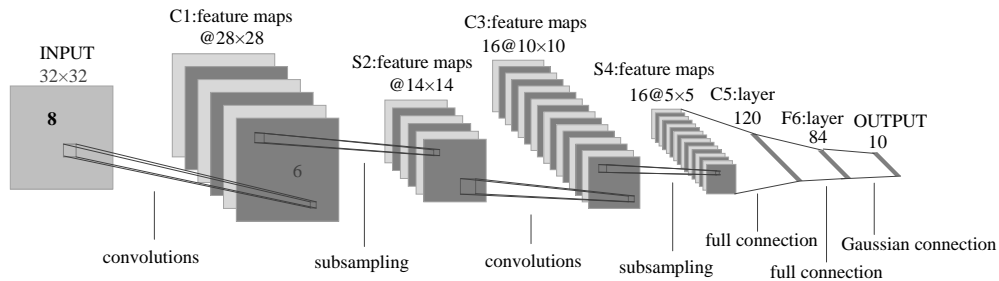


Fig.4 Schematic diagram of convolutional neural network
图 4 卷积神经网络结构示意图

2 本文算法

对仿真跳频信号进行 SPWVD 时频变换，获取跳频信号的彩色时频图像，将获取的彩色时频图像送入 CNN 中进行分类识别。其中，本文采用的 CNN 是基于 VGG16 进行调整的网络模型，包括 5 个卷积层、3 个池化层、2 个全连接层和 1 个 Softmax 层，其结构如图 5 所示。




Fig.5 Structure diagram of the convolutional network in this paper
图 5 本文所用卷积网络结构图

为进一步说明本文所搭建的网络结构，表 1 中对各层参数进行了详细说明。第一个和第二个卷积层分别包括 64 个 3×3 的卷积核，第三个和第四个卷积层分别包括 128 个 3×3 的卷积核，最后一个卷积层包括 256 个 3×3 的卷积核；激活函数均为 ReLU 函数。为使卷积层输入输出数据维数保持一致，本文将卷积函数 padding 设置为 same，池化方式采用最大池化方法，步长为 2，batch 设置为 16，学习率设置为 0.000 1，输入图像大小设置为 80×80。

表 1 CNN 参数设置

Table 1 CNN parameter settings

layer	filter size	Num.	stride	layer	filter size	Num.	stride
Input	-	1	-	ReLU	-	-	-
Conv1	3	64	1	Maxpooling	2	-	2
ReLU	-	-	-	Conv5	3	256	1
Conv2	3	64	1	ReLU	-	-	-
ReLU	-	-	-	Maxpooling	2	-	2
Maxpooling	2	-	2	FC1	512	-	-
Conv3	3	128	1	FC2	6	-	-
ReLU	-	-	-	Softmax	-	1	-
Conv4	3	128	1				

3 实验及结果分析

本文在上述方法下进行仿真实验，使用的数据集包括 6 种常见的跳频信号的调制形式：2ASK,2FSK,BPSK,

QPSK,16QAM,32QAM。跳频信号的仿真参数如表 2 所示，采样频率为 40 kHz，每种信号信噪比为-6~6 dB，步进为 2 dB。数据集共包括 8 400 张时频图像，每种调制类型的跳频信号在每个信噪比下获取 200 张时频图像，训练集和测试集按 7:3 进行划分，训练集的每种信号在每个信噪比下为 140 张图像，总包含 5 880 张时频图像，测试集的每种信号在每个信噪比下为 60 张图像，总包含 2 520 张时频图像。将获取的图像输入到 CNN 模型中进行分类识别，获取不同信噪比下的跳频信号调制识别率。

表 2 跳频调制信号仿真参数
Table2 Simulation parameters of frequency-hopping modulation signal

sample rate	modulation type	SNR	data set	sampling points	frequency-hopping set/kHz	frequency-hopping period/ms
40 kHz	2ASK	-6~6 dB step is 2 dB	200 images of each modulation type and each SNR	200/hop	12	5
	2FSK				15	
	BPSK				10	
	16QAM				12	
	QPSK				13	
	32QAM					

在 6 dB 和 -6 dB 下不同调制类型的信号识别效果如图 6~图 7 所示，从图中可以看出，2FSK 调制类型的信号在低信噪比和高信噪比都取得了很好的识别效果，32QAM 信号的识别效果不理想。这是由于跳频信号频率跳变导致 QAM 调制类型的信号特征不明显，使这种调制类型的信号识别效果不理想。后续将继续研究如何提升这些调制类型的跳频信号的识别效果。跳频信号可看作多频频移键控信号，因此 FSK 信号特征相较于其他调制类型的跳频信号较为明显。




Fig.6 6 dB frequency hopping signal modulation recognition confusion matrix
图 6 6 dB 跳频信号调制识别混淆矩阵




Fig.7 -6 dB frequency hopping signal modulation recognition confusion matrix
图 7 -6 dB 跳频信号调制识别混淆矩阵

CNN 广泛用于图像分类任务，但目前成熟的 CNN 大多是基于自然图像进行分类识别而进行训练的。跳频信号时频图像与自然图像存在较大差距，已有的 CNN 并不能取得很好的分类识别结果。文献[15]对大量网络结构组合进行训练测试之后，选取了其中 4 种典型的结构组合进行分析，并选出了针对时频图识别效果最佳的 CNN，其结构如图 8 所示，包括 4 个卷积层、4 个最大池化层以及 2 个全连接层和一个 Softmax 层。其卷积层的卷积核大小均为 3×3，每层卷积核个数依次为 8,16,32,64；最大池化层步长为 2。




Fig.8 Structure diagram of the convolutional network used in reference[15]
图 8 文献[15]所用卷积网络结构图

为验证本文 CNN 模型的有效性,使用文献[15]所搭建的 CNN 模型对本文的数据进行分类识别,除神经网络结构不同外,其余参数设置与本文 CNN 模型参数一致,每个信噪比下进行 10 次实验取平均值作为最后的识别精确度。图 9 为不同信噪比下几种 CNN 结构的识别模型准确率,从图 9 中可以看出,本文的 CNN 模型相较于文献[15],在识别精确度上有一定的提升。图 10 为两种模型在 -4 dB 下的训练迭代变化曲线以及混淆矩阵。从图 10 中可以看出,本文的网络模型在迭代 1 400 次时损失函数达到了较好的收敛效果,文献[15]在迭代 2 000 次时损失函数达到了较好的收敛效果。为进一步验证本文模型的运算效能,将两种网络模型的训练损失函数达到较好的收敛效果时所需的时间进行对比,如表 3 所示。可以发现,虽然本文的网络模型及参数量比文献[15]复杂,但本文和文献[15]的网络模型运行时间相差不大,这是由于两种网络模型在较少的网络层数下,CNN 可以很好地学习到时频图像的特征,大大减少了运算量,进一步证明了本文 CNN 的优越性。




Fig.9 Recognition accuracy under different SNRs
图 9 不同信噪比下的识别精确度

表 3 运行时间对比
Table 3 Run time comparison

CNN model	CNN used in this paper	CNN used in reference[15]
time/s	72	57

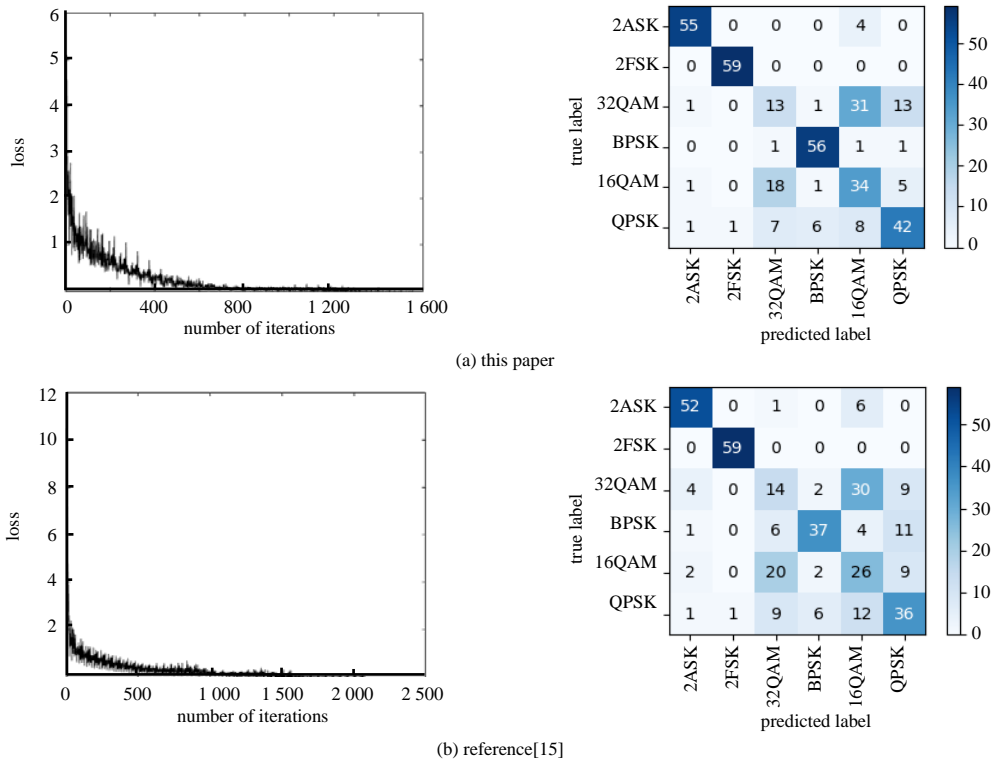


Fig.10 Loss function training iteration curves and confusion matrix of the two models under -4 dB
图 10 -4 dB 下两种模型的损失函数训练迭代曲线及混淆矩阵

4 结论

针对目前信号调制识别领域对跳频信号调制识别研究存在很大空缺的问题,本文提出了一种基于时频特征的跳频信号调制识别方法。该方法首先将一维信号通过 SPWVD 时频变换获取其彩色时频图,采用 CNN 卷积神经网络模型对获取的时频图像进行特征提取,仿真实验表明本文模型在低信噪比时取得了很好的分类效果,但该方法将信号处理成时频图像会在一定程度上损失信号的相位信息,会对信号的分类准确率产生一定的影响。后续要考虑如何降低相位信息的损失,在未来的研究中,将探索 QAM 信号的调制识别效果不理想是否与此原因有关。此外,通过对跳频信号的时频图进行去噪处理,可使特征更为明显,未来将进一步研究经去噪处理后的跳频信号调制类型识别,寻找更为高效的识别方法,使其能够用于军事电子信息战获取情报、抗干扰等场景。

参考文献:

- [1] 吕国裴,谢跃雷. 基于深度学习的跳频信号识别[J]. 电讯技术, 2020,60(10):1142–1147. (LYU Guopei,XIE Yuelei. Recognition of frequency hopping signal based on deep learning[J]. Telecommunication Engineering, 2020,60(10):1142–1147.)
- [2] PROKOPIOS P,ANASTASOPOULOS A,POLYDOROS A. Likelihood ratio tests for modulation classification[C]// MILCOM 2000 Proceedings. 21st Century Military Communications. Architectures and Technologies for Information Superiority. Los Angeles,CA,USA:IEEE, 2000:670–674.
- [3] ZHAO Y,JIANG H,CHEN Q,et al. Preserving minority structures in graph sampling[J]. IEEE Transactions on Visualization and Computer Graphics, 2021,27(2):1–10.
- [4] TU Y,LIN Y,HOU C,et al. Complex-Valued Networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020,69(99):10085–10089.
- [5] XUE Jilong,MIAO Youshan,CHEN C,et al. Tux2:distributed graph computation for machine learning[C]// 14th USENIX Symposium on Networked Systems Design and Implementation. Boston,MA,USA:[s.n.], 2017:669–682.
- [6] ZHANG Z,WANG C,GAN C,et al. Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD[J]. IEEE Transactions on Signal & Information Processing Over Networks, 2019,5(3):469–478.
- [7] 张思成,林云,涂涯,等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. 通信学报, 2020,41(11):12–21. (ZHANG Sicheng,LIN Yun,TU Ya,et al. Electromagnetic signal modulation recognition technology based on lightweight deep neural network[J]. Journal on Communications, 2020,41(11):12–21.)
- [8] KYUNG-GYU L,OH S J. Detection of fast frequency-hopping signals using dirty template in the frequency domain[J]. IEEE Wireless Communications Letters, 2019,8(1):281–284.
- [9] LI A,HAO H,TAO R,et al. Implementation of mixing sequence optimized modulated wideband converter for ultra-wideband frequency hopping signals detection[J]. IEEE Transactions on Aerospace and Electronic Systems, 2020,56(6):4698–4710.
- [10] XIE J,HOU S,ZHANG Q. An improved central frequency estimation method for frequency-hopping signal[C]// 2019 IEEE International Conference on Power,Intelligent Computing and Systems(ICPICS). Shenyang,China:IEEE, 2019.
- [11] WU K,ZHANG J,HUANG X,et al. Waveform design and accurate channel estimation for frequency-hopping MIMO radar-based communications[J]. IEEE Transactions on Communications, 2020,69(2):1244–1258.
- [12] HUANG X,ZHANG L,YAN K,et al. Novel modulation recognizer for frequency-hopping signals based on persistence diagram[C]// 2020 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting(BMSB). [S.l.]: IEEE, 2020:1–6.
- [13] 占锦敏,赵知劲. 常规调制信号与扩频信号的调制识别算法[J]. 信号处理, 2020,36(4):511–519. (ZHAN Jinmin,ZHAO Zhijin. Modulation identification algorithm for conventional modulation signals and spread spectrum signals[J]. Signal Processing, 2020,36(4):511–519.)
- [14] 李红光,郭英,睦萍,等. 基于时频能量谱纹理特征的跳频调制方式识别[J]. 通信学报, 2019,40(10):20–29. (LI Hongguang, GUO Ying,SUI Ping,et al. Frequency hopping modulation recognition based on time-frequency energy spectrum texture features[J]. Journal on Communications, 2019,40(10):20–29.)
- [15] 李红光,郭英,睦萍,等. 基于时频特征的卷积神经网络跳频调制识别[J]. 浙江大学学报(工学版), 2020,54(10):1945–1954. (LI Hongguang, GUO Ying,SUI Ping,et al. Frequency-hopping modulation recognition of convolutional neural network based on time-frequency characteristics[J]. Journal of Zhejiang University(Engineering Science Edition), 2020,54(10): 1945–1954.)

作者简介:

张 静(1998–), 女, 在读硕士研究生, 主要研究方向为电磁信号识别.email:zhangjing03@hrbeu.edu.cn.

侯长波(1986–), 男, 硕士, 副教授, 主要研究方向为人工智能与边缘计算、电磁信号智能识别与干扰、图像处理与应用.

于 蕾(1977–), 女, 工学博士, 副教授, 主要研究方向为数字图像处理、计算机视觉、目标检测跟踪.

张 结(1997–), 男, 在读硕士研究生, 主要研究方向为智能分布式通信干扰.

林佳昕(1999–), 男, 在读硕士研究生, 主要研究方向为人工智能与边缘计算.