

基于深度时频特征学习的雷达辐射源识别*

李东瑾, 杨瑞娟, 董睿杰

(空军预警学院 预警情报系, 湖北 武汉 430019)

摘要:针对雷达辐射源识别中拓展能力不足和识别率不高问题进行研究,提出一种基于深度时频特征学习的智能识别方法。基于降采样短时傅里叶变换高效提取具备较高辨识度和稳定性的浅层二维时频特征,利用信号局部频域维稀疏性完成降噪等预处理;设计用于深度特征学习与识别的卷积神经网络,并采用不同尺度卷积核组合扩展网络广度,强化特征表征能力;利用高信噪比条件下8种辐射源信号样本对网络进行训练调优,低信噪比样本测试验证算法和网络的有效性。仿真结果表明,该方式在-8 dB信噪比条件下能达到98.31%的整体平均识别率,具备较强的鲁棒性。

关键词:时频特征;降采样短时傅里叶变换;卷积神经网络;雷达辐射源识别;深度学习

中图分类号:TN971 **文献标志码:**A **文章编号:**1001-2486(2020)06-112-08

Radar emitter recognition based on the deep learning of time-frequency feature

LI Dongjin, YANG Ruijuan, DONG Ruijie

(Early Warning Intelligence Department, Air Force Early Warning Academy, Wuhan 430019, China)

Abstract: Aiming at the problem of insufficient expansion ability and low recognition rate in radar emitter recognition, an intelligent recognition algorithm based on the deep learning of time-frequency feature was proposed. The shallow two-dimensional time-frequency features with high recognition and stability were quickly extracted by down sampling of short-time Fourier transform, and the noise reduction and other pre-processing were completed by using the sparseness of the local frequency-domain signal; a convolutional neural network for deep feature learning and recognition was designed, and the scale of the network was expanded by different scale convolution kernels to enhance the feature representation ability; the network was trained and tuned by using eight kinds of emitter signals under high SNR (signal-to-noise ratio) conditions, and the effectiveness of the algorithm and network was verified by a low SNR sample. The experimental results showed that the system achieves overall recognition rate of 98.31% at SNR of -8 dB, which verifies that the proposed algorithm has strong robustness.

Keywords: time-frequency feature; down sampling of short time Fourier transfer; convolutional neural network; radar emitter recognition; deep learning

随着信息化技术和新型装备不断革新,未知辐射源识别技术在电磁频谱域对抗中的重要性日益凸显,高效识别带来的无源信息增益将直接影响电子对抗和探测等后续任务实施的精准化程度。传统基于人工提取的低维参数描述方式受限于综合性能,很难满足现代战场需求。基于此,诸多学者对复杂电磁环境下雷达辐射源识别技术进行研究,完成了模糊函数特征、复杂度特征、纹理特征、时频特征等多域特征提取^[1-5],并通过传统机器学习方法实现有效识别。为降低人为干预程度,部分学者开始致力于自动分类识别系统研究^[6-11],但仍然存在诸多不足:①处理过程未充

分考虑信号本身特性,易引入额外干扰与造成特征丢失;②识别系统可扩展性较低,只针对特定参数或特定类型信号进行识别;③深层特征学习能力和低信噪比环境适应性有待进一步提升。

2006年,Hinton等提出了深度学习的概念,在大数据和强大计算能力推动下,人工智能再次涌向高峰,深度学习技术因其独特优势在物联网、图像识别和计算机视觉等领域取得了显著成绩^[12-13]。深度学习将传统基于规则和人为描述的对象推向更深层表示,诸多深度学习网络中,卷积神经网络(Convolutional Neural Network, CNN)具备较强的三维空间深度表征能力,将其应用于

* 收稿日期:2019-04-16

基金项目:国防科技创新特区基金资助项目(17H86304ZT00302201)

作者简介:李东瑾(1992—),男,四川广元人,博士研究生,E-mail:li_dong_jin@163.com;

杨瑞娟(通信作者),女,教授,博士,博士生导师,E-mail:ruijuany@sohu.com

辐射源识别将有助于提升特征空间维度和辨识度。为提升辐射源识别系统智能化识别能力、环境适应性和可拓展性,本文对浅层特征提取和深层特征学习整个流程进行联合设计。浅层特征提取部分,通过降采样短时傅里叶变换(Down Sampling of Short Time Fourier Transfer, DS-STFT)处理降低计算复杂度并提升信号子空间占比,提取具备较好局部细节表征能力的浅层时频特征,并通过降维、降噪实现特征预处理;深度特征学习部分,扩展 CNN 广度进行多尺度卷积核联合学习,完成浅层特征空间到深层特征空间映射,同时实现高效识别。

1 雷达辐射源识别结构

雷达辐射源识别的整体实现流程如图 1 所示,信号截获后变换至同一中频带宽内进行处理,得到同一采样率下脉内信息序列,随后进行浅层特征提取与深层特征学习,最终通过训练得到性能较好的深度学习网络并用于分类识别。

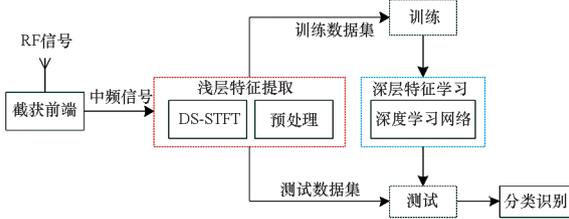


图1 雷达辐射源识别结构示意图

Fig. 1 Structure diagram of radar emitter recognition

考虑高斯白噪声环境时,截获后辐射源信号脉冲采样序列为

$$x(k) = A \exp \{ j [2\pi f_0 k + \varphi(k) + \psi] \} + n(k) \quad (1)$$

其中, A 为辐射源幅度, f_0 为辐射源信号载频, ψ 为初始相位, $\varphi(\cdot)$ 为脉内调制信息, $n(\cdot)$ 为高斯白噪声。辐射源特征差异集中体现在 $\varphi(k)$,其中非线性调频(NonLinear Frequency Modulation, NLFM)信号满足 $\varphi(k) = \pi\beta_1 k^2 + 2\pi\beta_2 k^3/3$, β_1 和 β_2 均为调制系数;多相编码(Frank)信号则满足 $\varphi(k) = 2\pi(m_0 - 1)(n_0 - 1)/M(m_0, n_0 = 1, \dots, M; M$ 为多相码参数)。本文主要考虑八种调制方式,即单载频雷达信号(Single Carrier Radar signals, SCR)、线性调频信号(Linear Frequency Modulation signals, LFM)、NLFM、二相编码(Binary Phase Shift Keying, BPSK)信号、四相编码(Quadrature Phase Shift Keying, QPSK)信号、Frank信号、二相频率编码(Binary Frequency Shift

Keying, BFSK)信号、四相频率编码(Quadrature Frequency Shift Keying, QFSK)信号。

2 基于 DS-STFT 的浅层时频特征提取

本节采用 DS-STFT 方式提取具备平稳表征的信号时频特征,并降低计算复杂度与细节特征损失。对中频信号进行处理时,采样率 f_s 一般大于奈奎斯特采样率。设中频带宽和中频分别为 B_s 、 f_1 ,原始采样序列长度为 N_0 ,则能够恢复原始信号的最小采样序列长度为

$$N_s = \begin{cases} 2 \cdot \left(f_1 + \frac{B_s}{2} \right) \frac{N_0}{f_s} = 2f_{\max} \frac{N_0}{f_s} & \text{实信号} \\ \left(f_1 + \frac{B_s}{2} \right) \frac{N_0}{f_s} = f_{\max} \frac{N_0}{f_s} & \text{复信号} \end{cases} \quad (2)$$

其中, N_s 向上取整, f_{\max} 为等效频率上限。引入降采样因子 β 进行处理,降采样平均序列为

$$x_1(n_1) = \frac{1}{\beta} \sum_{k=0}^{\beta-1} x(k + n_1\beta) \quad (3)$$

其中, $1 \leq \beta \leq \lceil \frac{N_0}{N_s} \rceil$ 且为整数, $\lceil \cdot \rceil$ 为向上取整。

实信号可通过希尔伯特变换转换为复数域解析信号,解析信号的 β 选择更为灵活,但会引入额外计算量,本文主要考虑实数域处理。DS-STFT 方式有别于低速采样,低速采样面临着局部特征不确定性,尤其是局部细微特征处能量微弱时易导致细节弱化或丢失;DS-STFT 方式能够充分利用高速采样带来的信息增益,通过局部信息加权平均对能量微弱的局部细节特征部分加以强化,有效避免后续处理带来的细节特征损失。

2.1 二维时频信号模型

短时傅里叶变换^[14]对局部特性和整体结构具备较稳定的表征能力。离散域短时傅里叶变换为

$$STFT_x(m, n) = \sum_{k=0}^{N-1} x(k) h^*(k-m) \exp\left(-j \frac{2\pi n k}{N}\right) \quad (4)$$

其中, m 、 n 分别为时域、频域索引, N 为傅里叶变换长度, $h(k)$ 为窗函数,此处选用 $N/4$ 长度的Hamming窗。因此,DS-STFT表示为

$$\begin{aligned} DS-STFT_x(m, n, \beta) &= \frac{1}{\beta} \sum_{k=0}^{N-1} \sum_{i=0}^{\beta-1} x(i+k\beta) h^*(k-m) \exp\left(-j \frac{2\pi n k}{N}\right) \\ &= \sum_{k=0}^{N-1} x_1(k) h^*(k-m) \exp\left(-j \frac{2\pi n k}{N}\right) \end{aligned} \quad (5)$$

其中,对应参数 β 与 N 选择方式为:①当 $1 \leq \beta \leq N_0/N_s$ 时,傅里叶变换长度等于序列长度,即 $N = N_1$ (N_1 为 $x_1(n_1)$ 的有效长度)。 $\beta = 1$ 时, $N = N_0$,计算量较

大; $\beta \geq 2$ 时, 计算复杂度由 $O(N^4)$ 降低为 $O(N_1^4)$ 。
 ②当 β 达到理论上限 $\lceil N_0/N_s \rceil$, 若 $N_1 < N_s$, 需保持最小傅里叶变换长度 N_s 不变, 避免频域混叠。

DS-STFT 处理带来了信号子空间占比增益, 有利于后续识别。引入信号子空间占比系数 γ 对其进行定量描述, 首先将 DS-STFT 信号二值化, 得到信号 $DS-STFT'_x(m, n, \beta)$, 然后投影至频域维, 投影信号为

$$f_\beta(n) = \sum_m |DS-STFT'_x(m, n, \beta)| \quad (6)$$

以 $f_\beta(n)$ 均值为门限, 过门限值部分对应信号子空间投影, 其余部分对应噪声子空间投影, γ 表示为

$$\gamma = \frac{\text{sum}(f_\beta \geq \text{mean}(f_\beta))}{N_f} \quad \beta = 1, 2, \dots, \lceil \frac{N_0}{N_s} \rceil \quad (7)$$

其中, N_f 为 $f_\beta(n)$ 信号序列长度, $\text{mean}(\cdot)$ 为取均值, $\text{sum}(\cdot)$ 为完成过门限信号个数统计。

设载频为 10 MHz, f_{\max} 为 25 MHz, f_s 为 200 MHz, N_0 为 2200, 得到表 1 所示八类信号系数 γ 随 β 变化情况。其中, BPSK 与 QPSK 信号因相似度较高, γ 一致, 其余信号 γ 差异较大。总体来看, γ 随 β 增大, 在 $\beta = 1$ 时最小, $\beta > 1$ 时增益约 β 倍。当 β 达到理论上限 4 时, $N_1 = N_s$, 进一步增大 β 不带来增益。

表 1 信号子空间占比系数对比

| 类型 | $\beta = 1$ | $\beta = 2$ | $\beta = 3$ | $\beta = 4$ |
|-------|-------------|-------------|-------------|-------------|
| SCR | 0.011 8 | 0.023 6 | 0.032 8 | 0.040 0 |
| BFSK | 0.027 3 | 0.052 7 | 0.076 5 | 0.101 8 |
| QFSK | 0.058 2 | 0.114 5 | 0.169 4 | 0.221 8 |
| LFM | 0.057 3 | 0.112 7 | 0.163 9 | 0.218 2 |
| NLFM | 0.104 5 | 0.205 5 | 0.306 0 | 0.400 0 |
| BPSK | 0.017 3 | 0.034 5 | 0.049 2 | 0.065 5 |
| QPSK | 0.017 3 | 0.034 5 | 0.049 2 | 0.065 5 |
| Frank | 0.082 7 | 0.163 6 | 0.240 4 | 0.320 0 |

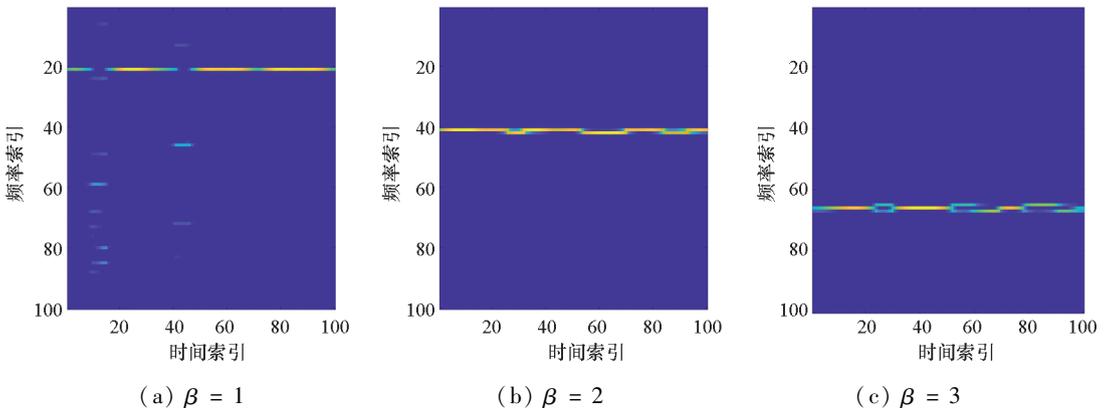


图 2 不同 β 条件下 BPSK 信号时频特征对比 ($SNR = -5$ dB)

Fig. 2 Comparison of time-frequency characteristics of BPSK signals under different β ($SNR = -5$ dB)

2.2 时频信号预处理

经 DS-STFT 处理后的时频信号维度仍然较大, 且存在噪声干扰, 可通过下述流程进行降维与降噪:

步骤 1: 对原始时频信号 $A_{N_1 \times N_1}$ 下采样, 降维后信号 $A_{p \times q}$ 本征结构和信号子空间占比系数 γ 基本不变。

步骤 2: 构建滤波系数矩阵 $F_{p \times q}$, 初始值为 $F_{p \times q} = A_{p \times q} \circ$

步骤 3: $F_{p \times q} = [f_1, f_2, \dots, f_q]$ 中列信号对应局部频域维特征, 具备稀疏性。 f_1 对应第一列元素, 逐列进行归一化处理

$$f_j = \frac{f_j}{\max(f_j)} \quad j = 1, 2, \dots, q \quad (8)$$

步骤 4: 滤波系数优化。选取系数增强函数 $g(x) = x^3$ 进行如下系数稀疏化表示

$$f_{i,j} = \begin{cases} g(f_{i,j}) & f_{i,j} \geq \text{mean}(f_j); i = 1, 2, \dots, p \\ 0 & f_{i,j} < \text{mean}(f_j); j = 1, 2, \dots, q \end{cases} \quad (9)$$

由于系数增强函数收敛较快, 重复步骤 3 ~ 4 迭代 2 次即可完成系数优化。

步骤 5: 降噪后二维时频信号更新为 $\tilde{A}_{p \times q} = A_{p \times q} \cdot F_{p \times q} \circ$

图 2 所示为 -5 dB 时 BPSK 信号预处理后不同 β 对应的浅层时频信号。由图可知: 信号子空间在不同 β 取值时相对位置存在差异; 信号子空间占比系数 γ 随 β 增大, γ 越大预处理所能保留的细节特征越明显, 其中 $\beta = 3$ 时对应信号子空间占比最大, 能够保留相位变化处更多细节特征。降噪处理能较好地抑制噪声子空间影响, 仅 $\beta = 1$ 时存在部分孤立噪声点, 因此合理选择 β 能够有效保留细节特征。

3 基于卷积神经网络的深度特征学习

3.1 卷积神经网络

CNN 具备二维特征深度学习能力,为避免人为确定卷积核类型,采用不同尺度卷积核扩展网络广度,网络结构及参数如图 3 所示。输入为二维时频信号 $\tilde{A}_{p \times q}$,各卷积层通过小卷积核组合获取强力特征。第一卷积层采用 7 个 3×3 卷积核和 3 个 5×5 卷积核提取特征,得到 10 通道特征图;第二卷积层采用 4 个 3×3 卷积核和 8 个 5×5 卷积核得到 12 通道特征图。各卷积层输出激活函数为 $f(x) = \max(0, x)$,为降低计算量,卷积层后加入最大池化层。输出层数据 $x_i (i = 1, \dots, 8)$ 采用 softmax 分类器进行处理,分类识别结果 R 为

$$R = \max_i \frac{e^{x_i}}{\sum_i e^{x_i}} \quad i = 1, 2, \dots, 8 \quad (10)$$

3.2 深度特征学习及识别

CNN 训练调优与测试过程为:①训练阶段。输入带标签时频信号样本,每个样本映射得到 12 通道 14×14 特征图,实现 3600 维浅层时频特征空间到 2352 维深层特征空间(全连接层)的映射,并通过输出层和分类器完成特征空间到 8 维类别空间映射;正向传播误差信号通过随机梯度下降算法进行反向传播与参数调优。②测试阶段。输入经过相同特征预处理的时频信号用于分类识别,完成性能验证。

4 仿真实验与分析

4.1 仿真参数设置

为验证本文识别方法有效性,利用第 1 节所

述 8 种雷达辐射源信号进行仿真实验。对应参数设置如下:①充分考虑信号多样性,所有信号频段位于 $[0, f_{\max}]$ 且载频随机分布:SCR 载频 10 ~ 30 MHz;BPSK 和 BFSK 随机采用 7、11、13 位 Barker 码;QFSK 频率编码和 QPSK 相位编码随机选择‘1,3,2,4,3,2,3,4,3,1,2’或‘4,1,3,2,1,4,1,3,2,3,4’;LFM 载频 10 ~ 25 MHz,带宽 5 ~ 10 MHz;NLFM 载频 10 ~ 25 MHz,调制系数 $\beta_1 = \beta_2$ 并随机取值 5 ~ 10;Frank 信号中 M 随机取值 5 ~ 8。②保持单个辐射源信号参数不变,选取五类共 10 种辐射源信号:SCR1 信号载频 10 MHz、SCR2 信号载频 20 MHz;BPSK1、BPSK2 分别采用 7 位、11 位 Barker 码;BFSK1、BFSK2 分别采用 7 位、13 位 Barker 码;LFM1 载频 10 MHz 且带宽为 5 MHz、LFM2 载频 25 MHz 且带宽为 8 MHz;Frank1、Frank2 信号中 M 分别取 5 和 8。

测试环境如下: f_{\max} 与 f_s 分别为 40 MHz、300 MHz, β 取 1 ~ 4,脉宽与采样时长均取 11 μ s。在 20 ~ 30 dB 信噪比条件下随机生成训练样本,每类信号 500 个样本,共 4000 个训练样本;在 -14 ~ 10 dB 信噪比(步长 2 dB)条件下随机生成测试样本,每个信噪比对应 200×8 个样本,共计 20 800 个测试样本。计算机配置为 CPU i5 - M480,内存 6.00 GB, MATLAB 版本为 R2018b。

4.2 参数选择与网络测试

选择参数设置①得到图 4 所示结果,其中图 4(a)为 DS-STFT 算法中不同 β 对应的性能曲线,平均识别率随信噪比提升不断增大。当 $\beta \leq 3$ 时,平均识别率随 β 增大; $\beta = 1$ 时 γ 最小,降维丢失细节特征,识别能力最弱; $\beta = 2$ 时 γ 增大带来性能提升; $\beta = 3$ 时 γ 较大,降维仍能保留较多细节

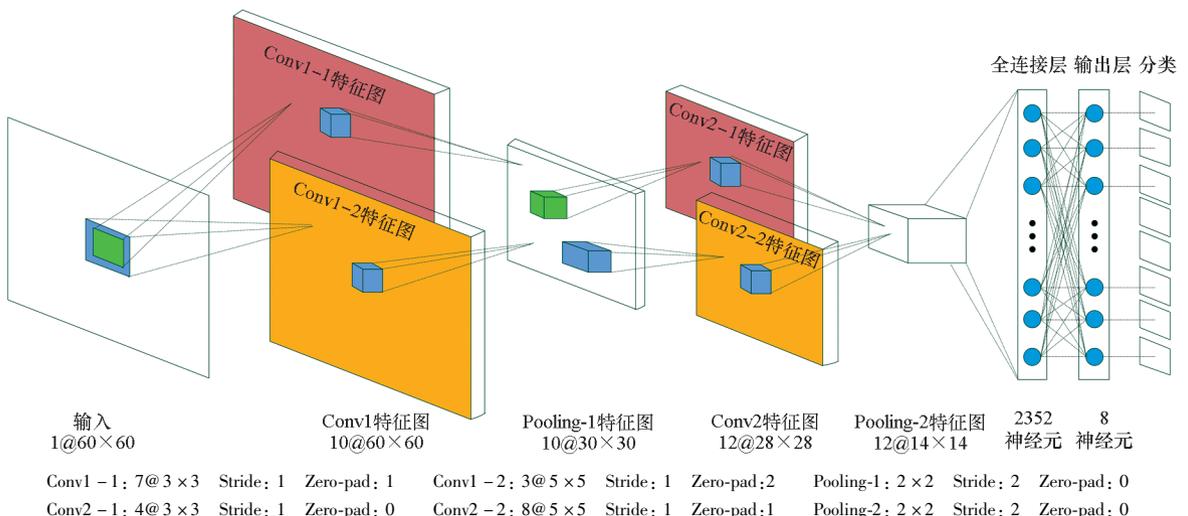
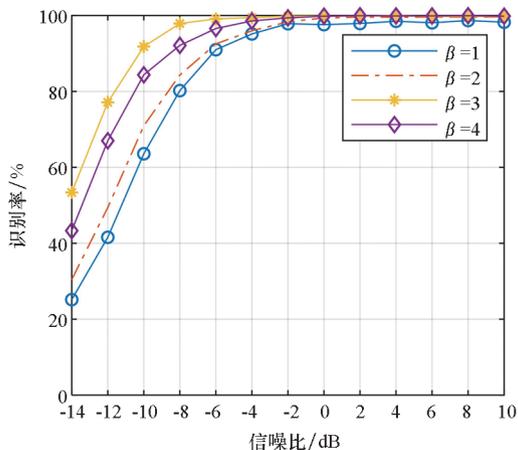


图3 CNN 网络结构及参数

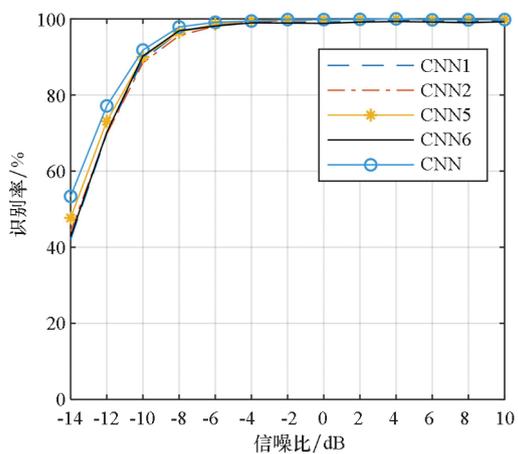
Fig. 3 CNN network structure and parameters

特征,识别性能最佳, -10 dB 时达到 90.81% 的平均识别率。当 β 取上限值 4 时, γ 提升有限, 此时信号有效长度小于傅里叶变换长度, 处理后细节特征弱化, 识别率反而降低。综合分析得出, 合理降采样能够提升信号子空间占比并保留更多细节特征, 有效避免了降维等处理带来的细节特征损失, 本文选择降采样因子 $\beta=3$ 进行浅层时频特征提取。



(a) 不同 β 的识别结果

(a) Recognition results for different β



(b) $\beta=3$ 时不同 CNN 识别结果

(b) Recognition results for different CNN when $\beta=3$

图 4 不同条件下识别结果

Fig. 4 Recognition results under different conditions

在信号参数随机条件下, 忽略网络广度, 各层选取单一卷积核进行对比测试, 结果如表 2 所示, 图 4(b) 为部分网络全局对比结果。其中: CNN1 ~ CNN16 对应不同尺度 (3, 5, 7 和 9) 卷积核组合方式; CNN 为本文深度学习网络; CNN17 和 CNN18 在 CNN 基础上改变卷积核为扩张卷积形式^[15], 对应扩张因子分别为 2-dilated 和 3-dilated, 该方式能够保持参数总数不变并扩大感受野。为保证一致性, 通道数和特征图大小保持不变, 选取 -12 dB、-10 dB 和 -8 dB 识别结果平均值进行

对比, 所有结果取 10 次平均。

表 2 不同 CNN 识别性能对比

Tab. 2 Recognition result of different CNN

| 神经网络 | 第一层 | 第二层 | 平均识别率/% |
|-------|-----------------------------|-----------------------------|---------|
| CNN | 3×3 & 5×5 | 3×3 & 5×5 | 89.08 |
| CNN1 | 3×3 | 3×3 | 86.50 |
| CNN2 | | 5×5 | 86.32 |
| CNN3 | | 7×7 | 85.16 |
| CNN4 | 5×5 | 9×9 | 85.62 |
| CNN5 | | 3×3 | 86.75 |
| CNN6 | | 5×5 | 86.56 |
| CNN7 | 7×7 | 7×7 | 84.98 |
| CNN8 | | 9×9 | 84.56 |
| CNN9 | | 3×3 | 84.87 |
| CNN10 | 7×7 | 5×5 | 84.55 |
| CNN11 | | 7×7 | 84.36 |
| CNN12 | | 9×9 | 84.22 |
| CNN13 | 9×9 | 3×3 | 83.35 |
| CNN14 | | 5×5 | 83.98 |
| CNN15 | | 7×7 | 84.01 |
| CNN16 | 9×9 | 83.68 | |
| CNN17 | 3×3 & 5×5 | 3×3 & 5×5 | 83.33 |
| CNN18 | 3×3 & 5×5 | 3×3 & 5×5 | 83.21 |

对比得出, 识别率随卷积核增大呈下降趋势, 扩张卷积感受野较大且性能最差, 而 CNN1、CNN2、CNN5、CNN6 采用小卷积核形式性能更优, 其原因在于本文输入特征为 60×60 , 尺度相对较小, 而细节特征差异也主要聚焦在局部感受野, 因此小卷积核形式获取到的局部感受野特征更有利于识别。综合来看, 本文的多尺度卷积核组合形式 CNN 在低信噪比条件下性能最优。表 3 所示为 -8 dB 信噪比下混淆矩阵, 整体平均识别率达到 98.31%, 其中 LFM 与 NLFM 信号、SCR 与 BPSK 信号由于差异性较小存在一定程度混淆。

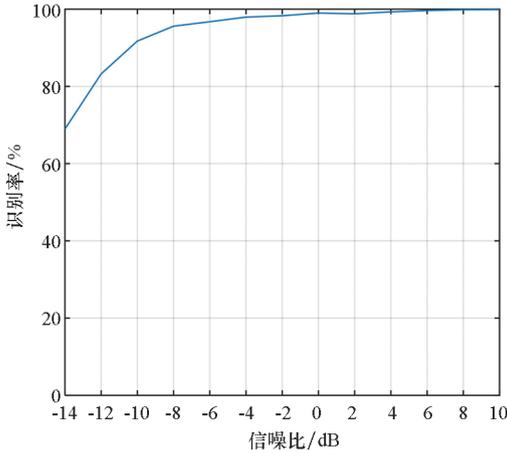
参数设置②测试结果如图 5 所示。由于辐射源参数固定, 无须学习随机变化特征, 低信噪比下识别能力优于随机参数下的类间识别, -14 dB 时平均识别率达到 68.95%。其中, BPSK1 信号识别率相对较低, 且收敛较慢, 原因在于该信号子空间占比较小, 在降维过程极易丢失细节特征, 易与 SCR 和同类 BPSK 信号产生混淆。对比图 5 与

图 4(a),可见本文方法具备较大的灵活性,既能用于参数多变的类间识别,也能有效完成类内类间综合识别。

表 3 -8 dB 时辐射源信号识别结果

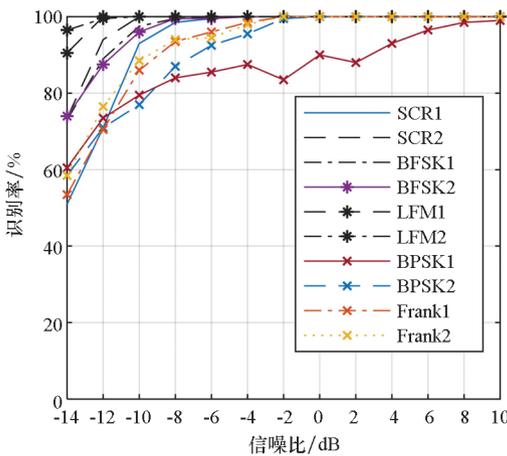
Tab.3 Recognition result of radar emitter signal at -8 dB

| | % | | | | | | | |
|-------|------|------|------|------|------|------|------|-------|
| | SCR | BFSK | QFSK | LFM | NLFM | BPSK | QPSK | Frank |
| SCR | 98.5 | 0 | 0 | 0 | 0 | 1.5 | 0 | 0 |
| BFSK | 0 | 100 | 0 | 0 | 0 | 0 | 0 | 0 |
| QFSK | 0 | 0 | 100 | 0 | 0 | 0 | 0 | 0 |
| LFM | 0 | 0 | 0 | 99.5 | 0.5 | 0 | 0 | 0 |
| NLFM | 0 | 0 | 0 | 11.5 | 88.5 | 0 | 0 | 0 |
| BPSK | 0 | 0 | 0 | 0 | 0 | 100 | 0 | 0 |
| QPSK | 0 | 0 | 0 | 0 | 0 | 0 | 100 | 0 |
| Frank | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 100 |



(a) 整体平均识别率

(a) Overall average recognition rate



(b) 各类型信号识别结果

(b) Recognition results of all types

图 5 类内类间综合识别性能

Fig.5 Comprehensive recognition performance within and between classes

4.3 不同识别方法性能对比

选用文献[9]和文献[10]的识别方法进行对比,相同条件下识别结果如图 6 所示。文献[9]采用两级识别完成分类,在 -5 dB 以上能够有效识别 BFSK、QFSK、LFM、NLFM 和 Frank 信号,但难以有效提取窄带信号内细节特征,对 SCR、BPSK 和 QPSK 信号的辨识度较低,其中 SCR 极易混淆为 BPSK 或 QPSK。文献[10]提取时频二次特征,运用强化深度信念网络完成识别,-8 dB 以上综合识别率高于文献[9],其中 SCR、LFM 和 NLFM 信号在 -6 dB 以上能够高效识别;低噪声环境下特征稳定性不高,-14 dB 时 BFSK、QFSK、LFM、BPSK、QPSK 几乎不能识别,QPSK 信号在 1 dB 以上才能与 BPSK 有效区分。对比来看,上述两种方式在高信噪比条件下识别率较高,但对差异性较小信号均存在一定程度混淆;本文 CNN 方式在整体识别率和各类型信号率上都表现最优,各类信号识别率均随信噪比平稳上升,特征稳定性较高,能够高效区分几类易混淆信号,具备较强鲁棒性。

综合来看,识别率差异主要体现在相似信号上,特征差异性较小信号识别率相对较低,主要有两类:一类为 SCR、BPSK 和 QPSK,其时频空间差异主要集中在相位变化处,且特征变化相对较微弱,极易受噪声影响;另一类为 LFM 和 NLFM,时频空间结构具备较大相似性,为识别带来难度。因此,在预处理阶段保留足够的细节特征将有利于后续识别,DS-STFT 处理方式充分利用高速采样带来的信息增益,通过降采样提升信号子空间占比并强化微弱特征,进而提升识别率。相比于常规固定参数辐射源识别,本文方式无须信号载频估计等先验知识,能够对随机参数集进行深度特征学习,能够有效适应实际环境中参数随机多变的复杂情况。同时,深层特征空间维度较高,具备冗余拓展能力,当加入新类型信号时,可保持 CNN 结构不变,适当提高降维参数,保留更多细节特征;也可保持整体流程不变,合理增大 CNN 深度与广度。

计算复杂度是衡量系统性能的另一重要指标,采用时间维进行度量,结果取 10 次平均。本文特征提取平均时间约为 0.077 s,文献[9-10]对应平均时间约为 0.082 s、0.085 s,本文特征提取方式无须多次迭代和二次特征处理,时效性更强。CNN 训练时间约为 137.534 s,文献[9-10]对应训练时间约为 130.068 s、80.562 s;文献[9]训练时间与本文相当,但二次识别过程复杂度增

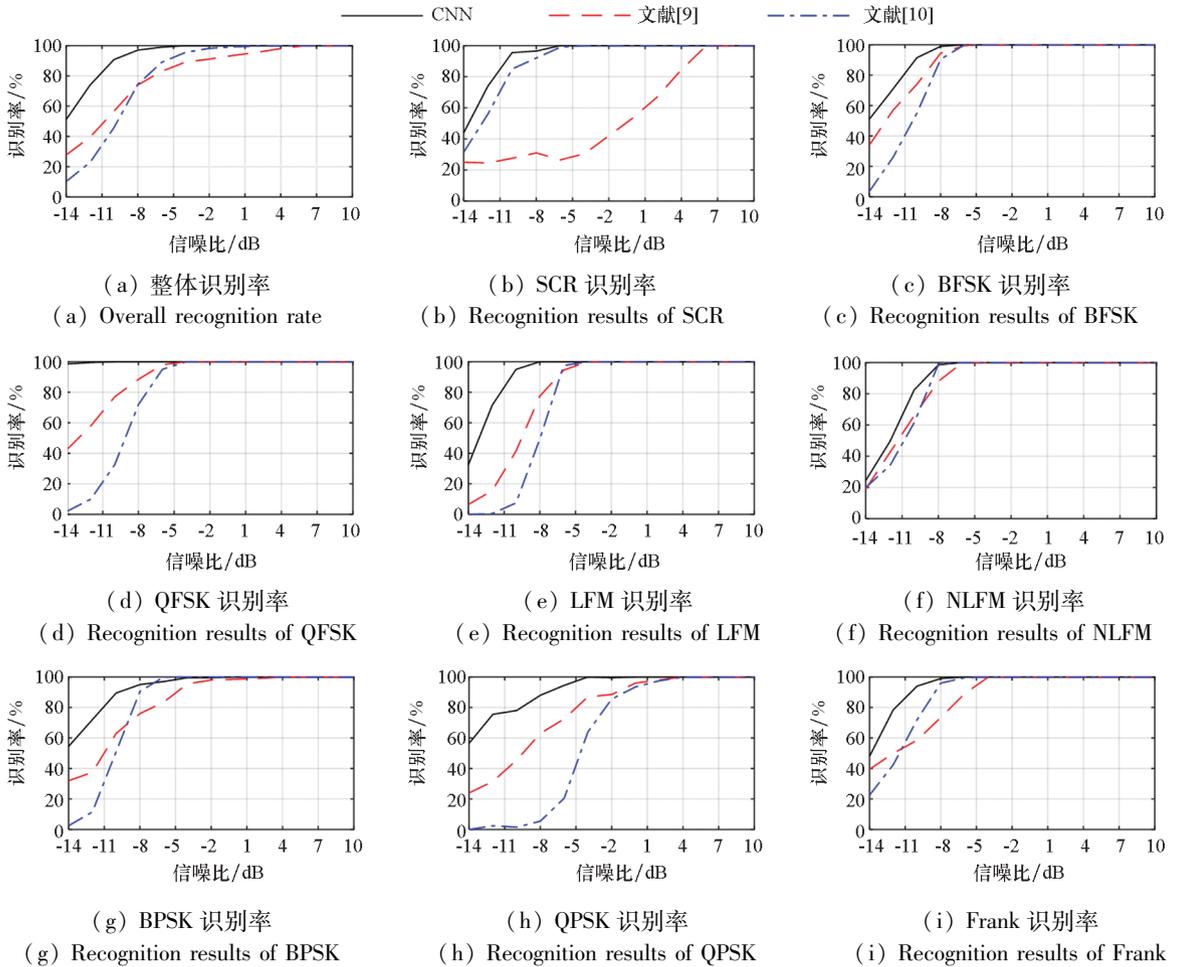


图 6 不同算法下各类信号识别性能比较

Fig. 6 Recognition performances under different algorithms

大;文献[10]的输入特征进行了等效降维处理,时效性相对较高;本文 CNN 网络具备深层特征抽象能力,网络参数较多导致训练较耗时,若采用图形处理器或高性能计算机,时效性将得到高效提升。监督学习方式下训练可离线完成,主要考虑识别过程的时效性。为充分对比上述识别方式时效性,进一步对测试样本中不同调制类型信号的识别时间进行对比,结果如表 4 所示。本文方式下各类型信号识别时间差异性不大,LFM、NLFM、BPSK 和 QPSK 信号的识别相对更耗时;文献[9]中 SCR、BPSK、QPSK 需二次识别,耗时相对增大,其余信号耗时与本文差异性不大;文献[10]为一维特征向量处理且网络参数相对较少,测试时间较短。

综合对比识别能力及时效性,三种识别方式均采用了深度学习思想,文献[9]方式时效性与本文相当,识别能力相对较弱;文献[10]方式时效性较强,但低信噪比环境下特征稳定性不足,其深度特征学习能力和复杂电磁环境适应能力存在一定局限性;本文方式能够有效兼顾时效性和环

境适应性,在低信噪比环境下识别率较高。

表 4 识别时效性对比

Tab. 4 Comparison of timeliness

单位:s

| | CNN | 文献[9] | 文献[10] |
|-------|--------|--------|--------|
| SCR | 6.807 | 7.451 | 4.612 |
| BFSK | 6.947 | 6.784 | 4.562 |
| QFSK | 7.786 | 7.825 | 4.835 |
| LFM | 8.182 | 8.056 | 4.816 |
| NLFM | 8.781 | 8.568 | 4.952 |
| BPSK | 7.864 | 8.354 | 4.528 |
| QPSK | 7.882 | 8.403 | 4.692 |
| Frank | 7.283 | 7.205 | 4.694 |
| Total | 61.532 | 62.648 | 37.691 |

5 结论

本文提出了一种基于 DS-STFT 浅层时频特征提取与深度特征学习的联合识别方法,DS-STFT 处理充分考虑了稀疏域降噪与降维,能够高

效提取高稳定性时频特征,并通过合理选取降采样因子提升特征辨识度与识别能力;深度学习网络兼顾了网络宽度与深度,具备智能识别能力和较强的拓展性,避免了人为特征提取的深度不足且降低了计算复杂度。仿真验证了算法的有效性,卷积神经网络具备较强深度特征学习能力,能够适应参数变化的类间识别和固定参数辐射源的内类间综合识别;系统对低信噪比环境适应性较强, - 10 dB 条件下整体平均识别率不低于 90%,具备较强的鲁棒性。

参考文献 (References)

- [1] Guo Q, Nan P L, Wan J. Radar signal recognition based on ambiguity function features and cloud model similarity [C]// Proceedings of 8th International Conference on Ultrawideband and Ultrashort Impulse Signals. IEEE, 2016: 128 - 134.
- [2] Zhang G X, Jin W D, Hu L Z. Radar emitter signal recognition based on complexity features [J]. Journal of Southwest Jiaotong University, 2004, 12(2): 116 - 122.
- [3] Thayaparan T, Stankovic L, Amin M, et al. Time-frequency approach to radar detection, imaging, and classification [J]. IET Signal Processing, 2010, 4(4): 325 - 328.
- [4] Yang L B, Zhang S S, Xiao B. Radar emitter signal recognition based on time-frequency analysis [C]// Proceedings of IET International Radar Conference, 2013: 1 - 4.
- [5] 白航, 赵拥军, 胡德秀. 时频图像局部二值模式特征在雷达信号分类识别中的应用 [J]. 宇航学报, 2013, 34(1): 139 - 146.
BAI Hang, ZHAO Yongjun, HU Dexiu. Radar signal recognition based on the local binary pattern feature of time-frequency image [J]. Journal of Astronautics, 2013, 34(1): 139 - 146. (in Chinese)
- [6] Zhang M, Liu L T, Diao M. LPI radar waveform recognition based on time-frequency distribution [J]. Sensors, 2016, 16(10): 1682 - 1706.
- [7] Iglesias V, Grajal J, Royer P, et al. Real-time low-complexity automatic modulation classifier for pulsed radar signals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(1): 108 - 126.
- [8] Zhou Z W, Huang G M, Chen H Y, et al. Automatic radar emitter waveform recognition based on deep convolutional denoising auto-encoders [J]. Circuit Systems and Signal Process, 2018, 37(9): 4034 - 4048.
- [9] Wang X B, Huang G M, Zhou Z W, et al. Radar emitter recognition based on the short time Fourier transform and convolutional neural networks [C]// Proceedings of 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics. IEEE, 2017: 1 - 5.
- [10] Wang X B, Huang G M, Zhou Z W, et al. Radar emitter recognition based on the energy cumulant of short time Fourier transform and reinforced deep belief network [J]. Sensors, 2018, 18(9): 1 - 22.
- [11] Wang C, Wang J, Zhang X D. Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network [C]// Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing, 2017: 2437 - 2441.
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning [J]. Nature, 2015, 521(7553): 436 - 444.
- [13] Ding S Y, Lin L, Wang G R, et al. Deep feature learning with relative distance comparison for person re-identification [J]. Pattern Recognition, 2015, 48(10): 2993 - 3003.
- [14] Auger F, Flandrin P. Improving the readability of time-frequency and time-scale representations by the reassignment method [J]. IEEE Transactions on Signal Processing, 1995, 43(5): 1068 - 1089.
- [15] Shi W Z, Jiang F, Zhao D B. Single image super-resolution with dilated convolution based multi-scale information learning inception module [C]// Proceedings of IEEE International Conference on Image Processing (ICIP), 2017: 977 - 981.