

基于深度学习的雷达干扰识别方法研究

李东霞, 师亚辉

(北京遥测技术研究所 北京 100076)

摘要: 针对复杂电磁环境下雷达干扰信号识别问题, 从优化卷积神经网络结构的角度出发, 本文提出了一种对卷积神经网络结构 LeNet-5 增加批量归一化层和改变激活函数的方法。该方法能够加速网络收敛, 提升网络的学习效率。本文首先建立舰船目标模型, 分析了噪声调幅干扰、噪声调频干扰、梳状谱干扰和无干扰的真实目标回波信号在时频域的差异, 然后利用四种信号对舰船目标模型生成数据集, 最后通过本文所提方法实现雷达干扰的自动识别。仿真结果表明: 在全信噪比条件下, 本文所提方法对四种信号的识别准确率达到 98.1%, 表明所提方法有着较好的稳定性和鲁棒性。

关键词: 干扰识别; 卷积神经网络; 批量归一化

中图分类号: TN972 **文献标志码:** A **文章编号:** 2095-1000(2023)04-0102-07

DOI: 10.12347/j.ycyk.20230111002

引用格式: 李东霞, 师亚辉. 基于深度学习的雷达干扰识别方法研究[J]. 遥测遥控, 2023, 44(4): 102-108.

Research on radar jamming recognition method based on deep learning

LI Dongxia, SHI Yahui

(Beijing Research Institute of Telemetry, Beijing 100076, China)

Abstract: To solve the problem of radar jamming signal recognition in complex electromagnetic environment, from the perspective of optimizing the convolution neural network structure, this paper proposes a method to add a batch normalization layer and change the activation function to the convolution neural network structure LeNet-5. This method can accelerate the network convergence and improve the network learning efficiency. In this paper, the ship target model is first established, and the differences in time-frequency domain between noise amplitude modulation jamming, noise frequency modulation jamming, comb spectrum jamming and the real target echo signal without jamming are analyzed. Then the data sets are generated for the ship target model by using four kinds of signals. Finally, the automatic recognition of radar jamming is realized by the method proposed in this paper. The simulation results show that under the condition of full signal-to-noise ratio (SNR), the recognition accuracy of the proposed method for four signals reaches 98.1%, indicating that the proposed method has good stability and robustness.

Keywords: Interference recognition; Convolutional neural network; Batch normalization

Citation: LI Dongxia, SHI Yahui. Research on radar jamming recognition method based on deep learning[J]. Journal of Telemetry, Tracking and Command, 2023, 44(4): 102-108.

引 言

随着当前国际局势的变化, 蕴含着巨大能源的海洋资源归属权成为各国间竞争的目标之一。海洋舰队作为战场的主力, 雷达作为获取信息的关键, 在战场中发挥着举足轻重的作用。针对超大型舰船目标的雷达干扰识别在当代海战中具有重要意义。

近年来, 雷达干扰识别是非常热门的研究方向, 许多学者在此方面进行了大量研究工作。智能技术的发展为雷达干扰识别提供了广阔的空间, 深度学习在图像分类网络、目标检测和实例分割等应用场景, 都展现出优异的性能^[1]。文献[2]针对弹载雷达对干扰信号识别问题, 采用信道叠加增强干扰信号的识别特征, 以及多核数字信号处理芯片进行大量计算的方法, 但是人为选取的特征

基金项目: 国家自然科学基金(U1906217)

通信作者: 李东霞 (2636361054@qq.com)

收稿日期: 2023-01-11 修回日期: 2023-02-13

参数存在偶然性；文献[3]研究了干扰在多域的特征，分别在时域、频域、小波域对干扰特征进行分析，并将干扰特征的主成分作为标签支撑向量机进行训练及测试，但是以点目标对回波信号进行干扰识别研究。文献[4]研究了在网络结构中利用全局平均池化代替展平层方法，以减少网络参数和降低过拟合的风险，但只分析了-3 dB至8 dB八个信干噪比。

本文首先构建舰船模型，例如海面的较大型船只。当利用Ka波段高分辨雷达发射信号时，由于雷达的分辨单元远小于舰船目标的尺寸，因此，舰船目标回波为非单一波形，故在模拟雷达回波过程中不能将舰船目标视作点目标。然后，本文对噪声调幅干扰、噪声调频干扰、梳状谱干扰和无干扰的真实目标回波信号进行建模解析，并通过短时傅里叶变换(Short Time Fourier Translation, STFT)将时域信号变换到时频域，分析了干扰信号和真实目标回波信号的差异，然后通过本文所提方法完成了四种信号的自动识别。

1 舰船回波信号及干扰信号建模

1.1 舰船目标模型

对舰船目标建模，采用目标强散射点原理，即舰船目标的雷达回波信号是由目标的强散射点的雷达回波信号的矢量和组成。由舰船目标的具有特征意义的点构成船在三维坐标中的点图就是目标的强散射点模型^[5]。在三维坐标中的每个点即为散射点，每个点对应雷达位置有一个设定好的RCS(雷达散射截面)。目标散射点可根据实际物体进行描点，方法简单易实现，有效减少数据量，便于算法实现和验证。

根据目标强散射点理论，对目标进行描点得到的模型如下：

假定舰船目标的大小是：舰船目标的长度为330 m，舰船目标的宽度为30 m，飞行甲板最宽为75 m，舰船几何形状参照图1所示的航母模型图片。

根据舰船目标的大小和几何形状，描点并体现在三维坐标系中，表明舰船特征点的空间分布，分布结果如图2所示。由于强散射点主要分布在目标的边缘、末端和角，因此仿真中目标的几何轮廓是由强散射点形成的^[6]。航母上搭载的飞机、塔台、桅杆都是由散射点构成的，这为未来的算法



图1 舰船目标实景图像

Fig. 1 Real image of ship target

研究以及验证提供了基本条件。

由舰船目标描点得到的三维坐标矩阵为：

$$T = \begin{bmatrix} A_1 & x_1 & y_1 & z_1 \\ & \dots & & \\ A_i & x_i & y_i & z_i \\ & \dots & & \\ A_n & x_n & y_n & z_n \end{bmatrix} \quad (1)$$

其中， A_i 为第*i*个散射点的雷达截面积， (x_i, y_i, z_i) 为第*i*个散射点的空间坐标。




图2 舰船强散射点空间分布图像

Fig. 2 Spatial distribution image of ship strong scattering points

1.2 目标回波信号的模拟

线性调频信号(Linear Frequency Modulation signal, LFM)是指一定时间内频率连续线性变化的信号。线性调频信号通过调制载波频率，增加信号的传输带宽，宽脉冲下高距离分辨率是通过在接收端进行脉冲压缩实现的^[7]。LFM信号的时域表达式为：

$$S(t) = \text{rect}\left(\frac{t}{T_p}\right) \exp\left\{j2\pi\left(f_c t + \frac{K}{2} t^2\right)\right\} \quad (2)$$

其中， f_c 为信号载频， $K = B/T_p$ 为调频斜率， B 为调频带宽， T_p 为信号脉宽。

当目标为点目标时，雷达的回波信号即为LFM信号的时延信号，其表达式如下：

$$S_r(t) = S[t - \tau] = u\left(\frac{t - \tau}{T_p}\right) \exp\left\{j2\pi\left[f_c(t - \tau) + \frac{K}{2}(t - \tau)^2\right]\right\} \quad (3)$$

其中, $\tau(t) = \frac{2R(t)}{c}$ 为回波时延, $R(t)$ 为目标距离, c 是光速。

舰船目标某一位置的散射点的回波信号可以表示为:

$$S(x_i, y_i, z_i) = g(x_i, y_i, z_i) A(x_i, y_i, z_i) e^{j\phi_i} \quad (4)$$

式中, $g(x_i, y_i, z_i)$ 是天线波束增益, $A(x_i, y_i, z_i)$ 为散射点的后向散射系数; ϕ_i 为回波的相位, $\phi_i = 2\pi f_c(t - \tau_i) + K\pi(t - \tau_i)^2$ 。

舰船目标的回波信号可以定义为所有散射点回波信号的线性叠加, 可以表示为:

$$S(x_i, y_i, z_i) = \sum_{i=1}^N g(x_i, y_i, z_i) A(x_i, y_i, z_i) e^{j\phi_i} = \sum_{i=1}^N g(x_i, y_i, z_i) A(x_i, y_i, z_i) e^{j\left(2\pi f_c(t - \tau_i) + K\pi(t - \tau_i)^2\right)} \quad (5)$$

式(5)中 τ_i 为第 i 个散射点的回波时延, N 为散射点的个数。

利用图 2 得到的舰船模型的三维坐标和以上回波信号原理, 对舰船目标的回波信号进行仿真, 结果如图 3 所示。




图 3 舰船目标的回波信号图像

Fig.3 Echo signal image of ship target

1.3 雷达干扰信号机理和模型

1.3.1 调幅干扰

噪声调幅干扰的数学模型为:

$$J(t) = [U_0 + U_n(t)] \exp(\omega_0 + \phi) \quad (6)$$

其中, $U_n(t)$ 是均值为 0、方差为 σ^2 的高斯白噪声, U_0 是载波幅度, ω_0 为干扰信号的角频率, ϕ 在 $[0, 2\pi]$ 上服从均匀分布, 且和 $U_n(t)$ 是相互独立的

随机变量^[8]。

1.3.2 调频干扰

噪声调频干扰的数学模型为:

$$J(t) = U_0 \cos\left[\omega_0 t + 2\pi K_{FM} \int_0^t u(t') dt' + \phi\right] \quad (7)$$

其中, 调频噪声 $u(t)$ 是零均值的广义平稳随机过程, K_{FM} 是调频系数, 用于控制单位调制信号 B 强度引起的频率增减。

1.3.3 梳状谱干扰

梳状谱干扰主要是通过对截获的雷达信号和梳状谱信号进行乘积调制生成。梳状谱信号的表达式如下:

$$S_{\text{comb}}(t) = \sum_{i=1}^M a_i e^{j2\pi f_i t} \quad (8)$$

其中, f_i 对应每个梳齿出现的频率点, a_i 对应第 i 个频率点处的幅度^[9]。

梳状谱干扰的数学模型如下:

$$J(t) = s(t) \cdot S_{\text{comb}}(t) = \text{rect}\left(\frac{t}{T_p}\right) \sum_{i=1}^M a_i e^{j2\pi\left[f_c + f_i\right]t + \frac{K}{2}t^2} \quad (9)$$

其中, f_c 为信号载频, K 为调频斜率。

2 卷积神经网络的数据准备及结构优化

2.1 数据预处理

2.1.1 短时傅里叶变换

时频分析法是以 STFT 原理实现的。STFT 是傅里叶变换的一种拓展^[10]。傅里叶变换原理的表达式为:

$$F(\omega) = F(f(t)) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (10)$$

然后对 FT 做局部化处理, 其表达形式为:

$$f(t) g(t-u) \quad (11)$$

其中, $g(t-u)$ 表示傅里叶变换的时域部分的滑动窗口, u 表示滑动窗口的时间中心。当 $g(t-u)$ 低于某一阈值时, 其信号是平稳的。

设 $g(t)$ 是在时间轴上跨度极小的窗函数, 则短时傅里叶变换可以表示为:

$$F_{\text{STFT}}(t, f) = \int_{-\infty}^{\infty} [z(u) g^*(u-t)] e^{-2j\pi f u} du \quad (12)$$

由于雷达接收机接收的是数字信号, 所以需要对连续 STFT 进行离散化处理^[6]。设: 信号长度为 N 的离散序列为 $x(t)$, 其解析信号为 $z(n)$, 则 STFT 的数学表达如下:

$$F_{\text{STFT}}(n, k) = \sum_{m=-(N-1)/2}^{(N-1)/2} z(m) g \otimes (m-n) e^{-2j\pi m k} \quad (13)$$

2.1.2 回波信号的仿真图像

由图4可以看出,四种信号的时频图存在明显

差别,利用STFT做时频分析进行信号识别具有理论可能性。

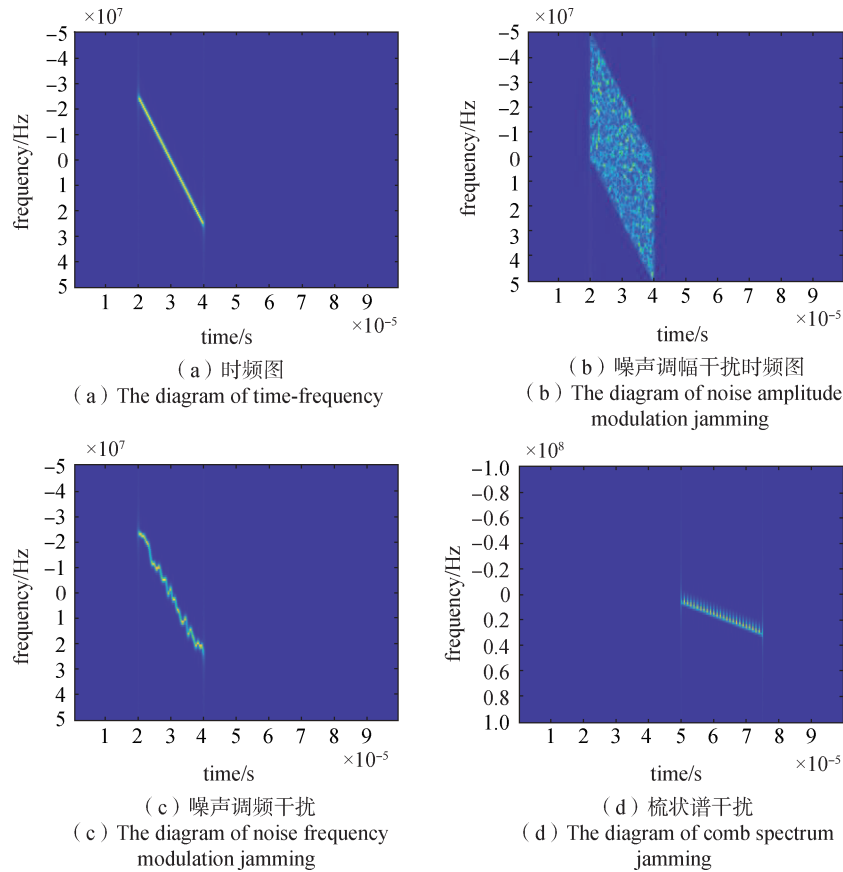


图4 四种信号的时频图

Fig. 4 Time-frequency diagram of four kinds of signals

2.2 生成数据集

本文设定的干扰识别任务分为噪声调幅干扰、噪声调频干扰、梳状谱干扰和无干扰的真实目标回波信号。卷积神经网络的训练过程需要大量的数据样本,但是雷达信号数据具有实际限制性,没有办法大量获取,所以考虑使用仿真数据来模拟复杂情况的雷达回波信号,并将其构建成满足神经网络学习的数据库。仿真参数如下:

干扰信号的中心频率为200 MHz,采样频率为2 000 MHz,带宽为300 MHz。干扰信号的附加噪声为高斯白噪声,将信噪比范围设定为-10~10 dB,等间隔选取信噪比值共11个,保证样本特征的前提下,简化样本复杂度。在每个信噪比下随机加入高斯白噪声,生成200个样本,最终生成4×200×11个样本。对数据集中的每个样本进行STFT变换,得到的时频图,形成一个干扰识别的数据集。随后,本文将数据集中70%的样本作为

训练集,30%的样本作为测试集,完成网络模型的训练和测试。对每个样本图像按照卷积神经网络输入层样本大小进行标准化处理,让每批的数据具有相同的分布,加速收敛。

2.3 卷积神经网络结构及优化方法

卷积神经网络(Convolutional Neural Network, CNN)提出利用共享参数的卷积运算可以提取图像中像素特征之间的相关性,卷积、降采样(池化)和非线性映射的使用是目前最常用的深度图像识别网络的基础^[1]。LeNet-5是比较经典的一个神经网络,它包含了深度学习卷积神经网络的基本模块:卷积层、池化层和全连接层。LeNet-5结构顺序依次由卷积层-池化层-卷积层-池化层-全连接层组成。其中下采样层和全连接层的核尺寸分别代表采样范围和连接矩阵的尺寸^[12]。CNN诞生很长一段时间以来,LeNet-5一直是CNN分类网络的标配结构,其中的卷积-池化层后通常接一个或多个全连

接层, 最后利用分类函数得到概率预测。表 1 为卷积神经网络结构模型。

卷积神经网络结构的具体细节并没有一个全面系统的设计理论, 需要通过人工经验不断调整尝试来进行完善。为了保障卷积神经网络的学习能高效准确, 卷积神经网络结构必须做到简洁以及拥有足够的学习能力。如果神经网络数据集样本图像 G , 其中图像的长、宽和深度为 L, W, H , 那么 CNN 的结构必须遵循以下基本准则^[13]:

① 在卷积过程中, L, W 逐渐变小, 输出的深度 H 逐层增加, 多数设计实例中 H 成倍增加。

② 卷积核越多可学习到越多的特征, 但其个数应保持在合理范围内。

③ 设置大的卷积核尺寸是基于局部图像的操作, 捕捉大尺寸的局部特征, 有利于特征学习。

根据以上原则, 在神经网络基础上加入增加归一化层和激活层。

批量归一化(Batch Normalization, BN)算法类似于一个输入层, 如卷积层、池化层和激活层。在提取数据特征的过程中, 每一层的参数都会随之更新, 如果上一层的参数更新后, 那么当前层的数据分布必然也会跟着变化, 如果变化很大, 那么必然会导致协变量偏移现象。神经网络中批量归一化的目的在于让数据的分布不产生较大的变化。在卷积层之后加入 BN 层, 这在很大程度上解决了数据输入的偏差和越来越大的影响^[14]。利用批量归一化层的优势如下:

① 加快训练速度, 可以提高学习效率, 即使是很小的学习率也可以有很快的学习效率;

② 经过每次训练归一化操作后, 避免了由数据不平均带来的参数变化过大, 减小了计算成本;

③ 在训练过程中, 能够通过打乱训练的数据集顺序, 防止发生数据偏移。

将 LeNet-5 模型中的 sigmoid 激活函数改成了更加简单且高效的 ReLU 激活函数。

① ReLU 激活函数中没有 sigmoid 激活函数的求幂运算, 计算更简单。

② ReLU 激活函数在不同的参数初始化方法下使模型更容易训练。这是由于当 sigmoid 激活函数输出极接近 0 或 1 时, 这些区域的梯度几乎为 0, 从而造成反向传播无法继续更新部分模型参数; 而 ReLU 激活函数在正区间的梯度恒为 1^[15]。因此, 若模型参数初始化不当, sigmoid 函数可能在正区间得到几乎

为 0 的梯度, 从而令模型无法得到有效训练。

表 1 卷积神经网络结构模型^[16]

Table 1 Parameters of convolutional neural network model^[16]

| Input: Image dimension | |
|-----------------------------------|-----------|
| Layer 1 | Conv. |
| Layer 2 | Batchnorm |
| Layer 3 | ReLU |
| Layer 4 | Max-Pool. |
| Layer 5 | Conv. |
| Layer 6 | Batchnorm |
| Layer 7 | ReLU |
| Layer 8 | Max-Pool. |
| Layer 9 | Conv. |
| Layer 10 | Batchnorm |
| Layer 11 | ReLU |
| Layer 12 | Fc |
| Layer 13 | Softmax |
| Output: Classification prediction | |




图 5 卷积神经网络优化后结构模型图

Fig.5 Structure model diagram of convolution neural network

图 5 是输入随着网络变化的过程, 可知输入 $128 \times 512 \times 1$ 的图象经过第一个卷积层输出 $128 \times 512 \times 8$ 的特征子图, 再通过池化层后前两维尺寸减半, 第二层卷积层使特征图谱增加到 16, 同样, 通过最后一个激活层后输出的维度为 $32 \times 108 \times 32$, 最后通过全连接层和 softmax 得到分类预测结果。

3 仿真结果

本文首先建立舰船目标模型和干扰信号模型, 以此生成雷达的回波信号, 利用 STFT 将得到的信号数据进行预处理得到信号的视频图像。建立卷积神经网络模型。将高斯白噪声随机加入到干扰信号中, 构建数据集。通过对卷积神经网络结构优化来对干扰信号进行识别, 提高干扰识别的准确度。

根据建模的干扰信号生成的数据集和构造的优化卷积神经网络结构,对算法进行了仿真验证。在全信噪比条件下,训练过程中的仿真结果如图6所示。

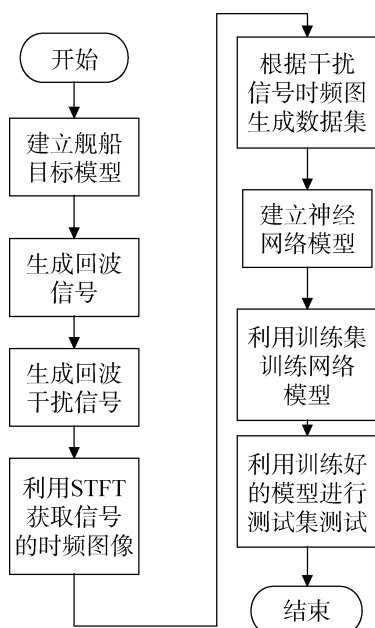


图6 仿真流程图^[17]


Fig.6 Simulation flow chart^[17]

从图7(a)处可得到,随着迭代次数的增多,网络的损失函数开始大斜率下降,在迭代次数到400次时,损失函数趋于0,表示网络学习过程拟合好,表明此时训练网络已接近稳定。图7(b)是训练过程中的准确率曲线。


将训练过程得到的网络结构参数,利用测试集测试,并画出卷积神经网络测试集的混淆矩阵,如图8所示。混淆矩阵是指每个信号的输出标签与信号的实际标签的比较,更直观地表征网络的精度^[8]。从图8可以看出,网络的识别率是98.1%。各干扰的识别率均在96%以上。

在神经网络数据库中,通过观察各种信噪比下的识别情况,可以了解卷积神经网络干扰识别算法随信噪比(Signal to Noise Ratio, SNR)变换的关系,结果如图9所示:

图9表示了在-10~10 dB的SNR下的神经网络识别率,当为-10~-6 dB时,神经网络的识别率经过一段快速的上升变化后,快速上升的趋势逐渐缓慢,识别率在SNR等于0 dB附近时识别率约为100%。而SNR大于0 dB时,神经网络的识别率无



(a) 训练过程中的损失函数曲线
(a) Loss curve of training process



(b) 训练过程中的准确率曲线
(b) Accuracy rate of training process

图7 卷积神经网络训练结果

Fig. 7 Training results of convolutional neural network

限接近100%。

4 结束语

本文提出了一种基于舰船目标的卷积神经网络优化方法,该方法利用批量归一化解决了数据输入的偏差以及通过改变激活函数简化计算量。在不同干燥比下对识别率进行分析。仿真结果显示,优化后的神经网络具有很高的识别效果,准确率能够达到96%以上,且信噪比在-10~0 dB时,信噪比越高神经网络的识别率越高,当信噪比达到0 dB以上时,神经网络的识别率基本接近100%。对比传统识别方法,降低了人工提取特征等主观因素带来的影响,雷达干扰识别率大幅提升。但卷积神经网络识别运算量大,不利工程应用。怎样获得

混淆矩阵

| | | | | | | |
|--------------|---|--------------|---------------|---------------|--------------|---------------|
| output class | 1 | 634 24.0% | 25 0.9% | 0 0.0% | 0 0.0% | 96.2% 3.8% |
| | 2 | 26 1.0% | 635 24.1% | 0 0.0% | 0 0.0% | 96.1% 3.9% |
| | 3 | 0 0.0% | 0 0.0% | 660 25.0% | 0 0.0% | 100% 0.0% |
| | 4 | 0 0.0% | 0 0.0% | 0 0.0% | 660 25.0% | 100% 0.0% |
| | | | 96.1% 3.9% | 96.2% 3.8% | 100% 0.0% | 100% 0.0% |
| | | 1 | 2 | 3 | 4 | |
| | | target class | | | | |

图 8 卷积神经网络测试集混淆矩阵结果
Fig. 8 Confusion matrix results of convolution neural network test set




图 9 测试集识别率随 SNR 变化

Fig. 9 Recognition rate of test set changes with SNR

最有效的特性参数值得深入探索, 对雷达有源干扰信号的认识不能停滞于基础理论问题, 必须通过工程化来解决雷达抗干扰能力问题。

参考文献

[1] 乔腾飞, 张超, 熊建林, 等. 基于深度学习的目标检测框架组件研究[J]. 遥测遥控, 2022, 43(6): 108-116.
QIAO Tengfei, ZHANG Chao, XIONG Jianlin, et al. Research components of object detection framework based on deep learning[J]. Journal of Telemetry, Tracking and Command, 2022, 43(6): 108-116.

[2] 郑苡榕. 雷达有源干扰识别方法及高效实现[D]. 成都: 电子科技大学, 2019.

[3] 刘慧敏. 基于深度学习的有源欺骗干扰特征级识别方

法研究[D]. 西安: 西安电子科技大学, 2019.

[4] 刘强. 基于深度学习的雷达干扰识别技术[D]. 成都: 电子科技大学, 2020.

[5] 栾丹. 反舰末制导雷达回波建模与信号处理算法研究[D]. 西安: 西安电子科技大学, 2009.

[6] 吴莹. 雷达辐射源指纹特征提取和识别技术研究[D]. 西安: 西安电子科技大学, 2018.

[7] 于濛. 基于深度学习的雷达信号识别技术研究[D]. 西安: 西安电子科技大学, 2020.

[8] 郭治锐, 鲁军, 刘磊, 等. 基于 Alexnet 的雷达干扰识别方法研究[J]. 电光与控制, 2021, 28(9): 49-53.
GUO Zhirui, LU Jun, LIU Lei, et al. Research on radar interference recognition method based on AlexNet[J]. Electronics Optics & Control, 2021, 28(9): 49-53.

[9] 陈秋菊, 杜小勇, 胡卫东, 等. 面向识别的雷达舰船目标低分辨回波仿真技术[J]. 计算机仿真, 2007, 24(7): 13-17.

[10] WANG Y, SUN B, WANG N. Recognition of radar active-jamming through convolutional neural networks [J]. The Journal of Engineering, 2019(21): 7695-7697.

[11] YU J, LI J, SUN B, et al. Barrage jamming detection and classification based on convolutional neural network for synthetic aperture radar[C]//IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium, 2018: 3281-3284.

[12] CHEN J, XU S, ZOU J, et al. Interrupted-sampling repeater jamming suppression based on stacked bidirectional gated recurrent uni tnetworkand infinite training [J]. IEEE Access, 2019, 7: 107428-107437.

[13] 卫南. 对反舰雷达导引头的干扰技术研究[D]. 西安: 西安电子科技大学, 2020.

[14] 邵广庆. 基于深度学习的雷达干扰信号识别方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.

[15] SCHLEHER D Curtis. Electronic war fare in the information Age[M]. Artech House, Boston, London, 1999.

[16] 孙嘉. 浅谈军用雷达发展及在现代战争中作用[J]. 军民两用技术与产品, 2016(20): 279.

[17] 刘斌杰. 浅谈军用雷达发展及在现代战争中作用[J]. 军民两用技术与产品, 2018(4): 190.

[作者简介]

李东霞 1996 年生, 硕士研究生, 主要研究方向为雷达信号处理。

师亚辉 1977 年生, 硕士, 研究员, 主要研究方向为雷达信号处理。

(本文编辑: 潘三英)