

DOI:10.11918/202306049

基于多变换域特征的雷达辐射源信号融合识别

普运伟^{1,2}, 余永鹏^{1,3}, 姜莹¹, 田春瑾²

(1. 昆明理工大学信息工程与自动化学院, 昆明 650500; 2. 昆明理工大学计算中心, 昆明 650500; 3. 广东科技学院机电工程学院, 广东 东莞 523668)

摘要: 针对现有复杂体制雷达辐射源信号识别方法信息利用率低、抗噪性能差等问题, 提出一种融合雷达辐射源信号多变换域特征的集成深度神经网络识别方法。首先基于双谱估计、模糊函数、希尔伯特黄变换 (HHT) 3 种变换域方法对辐射源信号展开处理, 分别提取信号矩形积分双谱特征、模糊函数正交切片特征和希尔伯特边际谱特征, 并转换为表达能力和可解释性更优的二维特征图像; 其次, 构建基于 ResNet18 + 多层感知机 (MLP) 的融合识别模型框架, 以多个 ResNet18 网络作为基学习器, 分别对 3 类变换域特征数据集进行初级识别, 获得以概率表征的特征向量; 最后, 通过 MLP 对特征向量进行融合学习, 输出最终的信号类别信息。实验结果表明, 该方法在信噪比为 0 dB 时, 对 6 类雷达辐射源信号的整体平均识别率均保持在 99.23% 以上, 即使是在 -4 dB 低信噪比环境中, 识别率也稳定在 96.54% 以上, 验证了所提方法的有效性和较好性能。

关键词: 雷达辐射源信号; 信号识别; 多变换域特征; 特征提取; 深度学习

中图分类号: TN974

文献标志码: A

文章编号: 0367-6234(2026)03-0088-10

Fusion recognition of radar emitter signals based on multiple transform domain features

PU Yunwei^{1,2}, YU Yongpeng^{1,3}, JIANG Ying¹, TIAN Chunjin²

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China; 2. Computer Center, Kunming University of Science and Technology, Kunming 650500, China; 3. School of Mechano-Electronic Engineering, Guangdong University of Science & Technology, Dongguan 523668, Guangdong, China)

Abstract: In response to the problems of low information utilization and poor anti-noise performance in existing recognition methods for radar emitter signals of complex systems, we proposed an ensemble deep neural network recognition method integrating multiple transform domain features of radar emitter signals. Firstly, based on the three transform domain methods of bispectrum estimation, ambiguity function (AF), and Hilbert-Huang transform (HHT), we processed the emitter signals, extracted, and transformed the signal's rectangular integral bispectrum feature, AF orthogonal slice feature, and Hilbert marginal spectrum feature into two-dimensional feature images with stronger expressiveness and interpretability. Then, we constructed a fusion recognition model framework based on ResNet18 + multilayer perceptron (MLP), took multiple ResNet18 as base learners to perform primary recognition on the datasets of three transform domain features, and obtained feature vectors represented by probabilities. Finally, we conducted fusion learning on the feature vectors via the MLP and output the final signal category information. The experimental results show that the proposed method maintains an overall average recognition rate of above 99.23% for six classes of radar emitter signals at a signal-to-noise ratio (SNR) of 0 dB. Even in the low SNR environment of -4 dB, the recognition rate remains stable at above 96.54%. The results verify the effectiveness and better performance of the proposed method.

Keywords: radar emitter signal; signal recognition; multiple transform domain feature; feature extraction; deep learning

雷达辐射源信号识别是雷达对抗侦察的核心环节。随着信息技术的发展, 雷达对抗已进入智能化阶段, 新型体制雷达的广泛应用使得辐射源数量急

速增加、信号样式复杂多变, 雷达辐射源信号识别面临严峻的挑战。传统基于脉冲描述字 (PDW) 参数测量的辐射源信号识别方法已难以满足现代战场的

收稿日期: 2023-06-12; 录用日期: 2023-08-21; 网络首发日期: 2024-07-02

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20240701.1738.005>

基金项目: 国家自然科学基金项目 (61561028)

作者简介: 普运伟 (1972—), 男, 教授, 博士生导师; 余永鹏 (1995—), 男, 硕士研究生

通信作者: 普运伟, puyunwei@126.com

需求。因此,能够稳健反映辐射源信号本质的脉内调制特征已成为研究热点,如时域特征^[1]、频域特征^[2]、时频域特征^[3-4]、模糊函数特征^[5]、高阶谱特征^[6]等。但依赖人工经验挖掘信号特征参数的方法存在耗时长、特征不完备等缺陷。如何自动挖掘信号深层分类特征亟待解决。

深度学习的快速发展推动深度神经网络在各个领域广泛应用。在雷达辐射源信号识别研究中,常通过域变换的信号处理方法,将信号的脉内调制特征转换为二维特征图像,再通过深度神经网络提取深层本质特征,完成分类识别任务。谢存祥等^[7]提取了辐射源信号的二维时频特征,利用残差神经网络实现了雷达信号的高效识别;普运伟等^[8]对模糊函数主脊(AFMR)进行极坐标变换提取二维特征,结合卷积神经网络提升识别率;全大英等^[9]采用Choi-Williams分布和多重同步压缩变换(MSST),获取二维时频图像并进行预处理,通过多通道卷积神经网络在低信噪比下取得良好表现。

然而,尽管这些方法在信号分析和判定方面取得了一定的成果,但均仅聚焦单一变换域特征,未能充分挖掘多域互补信息。同时,单一域的特征变换也存在一定的缺陷,如在低信噪比环境下易受到干扰而影响算法性能。因此,本文提出一种多变换域特征融合识别方法:联合双谱估计、模糊函数和HHT提取3类特征,构建二维特征图像;设计ResNet18+MLP融合模型,融合多变换域的识别结果,提升识别精度与鲁棒性。通过仿真实验证明了本文所提方法的有效性。

1 雷达辐射源信号多变换域特征提取方法

雷达辐射源信号 $s(t)$ 是一种非平稳信号,可表示为^[10]

$$s(t) = g(t) \exp[j(2\pi f_0 t + \varphi_0)] + n(t) \quad (1)$$

式中: $n(t)$ 为高斯白噪声; f_0 和 φ_0 分别为信号载频和初始相位,二者决定辐射源信号的调制类型; $g(t)$ 为信号的复包络,其表达式为

$$g(t) = a(t) \exp[j\theta(t)] \quad (2)$$

式中: $a(t)$ 和 $\theta(t)$ 分别为幅度调制函数、相位调制函数。

为了精确描述辐射源信号之间的微小差异,需提取多维度特征,但特征维度过多可能会引发维度灾难和过拟合等问题,从而降低识别模型的性能。

因此,本文选择代表性强的双谱估计、模糊函数和HHT3种方法,从不同的角度提取信号的特征信息,丰富信号特征数据集的多样性。

双谱估计能有效地保留信号的幅值和相位信息,降低高斯噪声、非高斯噪声的不利影响。作为最低阶的高阶谱,双谱处理方法更加简单,而且因为其具有时间不变性、尺度不变性、相位保持性等特点,可通过分析信号在不同频率下的相互作用,提取辐射源信号之间的微小差异^[11]。

模糊函数完全依赖雷达辐射源发射的信号波形,每个雷达信号的模糊函数都是唯一的,并且信号模糊体积的分配完全由信号本身决定。通过卷积不同时间延迟和频率偏移的信号,模糊函数可提取信号在不同时间和频率上的变化特征,进而区分不同的辐射源信号^[12],为从信号模糊函数的角度获取信号本身的特征参数提供了理论依据。

HHT将信号分解为多个固有模态函数,每个模态函数对应一个频率范围,可以捕获信号的局部非线性特征,从而实现辐射源信号微小差异的准确描述^[13]。相较于傅里叶变换和小波变换等传统方法,HHT不受线性和平稳性假设限制,因此更加适用于非平稳信号的分析。

直接从三维空间提取特征计算量和复杂度较高,结合深度学习在图像处理方面的优势,本文采用了3种不同的降维处理方法,将信号变换后的三维特征图像降维为二维特征图像,在保证识别准确性的同时,提升特征的可解释性和计算效率。

1.1 模糊函数正交切片特征提取

雷达辐射源信号 $s(t)$ 的模糊函数(ambiguity function, AF)可定义为

$$\chi_s(\tau, \xi) = \int_{-\infty}^{+\infty} g(t) g^*(t + \tau) \exp[j2\pi\xi t] dt \quad (3)$$

式中: τ 为时延; ξ 为多普勒频偏; t 为时间; $g^*(t)$ 为 $g(t)$ 的共轭函数。信号 $s(t)$ 的模糊函数由其复包络 $g(t)$ 所决定。

上式表明,AF实质上是 $s(t)$ 匹配滤波器对特定时延和多普勒频偏的回波信号的响应,可以视为信号在时域和频域上的联合二维时频表示,能够较好地反映信号内在结构特性。图1给出了10 dB信噪比下6类雷达辐射源信号的AF三维图,包括常规信号(CON)、线性调频信号(LFM)、二相编码信号(BPSK)、跳频扩频信号(COSTAS)、M伪随机序列(MSEQ)、二频编码信号(BFSK)。

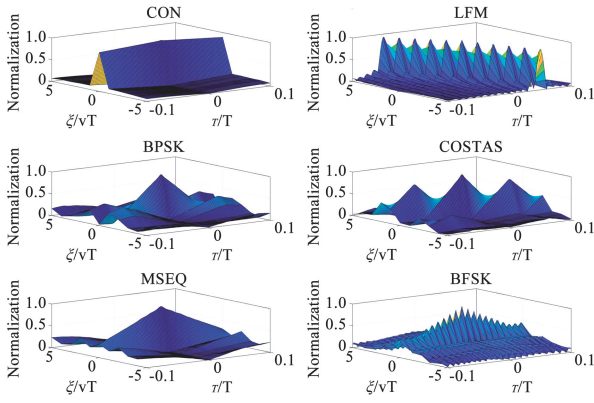


图 1 10 dB 信噪比下 6 类雷达辐射源信号的 AF 三维图

Fig. 1 Three-dimensional diagram of AF of six kinds of radar emitter signals at 10 dB SNR

由图 1 可知, AF 具有原点对称性和原点极值性,能量主要集中在零频偏($\xi = 0$)和零时延($\tau = 0$)附近,这意味着有效的 AF 特征应该集中在该区域。因此,提取模糊函数频偏和时延为零的切片作为雷达辐射源信号的主要表征,并根据 AF 的对称性,分别沿模糊函数的频偏半轴方向和时延半轴方向切割组合,获得 AF 正交切片。

1) AF 频移零点切片特征提取

当时延 $\tau = 0$ 时,由模糊函数定义式和轴切割特性可得如下函数:

$$|\chi(0, \xi)| = \left| \int_{-\infty}^{+\infty} g(t) g^*(t) \exp[j2\pi\xi t] dt \right| = \left| \int_{-\infty}^{+\infty} |g(t)|^2 \exp[j2\pi\xi t] dt \right| \quad (4)$$

当时延 $\tau = \tau_1 \neq 0$ 时,沿频偏轴方向垂直幅值轴进行切割,可得如下函数表示的切片:

$$|\chi(\tau_1, \xi)| = \left| \int_{-\infty}^{+\infty} g(t) g^*(t + \tau_1) \exp[-j2\pi\xi t] dt \right| = \left| \exp[j2\pi\xi\tau_1] \int_{-\infty}^{+\infty} g(-t) g^*(-t + \tau_1) dt \right| = |g(t) \exp[j2\pi\xi\tau_1] \otimes g^*(-t + \tau_1)| \quad (5)$$

该切片等效于输入信号为 $g(t) \exp[j2\pi\xi t]$ 的频移回波信号通过一个匹配滤波器,并把在 τ_1 时刻输出值沿着频移轴展开。

2) AF 时延零点切片特征提取

当频移 $\xi = 0$ 时,由模糊函数定义式和轴切割特性可得如下函数:

$$|\chi(\tau, 0)| = \left| \int_{-\infty}^{+\infty} g(t) g^*(t + \tau) dt \right| \quad (6)$$

当频移 $\xi = \xi_1 \neq 0$ 时,沿时延轴方向垂直幅值轴

进行切割,可得如下函数表示的切片:

$$|\chi(\tau, \xi_1)| = \left| \int_{-\infty}^{+\infty} g(t) g^*(t + \tau) \exp[j2\pi\xi_1 t] dt \right| = \left| \int_{-\infty}^{+\infty} g(-t) g^*(-t + \tau) \exp[-j2\pi\xi_1 t] dt \right| = |g(-t) \exp[-j2\pi\xi_1 \tau] * g^*(-t + \tau)| = |g(t) * g^*(-t + \tau) \exp[-j2\pi\xi_1 \tau]| \quad (7)$$

上式代表的 AF 切片经过匹配滤波后的输出。

在获取 AF 时延零点切片和频移零点切片后,根据 AF 的对称性原理将两种切片的半轴进行组合,得到 AF 正交切片,图 2 为 10 dB 下 6 类雷达辐射源信号的 AF 正交切片图。

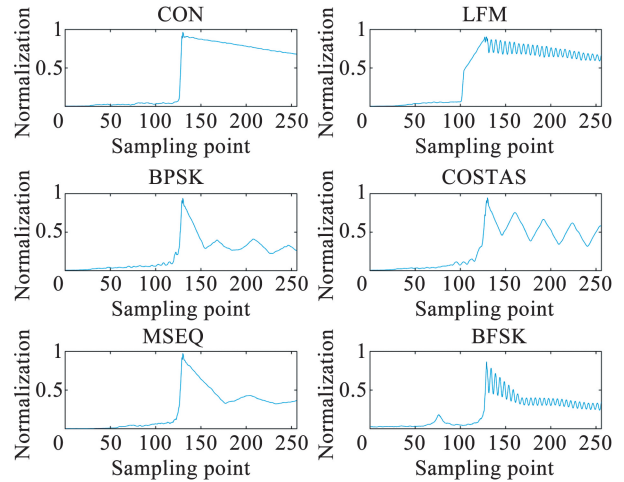


图 2 6 类雷达辐射源信号的 AF 正交切片图

Fig. 2 AF orthogonal slices of six kinds of radar emitter signals

1.2 矩形积分双谱特征提取

双谱是基于二重傅里叶变换的信号处理方法,其物理定义可近似理解为信号偏度在频域上的分解。具体来说,双谱的计算利用三阶累积量的二重傅里叶变换,其信号偏度为三阶累积量、方差为二阶累积量。在处理辐射源信号时,双谱的应用可以有效反映信号的非线性程度,其表达式为

$$B_x(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{+\infty} \sum_{\tau_2=-\infty}^{+\infty} c_{3x}(\tau_1, \tau_2) e^{-j(\omega_1\tau_1 + \omega_2\tau_2)} \quad (8)$$

式中: (ω_1, ω_2) 为双谱平面对应的坐标轴点; $c_{3x}(\tau_1, \tau_2) e^{-j(\omega_1\tau_1 + \omega_2\tau_2)}$ 为信号的三阶累积量。

双谱估计法在辐射源信号特征提取中具有明显的优势,但直接运用双谱估计进行特征提取需要克服其计算复杂度的问题。积分双谱是双谱的二次表征技术,能一定程度降低计算复杂度,常用的积分双谱方法包括:轴向积分双谱(axially integrated bispectra,

AIB)、圆周积分双谱(circularly integrated bispectra, CIB)、径向积分双谱(radially integrated bispectra, RIB)、矩形积分双谱(square integrated bispectra, SIB)。不同积分双谱按不同的积分路线在双谱平面进行特征提取,4种积分双谱的积分路径如图3所示(图中圆点为双谱值)。




图3 4种积分双谱的积分路径

Fig. 3 Integral routes of four kinds of integral bispectra

从图3双谱平面的积分路径来看:AIB提取的特征保留了双谱的幅度信息,并具有尺度变换性,但遗漏了较多的相位信息;RIB具有时移不变的特性,保留了信号的幅度和相位信息,但容易出现遗漏或者重复计算现象,计算结果依赖积分路径的选取;CIB保留了信号的尺度信息,但仍存在双谱值点遗漏的问题,并且计算时需要进行极坐标的转换,增加了特征提取算法的复杂度。

与其他3种积分双谱方式相比,SIB的积分路径能计算信号的所有双谱值信息,不存在信号双谱值的遗漏、重复利用的问题,这能够保证雷达辐射源信号的重要特征信息得到充分利用。当高斯噪声存在时,SIB能够有效抑制噪声,且具有时移不变性,可有效反映信号的尺度、相位信息。因此,选择SIB方法作为双谱估计法的二次表征,用于雷达辐射源信号特征提取。

采用SIB方法提取辐射源信号双谱特征的算法步骤如下:

1) 假设有 c 类未识别辐射源信号,每类信号有 N_c 个样本,其中第 c 类信号的第 i 个样本信号表示为 $x_{c,i}(t)$ 。

2) 对于每个样本信号 $x_{c,i}(t)$,通过公式(8)计

算其双谱 $B_{c,i}(\omega_1, \omega_2)$ 。

3) 根据图3中SIB积分路径来计算SIB提取的双谱特征 $y_j^i(l)$,即:

$$y_j^i(l) = \sum_{s_l} B_{c,i}(\omega_1, \omega_2), l = 1, 2, \dots, L \quad (9)$$

式中: L 为SIB的积分路径总条数; S_l 为图3中SIB采用的第 l 条积分路径。图4为10 dB下6类雷达辐射源信号的SIB提取的双谱二维特征图像。

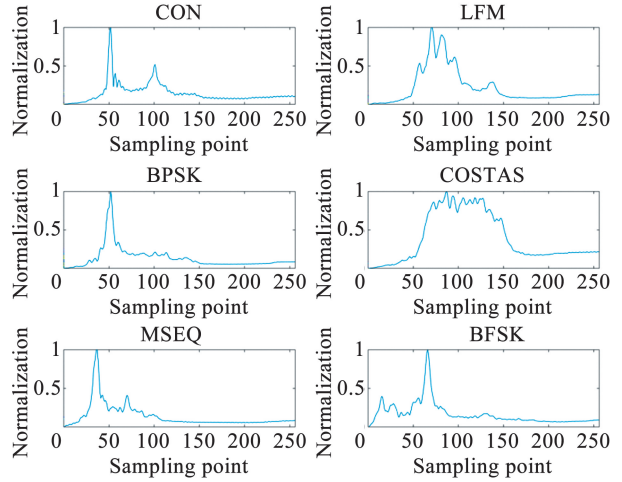


图4 6类雷达辐射源信号SIB双谱特征图

Fig. 4 Square integrated bispectra (SIB) characteristic of six kinds of radar emitter signals

1.3 希尔伯特边缘谱特征提取

HHT由经验模态分解(empirical mode decomposition, EMD)和希尔伯特谱分析(Hilbert spectrum analysis, HAS)两部分组成^[14]。EMD方法是对非平稳信号进行平稳化的处理手段,本质上是通过对信号进行局部分解和反复迭代,将原始信号分解为多个本征模态函数(intrinsic mode function, IMF),然后利用IMF对信号序列进行分解。

EMD过程结束时,雷达辐射源信号 $s(t)$ 被分解为若干个IMFs,即:

$$s(t) = \sum_{k=1}^n c_k(t) + r_n(t) \quad (10)$$

式中: n 为本征模态数; $c_k(t)$ 为第 k 个IMF; $r_n(t)$ 为残余分量。

对式(10)中的信号 $s(t)$ 进行希尔伯特变换后可得:

$$m(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{s(\tau)}{t - \tau} d\tau \quad (11)$$

$s(t)$ 与 $m(t)$ 形成一对复共轭对,则 $s(t)$ 的解析信号可表示为

$$z(t) = s(t) + jm(t) = a(t) \exp[j\varphi(t)] \quad (12)$$

式中： $a(t)$ 为瞬时幅值函数； $\varphi(t)$ 为瞬时相位函数，定义为：

$$a(t) = \sqrt{s(t)^2 + m(t)^2} \quad (13)$$

$$\varphi(t) = \arctan \frac{m(t)}{s(t)} \quad (14)$$

可通过瞬时相位的导数得到瞬时频率 $\omega(t)$ ，定义为

$$\omega(t) = \frac{d\varphi(t)}{dt} \quad (15)$$

至此，经希尔伯特变换后的信号是频率和幅值均为时间函数的 n 个分量的和，其 Hilbert 谱可表示为

$$H(\omega, t) = \text{Re} \sum_{i=1}^n a_i(t) \exp[j\int \omega_i(t) dt] \quad (16)$$

最后对 Hilbert 谱 $H(\omega, t)$ 在时间上进行积分，可得到 Hilbert 边际谱，其定义为

$$h(\omega) = \int_0^T H(\omega, t) dt \quad (17)$$

式中： T 为信号的总长度。Hilbert 边际谱表示每个频率值对应的总振幅值。从统计意义上讲，它反映了信号在整个时间跨度内各频点的能量积累分布情况，更能准确地反映实际信号的频率成分。因此，Hilbert 边际谱更符合非平稳特性雷达信号的处理需求。

图 5 为 10 dB 下 6 类雷达辐射源信号的 Hilbert 边际谱二维特征图像。

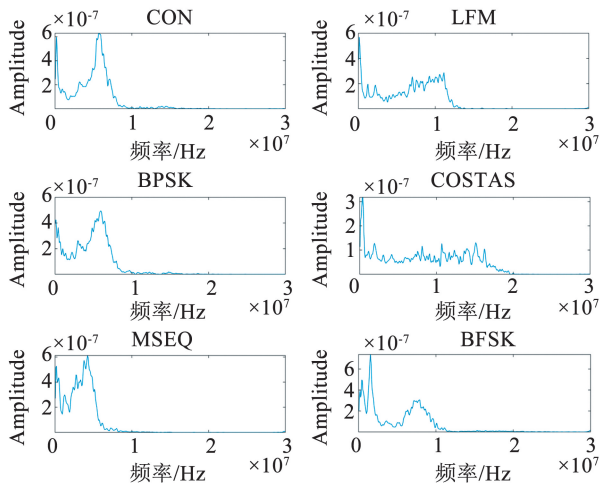


图 5 6 类雷达辐射源信号的 Hilbert 边际谱特征图

Fig. 5 Hilbert marginal spectrum characteristic of six kinds of radar emitter signals

2 辐射源信号识别模型构建

雷达辐射源信号经过多变换域处理后，分别提

取矩形积分双谱特征、模糊函数正交切片特征、Hilbert 边际谱特征并转化为二维图像。鉴于深度神经网络在图像处理中的独特优势，构建了 ResNet18 + MLP 网络模型对上述二维特征图像进行分类识别，多变换域特征融合识别模型框架如图 6 所示。

其中，ResNet18 网络主要作为识别模型的基学习器，通过多变换域特征数据集实现辐射源信号的初级识别，获得以概率形式表征的特征向量；然后采用 MLP 作为元学习器融合特征向量，提升识别精度，获得最终识别结果。

直接利用原始图像进行分类识别，深度神经网络的输入维数太大，计算工程量较高，因此需要对输入图像进行预处理，同时考虑到过多的预处理可能会丢失图像细微信息，所以仅采取灰度化、图像缩放 (Resize)、中心裁剪和归一化等方法进行预处理。

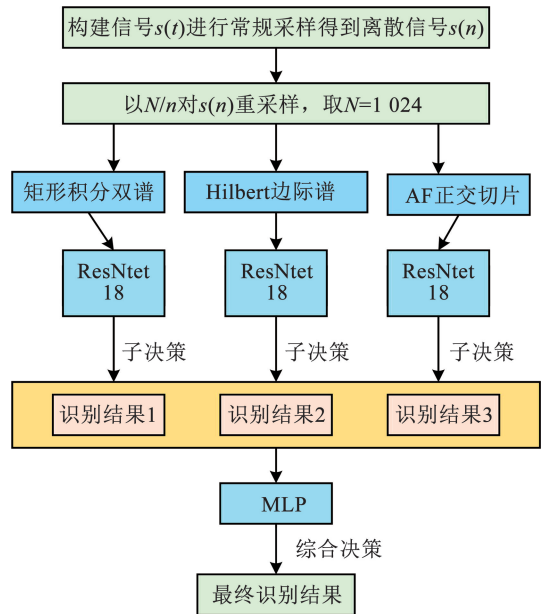


图 6 多变换域特征融合识别模型框架

Fig. 6 Fusion recognition model framework of multiple transform domain features

2.1 ResNet18 网络模型

残差网络 (residual network, ResNet) 采用残差块特殊网络结构^[15]，通过短连接的方式，将神经网络的输入 X 直接连接到有参层的输出 Y ，从而实现“恒等映射”的。在这种映射方式下，有参层可以学习残差映射 $f: X \rightarrow Y - X$ ，该映射可以将输入数据映射成为期望的输出数据，从而有效地解决深度神经网络中梯度消失和梯度爆炸的问题，并且可以加速网络的收敛速度。此外，由于残差块具有非常强的表达能力，可以很好地适应不同类型的数据。图 7 为 ResNet18 模型结构。

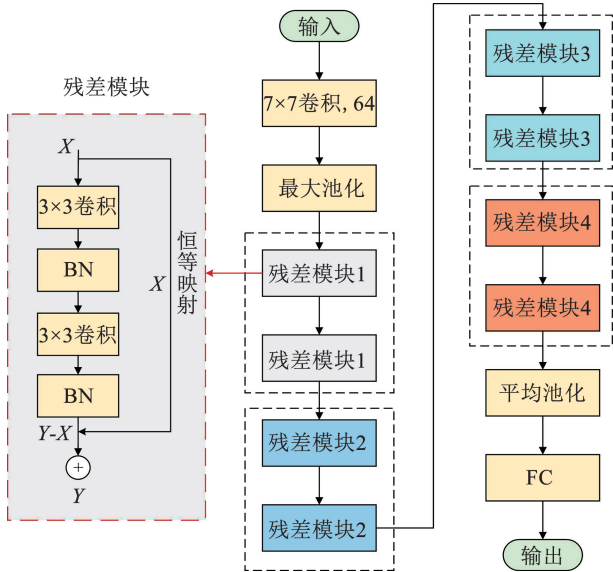


图7 ResNet18 模型结构

Fig. 7 ResNet18 model structure

ResNet18 模型的残差模块数量为 4 个,其中每个残差块中包含 2 个卷积层,卷积层参数设置如表 1 所示。

表 1 ResNet18 参数设置

Tab. 1 ResNet18 parameter settings

残差块	卷积层 1	卷积层 2
1	3 × 3 卷积, 64	3 × 3 卷积, 64
2	3 × 3 卷积, 128	3 × 3 卷积, 128
3	3 × 3 卷积, 256	3 × 3 卷积, 256
4	3 × 3 卷积, 512	3 × 3 卷积, 512

在真实环境中,辐射源信号样本数量通常较为稀缺,如果直接训练 ResNet18 网络模型,易出现过拟合现象。因此,本文采用预训练模型 ResNet18 作为辐射源信号识别的基础模型。

在预训练阶段,模型在 ImageNet 数据集上进行训练,通过学习大规模图像数据集的特征,提高模型的泛化能力和鲁棒性。在辐射源信号识别任务中,为了避免过拟合,本文对原始模型进行了微调,即保留原始 ResNet18 模型的大部分结构,去掉最后的全连接层输出,冻结前 3 个残差块的参数,以此作为一个浅层信号特征提取器。接着,随机初始化第 4 个残差块的参数,用于学习深层特征。最后,增加一个 6 类输出的全连接层,并采用 Softmax 作为分类器获得信号的初步识别结果,得到以概率形式表征的特征向量。

2.2 MLP 网络模型

元学习器需融合初级识别结果并完成最终的识别。多层感知机(multilayer perceptron, MLP)由输入层、隐藏层和输出层构成,具有良好的容错性和自学习功能,故选择 MLP 作为元学习器,基本结构如图 8

所示。




图 8 MLP 基本结构

Fig. 8 Basic structure of MLP

本文所提识别模型采用批量大小为 32 的训练策略,使用 Adam 优化器进行参数更新,并采用交叉熵损失函数作为模型的训练目标。在每个训练批次中,通过反向传播算法计算梯度,更新网络中的权重参数。学习率设置为 0.001,以平衡训练速度和模型收敛性能。

综上,本文基于多变换域特征的雷达辐射源信号融合识别算法如下所示。

算法 1 基于多变换域特征的雷达辐射源信号融合识别算法

1. 初始化变量
Emitter:待识别辐射源
Num:每个辐射源产生的信号个数
SNR:信噪比
 n :信号长度
 N :信号重采样长度
2. for all Emitter do
3. for all SNR do
4. for all Num do
5. 获得离散信号 $s(n)$
6. 根据 N/n 对信号 $s(n)$ 进行重采样,使信号保持相同长度,取 $N=1024$
7. 按第 1 节所提方法,对雷达辐射源信号同时进行双谱估计、模糊函数和 HHT 3 种变换
8. 提取矩形积分双谱、AF 正交切片和 Hilbert 边际谱 3 种变换域的二维特征图像并保存
9. end for
10. end for
11. end for
12. 构建 ResNet18 + MLP 融合模型
13. 输入雷达信号多变换域二维特征图像训练集到融合模型中进行训练,训练结束后保存模型参数
14. 将测试集输入到融合模型中实现分类识别
15. 统计识别结果和识别时间

3 实验结果与分析

3.1 实验环境与信号参数设置

通过仿真 CON、LFM、BPSK、COSTAS、M-SEQ、BFSK 6 类常见辐射源信号验证方法的可行性与有效性,重采样长度 $N = 1\ 024$ 。具体参数设置为:信号采样频率 $f_s = 60\ \text{MHz}$;脉冲载频 $f_c = 10\ \text{MHz}$;脉冲宽度 $\text{PW} = 10\ \mu\text{s}$;其中 LFM 信号的带宽为 $10\ \text{MHz}$, BPSK 和 BFSK 均为 13 位 Baker 码;M-SEQ 编码为 $[1, 0, 1, 1, 1, 0, 0]$;COSTAS 编码为 $[1, 2, 4, 8, 5, 10, 9, 7, 3, 6]$;此外,除 BFSK 的两个频点分别取 $10\ \text{MHz}$ 和 $2\ \text{MHz}$ 之外,其余信号的载频 $f_c = 10\ \text{MHz}$ 。

实验数据的设置:在 $\text{SNR} \in (-10, 18)\ \text{dB}$ 的条件下,每类信号每隔 $2\ \text{dB}$ 生成 40 个不同初相的信号样本,共有 3 600 个信号作为训练集;测试集根据实际实验需求,每个 SNR 下每类信号各产生 200 个,共 1 200 个信号。

高斯白噪声 $n(t)$ 的生成参数设置如下:

在未识别雷达辐射源信号时,信噪比定义为

$$\text{SNR} = 10 \log_{10} (P_{\text{signal}} / P_{\text{noise}}) \quad (18)$$

当获取辐射源信号时,可计算出辐射源信号功率为

$$P_{\text{signal}} = \frac{1}{n} \sum_{t=1}^n |s(t)|^2 \quad (19)$$

式中: n 为辐射源信号长度。计算出信号功率后,通过设置信噪比参数 SNR (如 $-2\ \text{dB}, 0\ \text{dB}, \dots$), 计算出噪声的功率为

$$P_{\text{noise}} = P_{\text{signal}} / 10^{\text{SNR}/10} \quad (20)$$

获得噪声的功率之后,生成标准高斯分布(均值为 0,标准差为 1)的噪声序列(和辐射源信号长度一样),再通过功率归一化转换得到最终所需高斯白噪声 $n(t)$ 。

实验的信号仿真与处理工作在 MATLAB 环境下完成,深度学习环境为 Python 3.6 + Pytorch 1.9。

3.2 多域融合前后识别结果比较

为验证多域融合方法的有效性,对比动态信噪比条件下单个域特征和多域特征融合后的识别结果,如表 2 所示。

从表 2 的实验结果可知,随着 SNR 的增大,单个变换域特征与多域特征融合后的识别结果的差异逐渐变小,SNR 为 $2\ \text{dB}$ 时识别差异小于 1% ;但在低信噪比环境下,经多域特征融合后的识别结果明显高于单个变换域特征,这是因为当 SNR 较低时,多域特征的融合能够有效避免特征被噪声淹没,同时在分类识别时,本文所提的融合模型框架能够充分利用各个域的特征信息,有效归纳并纠正单个变

换域特征的错误识别结果,进而提升整个模型的识别性能。

表 2 多域融合前后识别结果比较

Tab. 2 Comparison of recognition results before and after multi-domain fusion

变换域特征	动态 SNR 下的信号识别率/%				
	-4 dB	-2 dB	0 dB	2 dB	4 dB
AF 正交切片	94.56	96.45	98.42	99.58	100
Hilbert 边际谱	92.89	95.32	97.83	99.19	99.86
矩形积分双谱	93.75	96.08	98.16	99.37	100
多域融合	96.54	98.17	99.23	99.89	100

3.3 不同学习器组合的识别性能对比

为考察不同的基学习器对多变换域特征的识别性能差异,采用经 ImageNet 训练的预训练模型 AlexNet、VGG16 两种深度神经网络作为融合框架模型的基学习器,与 ResNet18 进行对比,对比结果如图 9 所示,识别耗时如表 3 所示。

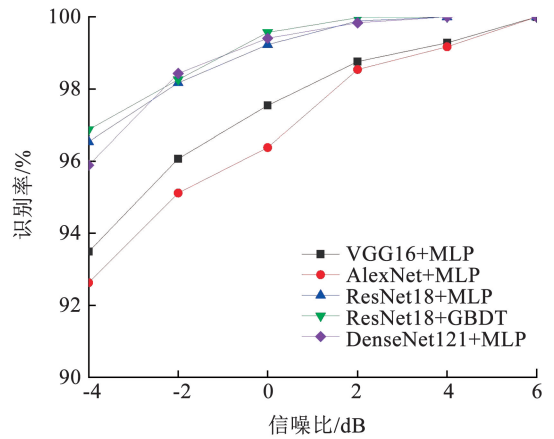


图 9 不同学习器识别性能对比

Fig. 9 Comparison of recognition performance of different learners

表 3 不同学习器识别耗时对比

Tab. 3 Comparison of recognition time of different learners

学习器结构	识别耗时/s
VGG16 + MLP	846.45
AlexNet + MLP	194.12
ResNet18 + MLP	248.76
ResNet18 + GBDT	417.18
DenseNet121 + MLP	589.57

通过图 9 和表 3 可知,在相同 SNR 条件下,本文采用的 ResNet18 + MLP 组合识别效果最佳。分析原因: AlexNet 模型含 5 层卷积层,参数数量较少,虽然识别耗时最短,但识别效果不理想; VGG16 是卷积层超过 10 层的深层卷积神经网络,模型复杂,参数数量最多,易出现梯度消失问题,识别效果受到

影响且识别耗时最长;DenseNet121 模型识别效果与 ResNet18 模型识别效果接近,收敛速度快,但训练时间、迭代速度慢。

同时,与 ResNet18 + MLP 相比,ResNet18 + GBDT 的识别精度略高,但 GBDT (gradient boosting decision tree) 是基于序列的集成算法,每次迭代都需要建立一个新的决策树模型,识别耗时较长。而本文采用 ResNet18 作为识别模型的基学习器,引入了短连接,能够在训练过程中有效缓解梯度消失的问题,使得网络易于学习和优化,进而提升了整个识别模型框架的识别效果;MLP 作为元学习器虽然识别精度略低于 GBDT,但耗时更短,更符合实际应用场景。

3.4 与人工特征提取方法比较

为探究本文所提方法的性能,实验选取 DTW 距离特征^[16]、分形维数三维特征^[17],AF 极坐标域特征^[18] 3 种人工提取特征方法进行对比,结果如图 10 所示。




图 10 与人工特征提取方法比较

Fig. 10 Comparison with manual feature extraction method

由图 10 可知,文献[17]从分形维数中提取近似熵、盒维数和信息维数组成三维特征,虽然能够反映信号时域信息,但低 SNR 时受噪声影响较大,适用范围有限;文献[16]采用样本相似的度量方法构建了 DTW 距离特征,时间复杂度较高,整体识别效果不佳,当 SNR = 6 时识别率仅为 93.89%;文献[18]从坐标转换的思路出发,在不损失 AF 能量信息的情况下,提取了 AF 极坐标域中的致密度等特征,低 SNR 时具有良好的分选成功率,但整体精度低于本文方法。

由此可见,人工提取特征的方法在低 SNR 环境下易受噪声干扰,整体表现不佳。而本文所提方法基于深度学习,虽然需要信号的先验信息,但所提取

的多域特征能够充分表征信号更加完备的内在信息,且具有稳定的抗噪性能,在 -2 dB 的条件下识别准确率达到 98.17%,相较于另外 3 种人工特征提取方法,拥有更优的识别精度。

3.5 不同网络模型识别性能对比

为进一步验证本文所提方法的高效性,通过实验对不同深度学习识别算法进行分析对比,选取文献[19]、[20]和[21]的 3 种方法进行比较,对比结果如图 11 所示。




图 11 与其他深度学习识别算法对比

Fig. 11 Comparison with other deep learning recognition algorithms

由图 11 可以看出,在相同的信噪比环境下,本文方法的识别准确率最高。当 SNR > 4 dB 时,4 种网络结构的识别效果均比较理想,但随着 SNR 的下降,文献[19]和文献[21]所用识别算法的识别准确率下降速度较快,抗噪性能不佳;文献[20]所用识别算法虽然抗噪性较好,但识别准确率提升速度较慢,整体性能并不如本文所提方法。

究其原因,文献[21]采用短时傅里叶变换提取信号特征并排列组合,输入到广义回归神经网络完成信号识别,算法的复杂度较高,且所提特征在低 SNR 下易受噪声影响;文献[19]将雷达信号变换到时频域后,只改变了分类器的类型,对识别准确率提升的效果有限;文献[20]使用双谱分析法提取特征,但采用的卷积神经网络对信号识别的提升效果并不明显,导致整体性能不佳。相比之下,本文基于多变换域特征的模型融合识别方法具有更好的性能表现。

3.6 算法复杂度分析

算法复杂度主要体现为执行该算法时所需要消耗的计算机资源,是雷达辐射源信号识别方法的关键性能指标^[22-24]。为考察本文算法的运算量,分别采用文献[7]、[8]、[25]的特征提取方法与所提出

算法进行复杂度对比,结果如表 4 所示。

表 4 不同方法的算法复杂度对比

Tab. 4 Comparison of algorithm complexity of different methods

特征提取方法	算法复杂度
文献[7]方法	$O(N^2 \log N + 3N^2)$
文献[8]方法	$O(18\ 000N \log N + 7N)$
文献[25]方法	$O((PN + N^2) \log N + N^2)$
本文方法	$O((K+1)N \log N + 3N^2 + 3N)$

文献[7]先对原始信号进行平滑伪 Wigner-Ville 分布变换,单次的复杂度为 $O(N^2 \log N)$,接着对时频图像分别进行开运算、均值滤波和双三次插值法缩放,复杂度为 $O(3N^2)$,故总复杂度为 $O(N^2 \log N + 3N^2)$ 。

根据文献[8]的算法步骤,二维 AFMR 的提取首先需要利用分数自相关计算任意角度对应的 AF 值,复杂度为 $O(N \log N)$ 。此外,需要对 AFMR 进行 18 000 次的搜索,所以复杂度为 $O(18\ 000N \log N)$,之后需对一维 AFMR 进行极坐标变换,复杂度为 $O(7N)$,所以此方法的总复杂度为 $O(18\ 000N \log N + 7N)$ 。

文献[25]中的算法先进行 Chirp 基分解,在二维搜索过程中变换阶次数为 P ,故 Chirp 基分解的复杂度为 $O(PN \log N)$,之后进行伪 Wigner-Ville 分布变换,单次复杂度为 $O(N^2 \log N)$,最后计算 Zernike 矩,复杂度为 $O(N^2)$,总复杂度为 $O((PN + N^2) \log N + N^2)$ 。

在本文方法中,①AF 正交切片特征提取:通过快速傅里叶变换(fast fourier transform, FFT)计算离散 AF 值,此过程的复杂度为 $O(N \log N)$;平滑处理环节,需先对 AF 按行逐渐平滑,接着对中间结果按列依次平滑,复杂度为 $O(2N^2)$,所以,AF 正交切片的算法复杂度为 $O(N \log N + 2N^2)$ 。②矩形积分双谱特征提取:计算其 K 段的三阶累积量,单次复杂度为 $O(N \log N)$,总复杂度为 $O(KN \log N)$;计算双谱值并根据积分路径提取双谱的围线积分双谱特征,进行归一化处理,复杂度为 $O(2N)$,总复杂度为 $O(KN \log N + 2N)$ 。③HHT 边际谱特征提取:计算 Hilbert 谱复杂度 $O(N^2)$,再对 Hilbert 谱在时间上进行积分,其复杂度为 $O(N)$,所以,HHT 边际谱特征的总复杂度为 $O(N^2 + N)$ 。综上,本文方法的总复杂度为 $O((K+1)N \log N + 3N^2 + 3N)$ 。

综上所述,从算法阶数的角度来看,文献[8]的复杂度阶数最低,为 $O(N \log N)$,其余方法复杂度阶数均为 $O(N^2)$,但其余项系数有很大差异。在实

际应用中,采样点数 N 的取值通常在 128 ~ 1 024 范围内,因此可对算法的总计算量 C 进行估算,总计算量的比较结果为: $C_{\text{本文方法}} < C_{\text{文献[25]}} < C_{\text{文献[7]}} < C_{\text{文献[8]}}$ 。算法总计算量的取值范围在 $[10^5, 10^7]$ 区间内,能够很好地适应实时性需求,满足实际应用场景。

4 结 语

本文提出了一种基于多变换域特征融合的雷达辐射源信号识别方法。该方法在信息处理阶段同时提取了辐射源信号的矩形积分双谱特征、模糊函数正交切片特征和希尔伯特边际谱特征,能够充分表征辐射源信号不同层面的内在细微信息;在图像处理阶段采用基于 ResNet18 + MLP 的特征融合框架模型,可以有效提取和利用不同变换域特征之间的互补性,提高识别准确率。仿真实验结果表明,本文所提方法能够充分描述信号间的差异性,整体识别率较高,在低 SNR 条件下也有较好的表现。

本文所识别的雷达辐射源信号调制类型为经典类型,而实际场景中还存在更多复杂多变的雷达辐射源信号,后续研究可以考虑拓展识别的调制类型范围,进一步提升方法的泛化能力。

参 考 文 献

- [1] LIU X Y, YANG S H, JI J, et al. Improvement of underwater laser ranging accuracy based on wavelet time-frequency analysis[J]. IEEE Photonics Journal, 2022, 14(6): 7856105. DOI: 10.1109/JPHOT.2022.3211711
- [2] MISANS P, TERAUDS M. CW Doppler radar based land vehicle speed measurement algorithm using zero crossing and least squares method[C]. Proceedings of the 13th Biennial Baltic Electronics Conference. Tallinn, Estonia: IEEE, 2012: 161. DOI: 10.1109/BEC.2012.6376841
- [3] KISHORE T R, RAO K D. Automatic intrapulse modulation classification of advanced LPI radar waveforms[J]. IEEE Transactions on Aerospace and Electronic Systems, 2017, 53(2): 901. DOI: 10.1109/TAES.2017.2667142
- [4] ZHANG M, LIU L, DIAO M. LPI radar waveform recognition based on time-frequency distribution[J]. Sensors, 2016, 16(10): 1682. DOI: 10.3390/s16101682
- [5] 侯文太, 普运伟, 郭媛蒲, 等. 基于高斯平滑与模糊函数等高线的雷达辐射源信号分选[J]. 自动化学报, 2021, 47(10): 2484
HOU Wentai, PU Yunwei, GUO Yuanpu, et al. Radar emitter signal sorting based on Gaussian smoothing and fuzzy function contour[J]. Acta Automatica Sinica, 2021, 47(10): 2484. DOI: 10.16383/j.aas.c180739
- [6] 王世强, 张登福, 毕笃彦, 等. 双谱二次特征在雷达信号识别中的应用[J]. 西安电子科技大学学报, 2012, 39(2): 127
WANG Shiqiang, ZHANG Dengfu, BI Duyan, et al. Application of bispectrum quadratic feature in radar signal recognition[J]. Journal of Xidian University, 2012, 39(2): 127. DOI: 10.3969/j.issn.

- 1001-2400.2012.02.021
- [7] 谢存祥,张立民,钟兆根. 基于时频特征提取和残差神经网络的雷达信号识别[J]. 系统工程与电子技术,2021,43(4):917
XIE Cunxiang, ZHANG Limin, ZHONG Zhaogen. Radar signal identification based on time-frequency feature extraction and residual neural network [J]. System Engineering and Electronics, 2021, 43 (4):917. DOI: 10.12305/j. issn. 1001-506X. 2021. 04. 08
- [8] 普运伟,刘涛涛,郭江,等. 基于卷积神经网络和模糊函数主脊坐标变换的雷达辐射源信号识别[J]. 兵工学报,2021,42(8):1680
PU Yunwei, LIU Taotao, GUO Jiang, et al. Radar emitter signal recognition based on convolutional neural network and coordinate transformation of ambiguity function main ridge[J]. Acta Armamentarii, 2021, 42 (8): 1680. DOI:10.3969/j. issn. 1000-1093. 2021. 08. 012
- [9] 全大英,陈赞,唐泽雨,等. 基于双通道卷积神经网络的雷达信号识别[J]. 上海交通大学学报, 2022, 56(7):9
QUAN Daying, CHEN Yun, TANG Zeyu, et al. Radar signal recognition based on dual-channel convolutional neural network[J]. Journal of Shanghai Jiaotong University, 2022, 56(7):9. DOI:10.16183/j. cnki. jsjtu. 2021. 209
- [10] ZHANG X, WAN J, ZHAO Y, et al. Recognition of radar emitter signals based on SVD and AF main ridge slice [J]. Journal of Communications & Networks, 2015, 17(5):491. DOI:10.1109/JCN.2015.000087
- [11] HAN J, ZHANG T, REN D, et al. Communication emitter identification based on distribution of bispectrum amplitude and phase [J]. IET Science, Measurement & Technology, 2017, 11(8):1104. DOI: 10.1049/iet-smt. 2017. 0024
- [12] LIU Y J, LIAO G S, YANG Z W. Ambiguity function analysis of intergrated radar and communication waveform based on OFDM [J]. Systems Engineering and Electronics, 2016, 38(9): 2008. DOI: 10.3969/j. issn. 1001-506x. 2016. 09. 07
- [13] WANG W Z, WU H, WANG S S, et al. Extraction method of subtle features in radar signals based on CEEMDAN [J]. Journal of Beihang University, 2016, 42(11):8. DOI:10.13700/j. bh. 1001-5965. 2016. 0410
- [14] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition method and the Hilbert spectrum for non-stationary time series analysis [J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903. DOI:10.1098/rspa. 1998. 0193
- [15] HE K, ZHANG X, REN S, et al. Identity mappings in deep residual networks [J]. Springer, Cham, 2016. DOI:10.1007/978-3-319-46493-0_38
- [16] 黄颖坤,金炜东,颜康,等. 基于距离特征的雷达辐射源信号识别方法[J]. 系统仿真学报,2021,33(12):2959
HUANG Yingkun, JIN Weidong, YAN Kang, et al. Radar emitter signal identification via distance features [J]. Journal of System Simulation, 2021, 33(12):2959. DOI:10.16182/j. issn1004731x. joss. 21-FZ0808
- [17] 曲志昱,毛校洁,侯长波. 基于奇异值熵和分形维数的雷达信号识别[J]. 系统工程与电子技术,2018,40(2):303
QU Zhiyu, MAO Xiaojie, HOU Changbo. Radar signal recognition based on singular value entropy and fractal dimension [J]. System Engineering and Electronics, 2018, 40(2):303. DOI:10.3969/j. issn. 1001-506x. 2018. 02. 10
- [18] 普运伟,郭媛蒲,侯文太,等. 模糊函数主脊切面极坐标域形态特征提取方法[J]. 仪器仪表学报,2018,39(10):1
PU Yunwei, GUO Yuanpu, HOU Wentai, et al. Morphological feature extraction based on the polar transformation of the slice of ambiguity function main ridge [J]. Chinese Journal of Scientific Instrument, 2018, 39 (10): 1. DOI: 10.19650/j. cnki. cjsi. J1803883
- [19] 黄颖坤,金炜东,余志斌,等. 基于深度学习和集成学习的辐射源信号识别[J]. 系统工程与电子技术, 2018, 40(11):6
HUANG Yingkun, JIN Weidong, YU Zhibin, et al. Radar emitter signal recognition based on deep learning and ensemble learning [J]. System Engineering and Electronics, 2018, 40(11):6. DOI: 10.3969/j. issn. 1001-506X. 2018. 11. 05
- [20] 刘赢,田润澜,王晓峰. 基于深层卷积神经网络和双谱特征的雷达信号识别方法[J]. 系统工程与电子技术, 2019, 41(9):8
LIU Ying, TIAN Runlan, WANG Xiaofeng. Radar signal recognition method based on deep convolutional neural network and bispectrum feature [J]. System Engineering and Electronics, 2019, 41(9):8. DOI:10.3969/j. issn. 1001-506X. 2019. 09. 12
- [21] 蒋兵,茅玉龙,曹俊纺. GRNN神经网络在雷达信号调制类型识别中的应用[J]. 电子设计工程, 2018, 26(16):5
JIANG Bing, MAO Yulong, CAO Junfang. Application of GRNN neural network in radar signal modulation type identification [J]. Electronic Design Engineering, 2018, 26(16):5. DOI:10.3969/j. issn. 1674-6236. 2018. 16. 024
- [22] ALKHODARY M T, MUQAIBEL A H. Low complexity sparse Bayesian estimation for UWB radar imaging [J]. Iet Radar Sonar & Navigation, 2018, 12(2):268. DOI:10.1049/iet-rsn. 2017. 0143
- [23] ZHENG L U, GONG Y. Thoughts on the major challenge of radar emitter recognition technology and countermeasures [J]. National Defense Science & Technology, 2017, 38(2):24. DOI:10.13943/j. issn1671-4547. 2017. 02. 06
- [24] DUDCZYK, J. A method of feature selection in the aspect of specific identification of radar signals [J]. Bulletin of the Polish Academy of Sciences Technical Sciences, 2017, 65(1):113. DOI: 10.1515/bpasts-2017-0014
- [25] 张立民,谭凯文,闫文君,等. 基于多级跳线残差网络的雷达辐射源识别[J]. 系统工程与电子技术, 2022, 44(7): 2148
ZHANG Limin, TAN Kaiwen, YAN Wenjun, et al. Radar emitter recognition based on multi-level jumper residual network [J]. Systems Engineering and Electronics, 2022, 44(7): 2148. DOI: 10.12305/j. issn. 1001-506X. 2022. 07. 10

(编辑 丁晓清)