

基于深层神经网络的雷达波形设计

赵俊龙, 李伟, 王泓霖, 邹鲲

(空军工程大学信息与导航学院, 西安, 710077)

摘要 针对雷达波形多准则优化目标函数难以建立的问题,降低目标响应的不确定性,提高雷达检测性能,提出了一种基于深层神经网络的雷达波形设计方法。首先,根据雷达回波数据形式进行深层神经网络(DNNs)结构设计;然后,将基于信噪比(SNR)和互信息(MI)准则产生的信号随机混合并与其对应的环境信息组成训练集,对DNNs训练;最后将另一部分基于互信息准则产生的信号与其对应的环境信息作为测试集,利用DNNs生成信号并进行测试。实验结果表明,使用该方法产生的信号作为雷达发射波形与仅基于MI准则产生的信号作为雷达发射波形相比,雷达回波与目标的互信息量最大提高了21.37 nat,雷达接收信号的信干噪比最大提高了1.35 dB。与线性调频信号相比,相应的互信息量最大提高了950.76 nat,相应的信干噪比最大提高了18.23 dB。

关键词 波形设计;互信息准则;信噪比准则;神经网络

DOI 10.3969/j.issn.1009-3516.2020.01.009

中图分类号 TN957.3 **文献标志码** A **文章编号** 1009-3516(2020)01-0052-06

A Waveform Design of Radar Based on Deep Neural Networks

ZHAO Junlong, LI Wei, WANG Honglin, ZOU Kun

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract Aimed at the problems that the radar waveform multi-criteria optimization target function is difficult to establish, and in order to reduce the uncertainty of target response and to improve the radar detection performance, a radar waveform design method based on deep neural network is proposed. First, deep neural networks (DNNs) are designed according to the radar echo data. Then, the signals generated based on the Signal-to-Noise Ratio (SNR) and the Mutual Information (MI) criteria are randomly mixed, and the corresponding environmental information is used to form a training set, and the DNNs are trained. Finally, taking another part of the signals generated based on the mutual information criterion and its corresponding environmental information as test sets, this paper utilizes the DNNs for generating signals and testing. The experimental results show that if the signals generated by the method taken as a radar emission waveform compares to the signals generated based on the MI criterion alone taken as a radar transmission waveform, the mutual information of the radar echo and the target is increased by 21.37 nat, and the signals of the radar receiving signals are improved. The noise ratio is increased by a maximum of 1.35 dB. Compared with the chirp signals, the corresponding mutual information is increased by 950.76 nat, and the

收稿日期: 2019-07-13

基金项目: 国家自然科学基金(61571456);航空科学基金(20160196001)

作者简介: 赵俊龙(1995—),男,安徽阜阳人,硕士生,主要从事雷达波形设计和深度学习研究。E-mail:jlzhao0826@163.com

通信作者: 李伟(1978—),男,山东济宁人,副教授,主要从事新体制雷达研究。E-mail:liweichangsha@163.com

引用格式: 赵俊龙,李伟,王泓霖,等. 基于深层神经网络的雷达波形设计[J]. 空军工程大学学报(自然科学版), 2020, 21(1): 52-57. ZHAO Junlong, LI Wei, WANG Honglin, et al. A Waveform Design of Radar Based on Deep Neural Networks[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(1): 52-57.

corresponding signal-to-noise ratio is increased by 18.23 dB.

Key words waveform design; mutual information criterion; signal to noise ratio criterion; neural network

雷达是现代战争不可或缺的探测工具,历次战争都证明具有良好目标探测与识别能力的雷达对战争态势的塑造具有决定性作用。雷达通过接收和处理目标反射的电磁波来获取目标信息,其发射波形关系到反射波中包含信息的多少,因此,发射波形对雷达性能有重要影响。雷达波形设计方法多种多样,其中,SNR准则和MI准则是雷达波形设计中常用的两种设计准则。Pillai^[1]首次提出最大化雷达接收信号的信噪比来设计波形,提高了雷达目标检测能力,但其产生的波形往往将能量聚集在雷达工作频带的某一频段,减缩了雷达正常工作带宽,降低雷达分辨率^[2]。Bell^[3]提出最大化回波信号与目标冲激响应间的互信息量来设计波形,降低了目标响应不确定性,然而该方法将更多的能量置于互信息量更高的频点,制约了雷达其他性能。Romero^[4]针对确定目标和随机目标分别采用SNR与MI准则设计波形,并推导出两准则之间关系。胡旭^[5]提出了一种联合准则,通过最大化信噪比与互信息之间的差异来设计波形。在此基础上,本文基于多准则联合优化思想,联合SNR与MI准则设计波形。

近年来深度学习成为研究热门,其可有效提取数据高维特征,在图像处理、语音识别、机器翻译、自动驾驶^[6]等领域帮助人类取得了前所未有的成就,同时在雷达领域也得到了广泛应用^[7-9],例如基于深度学习的SAR图像目标检测^[10]和识别^[11],基于深度学习的SAR地物分离以及深度学习在多普勒雷达身体姿态感知中的应用^[12]。然而深度学习目前在雷达领域主要应用于雷达目标识别,并未涉及雷达波形设计。

雷达根据任务类型选择不同波形设计准则,进行参数估计时常用MI准则,针对目标检测则常用SNR准则^[13]。基于上述单一准则的波形设计方法,会在提高某个指标的同时影响其他指标,无法兼顾检测性能和参数估计性能;如果联合2个准则,则面临目标函数难于建立的问题。而DNNs具有极强数据内在规律学习能力,可将不同数据的内在规律提取、综合,达到数据特征融合的目的。利用DNNs对复杂数据规律的学习能力,将SNR与MI准则生成信号的内在规律进行提取、融合,兼顾两种准则信号产生方式,进而达到联合目的。

基于上述联合思想及DNNs对数据内在规律的学习能力,本文提出一种基于深层神经网络的雷达波形设计方法,利用DNNs将SNR和MI准则联

合起来设计波形。首先设定环境变量,根据SNR与MI准则分别进行波形设计,产生相应数据;其次将SNR与MI准则生成信号进行混合且与其对应的环境变量共同组成训练集,并对DNNs进行训练;最后将另一部分由MI准则产生数据与其对应环境信息一起构成测试集,进行测试。

1 雷达信号模型与深层神经网络基本原理

1.1 雷达信号模型

信号模型见图1所示,设 $x(t)$ 为雷达发射信号, $n(t)$ 为雷达接收机噪声,目标冲激响应 $h(t)$ 为定义在区间 $[0, T_h]$ 中的一个随机过程, $c(t)$ 为信号杂波冲激响应, $y(t)$ 是雷达接收机接收信号, $f(t)$ 为理想低通滤波器的系统响应。 $x(t)$ 的傅里叶变换为 $X(f)$, $n(t)$ 的功率谱密度为 $S_{nn}(f)$,且 $h(t)$ 的傅里叶变换为 $H(f)$, $c(t)$ 的功率谱密度为 $S_{cc}(f)$ 。由图1可知:

$$y(t) = f(t)[x(t)h(t) + x(t)c(t) + n(t)] \quad (1)$$

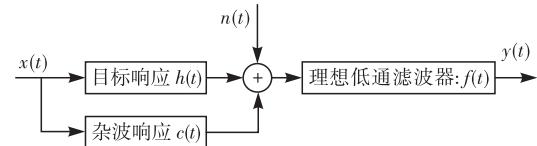


图1 随机扩展目标信号模型

雷达波形设计中常用两种设计准则^[4],即MI准则和SNR准则:

$$\text{SINR} \simeq \int_w^y \frac{\sigma_H^2(f) |X(f)|^2}{S_{cc}(f) |X(f)|^2 + S_{nn}(f)} df \quad (2)$$

$$\text{MI} = I(y(t); h(t) | x(t)) = \int_w^y \ln \left[1 + \frac{\sigma_H^2(f) |X(f)|^2}{S_{cc}(f) |X(f)|^2 + S_{nn}(f)} \right] df \quad (3)$$

SINR为雷达接收信号的信干噪比,MI为发射波形确定时,雷达接收回波与目标冲激响应之间的互信息量。其中 σ_H^2 是 $H(f)$ 的平均能量谱方差(Energy Spectral Variance, ESV),W为雷达工作频带, T_y 为卷积输出持续时间。式(2)与式(3)中被积函数为凹函数,二者均受到能量限制,应用拉格朗日乘子法可解出最优发射信号,求解最优波形的过程分别称为信噪比法和互信息量法。

1.1.1 SNR准则

SNR准则通过最大化雷达接收信号的信噪比设计信号,引入干扰,在此为最大化信干噪比。式

(2) 中被积函数为凹函数, 能量限制 $\int_w |X(f)|^2 df \leq E_x$ 为其约束条件, 利用拉格朗日乘子法可解出最优波形。根据文献[4]计算得:

$$|X(f)|^2 = \max[0, B(f)(A - D(f))] \quad (4)$$

式中: $B(f)$ 和 $D(f)$ 分别为:

$$B(f) = \frac{\sqrt{\sigma_H^2 S_m(f)}}{S_{\alpha}(f)} \quad (5)$$

$$D(f) = \sqrt{\frac{S_m(f)}{\sigma_H^2}} \quad (6)$$

A 是由发射波形能量限制 $\int_w \max[0, B(f)(A - D(f))] df \leq E_x$ 决定的常数。

1.1.2 MI 准则

给定发射波形 $x(t)$, MI 准则通过最大化目标响应 $h(t)$ 与接收信号 $y(t)$ 之间的互信息量 $I(y(t); h(t)|x(t))$ 设计信号。式(3)被积函数为凹函数, 且约束条件为 $\int_w |X(f)|^2 df \leq E_x$, 使用拉格朗日乘子法可得发射信号频谱。根据文献[4]计算得:

$$|X(f)|^2 =$$

$$\max[0, -R(f) \sqrt{R(f)^2 + S(f)(A - D(f))}] \quad (7)$$

式中:

$$D(f) = \frac{S_m(f)}{\alpha \gamma_H(f)} \quad (8)$$

$$R(f) = \frac{S_m(f)(2S_m(f) + \alpha \gamma_H(f))}{2S_{\alpha}(f)(S_m(f) + \alpha \gamma_H(f))} \quad (9)$$

$$S(f) = \frac{S_m(f)\alpha \gamma_H(f)}{S_{\alpha}(f)(S_{\alpha}(f) + \alpha \gamma_H(f))} \quad (10)$$

A 是由发射波形能量限制 $\int_w \max[0, -R(f) \cdot \sqrt{R(f)^2 + S(f)(A - D(f))}] df \leq E_x$ 决定的常数。

1.2 深层神经网络基本原理

早在 20 世纪 40 年代, 心理学家 McCulloch 和数理逻辑学家 Pitts 就提出了一种 MP 神经网络模型, 该模型实际上只是单个神经元的数学描述, 开启了神经网络研究的大门。2006 年, Hinton 提出了深度置信网络以及快速学习算法, 拉开深度学习大幕。随着近年来在大量数据驱动下, 神经网络已经发展出诸多变体, 学术界迎来了研究神经网络的热潮。

神经元是由输入、输出以及计算单元组成的自适应非线性模型, 人工神经网络(Artificial Neural Network, ANN)由众多神经元组成, 具有刻画输入数据与对应输出数据之间复杂非线性关系的能力^[14]。一般具有输入层、隐藏层、输出层 3 层结构,

每层输出端设置相应激活函数, 层与层之间具有相应权值。数据由输入层进入神经网络, 神经网络中每个神经元将其接收到的数据进行叠加, 并将其与该神经元对应偏置之和经由激活函数处理后输出。经过网络中所有神经元的处理之后可得神经网络的输出。理论上, 只要隐藏层神经元数量足够多, 单隐层神经网络便可以无限逼近任何函数^[15]。然而, 为提高网络对数据特征的刻画能力, 通常增加隐藏层的数量, 这样就得到了 DNNs, 其结构见图 2。

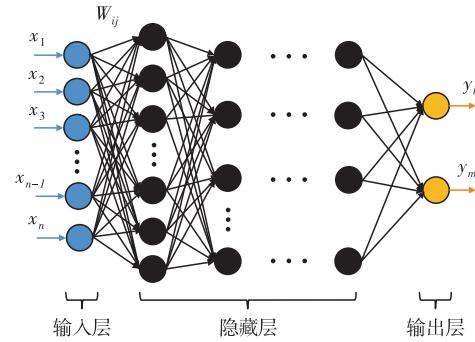


图 2 深层神经网络

DNNs 在 ANN 基础上增加隐藏层以及每层神经元数量, 隐藏层与神经元数量更多的 DNNs 可以学习数据更深层的特征, 完成更复杂的任务^[16-17]。设神经网络的输入和输出为 $D = \{(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(n)}, y^{(n)})\}$, 其中 $x^{(i)}$ 为神经网络输入向量, $y^{(i)}$ 为神经网络预测时希望得到的向量。若第 m 层隐藏层具有 N 个神经元, 输出向量为 $\{a_1^m, a_2^m, \dots, a_N^m\}$, 则第 $m+1$ 隐藏层的第 j 个神经元输出为:

$$a_j^{m+1} = f \left(\sum_{i=1}^N W_{ji}^{m+1} a_i^m + b_j^{m+1} \right) \quad (11)$$

式中: f 为非线性激活函数; W_{ji}^{m+1} 为第 $m+1$ 层隐藏层的权重; b_j^{m+1} 为第 $m+1$ 层隐藏层的偏置。每层神经网络对其接收到的数据进行如上计算, 并将数据输出到下一层网络, 依此计算, 便可得到整个神经网络的输出。

2 基于 DNNs 的雷达波形设计

2.1 训练与测试过程

使用 DNNs 设计雷达波形, 即利用 DNNs 高效学习能力, 对环境信息与该环境下经 MI 准则和 SNR 准则生成的最优波形之间非线性映射关系进行学习, 调整 DNNs 自身权值参数, 使 DNNs 权值兼具 MI 准则和 SNR 准则特性, 避免建立联合优化目标函数, 达到联合 MI 和 SNR 准则自适应生成最优波形的目的。由基于 MI 准则和 SNR 准则的波形设计过程可知, 若已知环境中目标、杂波、噪声、干

扰等信息,可使用相关准则来设计最优波形。利用神经网络进行波形设计,神经网络生成信号的影响因素同样为环境中目标、杂波、噪声、干扰等4个因素。在实验中,通常将噪声设置为白噪声,干扰的功率谱密度为高斯分布,故可将噪声与干扰合并。综上,神经网络生成信号的影响因素为环境中目标、杂波、噪声与干扰之和等3个因素。

本文方法分为训练阶段和测试阶段,见图3~4。

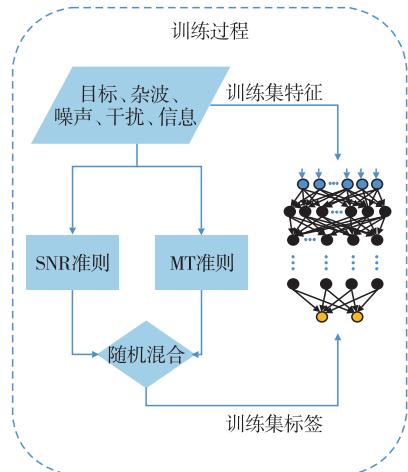


图3 训练流程图

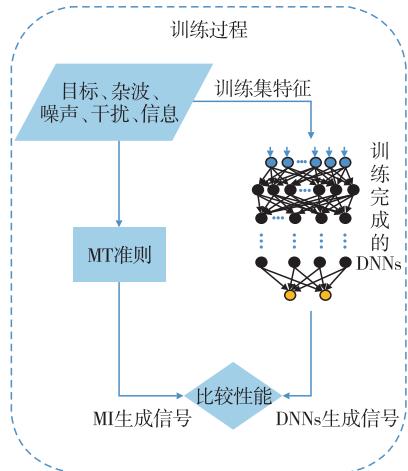


图4 测试过程

图3为训练流程图,该过程中,环境变量均为假设,首先对目标能量谱方差、杂波功率谱密度、噪声与干扰之和的功率谱密度等3个变量进行假设取值,这3个变量的取值组成训练集特征。然后根据MI准则和SNR准则来生成相应最优发射信号,将2种准则产生的波形进行混合并与其所对应的环境信息组成训练集。之后使用训练集对DNNs进行训练,使得DNNs同时具有MI准则和SNR准则特性,达到2种准则融合的目的。该过程中,DNNs输入层输入为目标能量谱方差、杂波功率谱密度、噪声与干扰之和的功率谱密度等3个变量的频域采样构

成的序列,而输出层希望得到的序列为不同准则生成波形的频域采样。

图4为测试流程图,经训练阶段得到训练完成的DNNs,测试过程目的在于检测本文方法有效性。为确保训练集与测试集之间差异,测试过程中环境信息取值与训练流程中不同。将同一组环境信息分别经由MI准则和训练完成的DNNs来产生相应发射信号,将两者生成信号分别作为雷达发射波形时,对比目标响应与回波之间的互信息量。该过程中,DNNs输入层输入为目标能量谱方差、杂波功率谱密度、噪声与干扰之和的功率谱密度等3个变量的频域采样构成的序列,输出层输出为训练完成的DNNs生成信号的频域采样序列。对比数据为MI准则产生的信号,并与线性调频信号也进行了对比。

2.2 神经网络参数设计

DNNs的层数以及各层神经元数量决定了其学习能力。一般来说,层数越多,每层神经元数量越多,网络学习能力越强。但在实验中,选取过多层数以及每层过多神经元数量会造成网络的过拟合,导致其在训练集上表现突出,而在测试集上表现不佳。故对网络层数以及每层神经元的选择至关重要,不可过多或过少。本文采用数据是在杂波响应、噪声与干扰之和、目标响应、发射波形等4个变量频谱上采样500点得到的,其中前3个变量的1500个采样点作为DNNs输入数据,发射波形的500个采样点为网络希望预测的数据。故本文神经网络输入层神经元数量为1500,输出层神经元数量为500。根据文献[7]神经网络设计经验,本文设计的DNNs模型具有5层神经元,其中有3层隐藏层。每层所对应神经元数量分别为:1500,3000,1500,750,500。输入层1500个神经元对应输入的1500点数据,而输出层500个神经元对应输出的500点数据。

激活函数为神经网络提供处理非线性问题的能力,决定了网络收敛速度与精度。常见激活函数有ReLU函数、sigmoid函数、LeakyReLU函数以及双曲正切(tanh)函数。本文采用tanh函数,由于本文是回归过程,故在网络输出层不使用激活函数。式(12)给出了tanh函数的数学表达式:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (12)$$

对于损失函数,本文采用均方误差损失,每个输入向量 $x^{(i)}$,设网络预测的输出向量为 $y^{(i)}$,损失函数为:

$$\text{loss} = \frac{1}{n} \sum_{i=1}^n (y^{(i)} - \hat{y}^{(i)})^2 \quad (13)$$

通过优化器将损失函数最小化,即把实际输出

与预测输出之间的差距减小以提高预测精度。为提高运算速度,本文使用小批梯度下降法。其中学习率 $\alpha=0.1$,最小批数 batch_size=100,迭代次数为 10 000 次。

3 实验仿真

3.1 数据准备

假设雷达中心频率 $f_c = 10 \text{ GHz}$,带宽 $W = 10 \text{ MHz}$,发射信号时宽 $T = 25 \text{ ms}$,功率 $P_x = 1000 \text{ W}$,其工作频段为 $[9.995 \text{ GHz}, 10.005 \text{ GHz}]$,采样频率 $f_s = 2 \text{ W} = 20 \text{ MHz}$,工作频带内采样点为 500。实验中,设定 4 000 组不同杂波以及噪声干扰条件,利用 SNR 准则和 MI 准则分别产生 4 000 组发射波形。为使数据符合雷达实际工作环境,本文采用杂波响应谱方差为目标响应谱方差 10 倍。对于 $i \in [1, 4000]$,假设目标响应能量谱方差 $\sigma_g^2(f) = iB(\exp(-\alpha(f-f_c)^2))$;杂波能量谱方差 $\sigma_c^2(f) = i10B(\exp(-0.8\alpha(f-f_{c2})^2))$;干扰功率谱密度 $P_j(f) = 0.001B\exp(-\alpha(f-f_{c3})^2)$;其中 $f_{c2} = f_c + W - 500i$ 为杂波中频, $f_{c3} = f_c - W + 500i$ 为干扰中频, B 是由目标雷达反射面积决定的常数,这里取 $B = 7.9577 \times 10^{-16}$, α 表示谱方差随频率变化率,取 $\alpha = 1 \times 10^{-13}$ 。设高斯白噪声由雷达所处环境温度决定,取 $T = 300 \text{ K}$,则噪声功率谱密度 $P_n(f) = kT = 4.1430 \times 10^{-21} \text{ J}$,其中 $k = 1.3806 \times 10^{-23} \text{ J/K}$ 为玻尔兹曼常量。

每组环境中,目标能量谱方差 $\sigma_g^2(f)$,杂波的能量谱方差 $\sigma_c^2(f)$,干扰的功率谱密度 $P_j(f)$ 与噪声的功率谱密度 $P_n(f)$ 之和 $P_j(f) + P_n(f)$,以及生成波形 $X(f)$ 等 4 个变量构成一组样本,故 2 种准则分别有 4 000 组样本,随机在 2 种准则信号中各抽取 3 000 组样本混合组成包含 6 000 组样本的训练集。并将剩下 1 000 组由 MI 准则产生的信号样本作为测试集。

3.2 实验结果

将 3.1 节中生成的 6 000 组训练数据送入 DNNs 进行训练,之后将测试集 1 000 组数据送入训练完成的 DNNs 得到神经网络输出,进而可得当发射信号为 DNNs 生成信号、MI 准则生成信号和线性调频信号时,雷达回波与目标之间的互信息量,见图 5。

从图 5 可以看出,DNNs 生成信号对应的互信息量要高于 MI 准则生成波形所对应的互信息量,且两者要远高于线性调频信号所对应的互信息量。与仅基于 MI 准则产生的信号相比,采用本文方法

生成的信号作为发射波形时,雷达回波与目标的互信息量最大提高了 21.37 nat,与线性调频信号相比提高了 950.76 nat,由文献[13]知,相应互信息量的提升降低了目标响应不确定性。

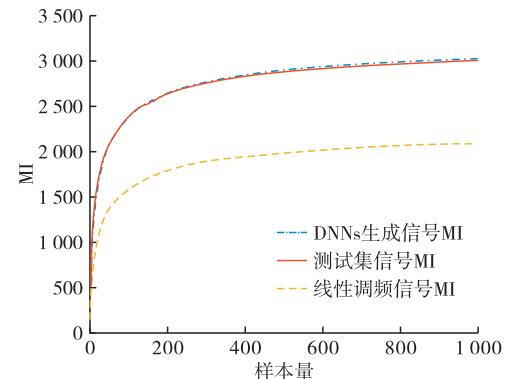


图 5 DNNs 产生信号的 MI 对比图

得到 DNNs 生成信号后,由式(3)可得接收机信号的 SINR,经过 $10\log(\text{SINR})$ 处理后,可得 DNNs 产生信号与 MI 准则生成信号以及线性调频信号的 SINR 对比图,见图 6。图 6 中 SINR 曲线的分布规律与图 5 中 MI 曲线大致相同,这是由 SINR 的表达式(3)与 MI 的表达式(4)之间的相似性来决定的,经过 $10\log(\text{SINR})$ 处理,SINR 的曲线趋于紧凑,使得 SINR 曲线与 MI 曲线大致趋势相似。由图 6 可知,采用本文方法生成的信号,相较于 MI 准则生成的信号所对应的 SINR 最大提高了 1.35 dB,而相较于线性调频信号最大提高了 18.23 dB,由文献[3]可知,信干噪比的提升提高了目标的检测性能。

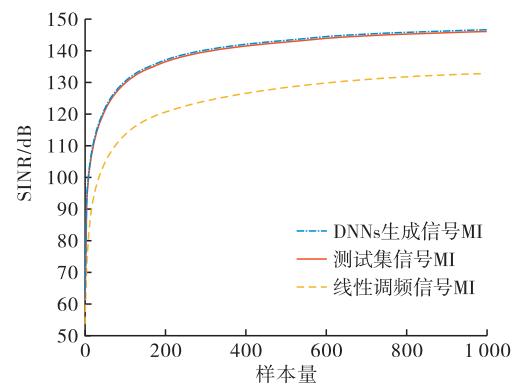


图 6 DNNs 产生信号的 SINR 对比图

由图 5 和图 6 可知,利用 DNNs 生成的信号无论是在 MI 还是 SINR 指标上都有所进步,这是因为 DNNs 综合了 MI 和 SINR 2 种准则,结合了 SINR 准则分配更多能量在使 SINR 最大化的频点上的特点与 MI 准则分配能量在利于信息提取频点上的特点,优化发射波形能量分配,提高了雷达回波与目标之间的互信息量,降低了目标响应的不确定性,且提

高了 SINR 指标,改善了雷达检测性能。

4 结语

针对雷达波形设计多准则联合优化问题,本文提出基于 SNR 准则与 MI 准则的 DNNs 的雷达波形设计方法。通过 DNNs 学习数据内在规律的能力,将 SNR 准则与 MI 准则分别产生的数据联合起来训练 DNNs 模型,使得 DNNs 模型兼顾 SNR 准则与 MI 准则的特征,且实验结果表明,相较于 MI 准则,采用本文方法产生的信号与目标响应之间的互信息量与接收信号的信干噪比更高,降低了目标响应的不确定性,提高了雷达的检测性能,为雷达波形设计提供了一个新思路。

参考文献

- [1] PILLAI S U, OH H S, YOULA D C, et al. Optimal Transmit-Receiver Design in the Presence of Signal-Dependent Interference and Channel Noise[J]. IEEE Transactions on Information Theory, 2000, 46(2): 577-584.
- [2] 纠博,刘宏伟,李丽亚,等.一种基于互信息的波形优化设计方法[J].西安电子科技大学学报,2008,35(4):678-684.
- [3] BELL M R. Information Theory Andradar Waveform Design[J]. IEEE Transactions on Information Theory, 1993, 39(5): 1578-1597.
- [4] ROMEROR, BAE J, GOODMAN N. Theory and Application of SNR and Mutual Information Matched Illumination Waveforms[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(2): 912-927.
- [5] 胡旭,贾鑫,秦乙.一种新的认知雷达波形优化方法[J].电子信息对抗技术,2014,29(1):33-37.
- [6] 毛健,赵红东,姚婧婧.人工神经网络的发展及应用[J].电子设计工程,2011(24):62-65.
- [7] YE H, LI G Y, JUANG B H F. Power of Deep Learning for Channel Estimation and Signal Detection in OFDM Systems[J]. IEEE Wireless Communications Letters, 2017, 7(1): 114-117.
- [8] OSHEA T, HOVDIS J. An Introduction to Deep Learning for the Physical Layer[J]. IEEE Transactions on Cognitive Communications & Networking, 2017, 3(4): 563-575.
- [9] 王俊,郑彤,雷鹏,等.深度学习在雷达中的研究综述[J].雷达学报,2018,7(4):5-21.
- [10] 徐丰,王海鹏,金亚秋.深度学习在 SAR 目标识别与地物分类中的应用[J].雷达学报,2017,6(2):136-148.
- [11] WANG H, CHEN S, XU F, et al. Application of Deep-Learning Algorithms to MSTAR Data[C]// IGARSS 2015 IEEE International Geoscience and Remote Sensing Symposium. [S. l.] IEEE, 2015: 3743-3749.
- [12] 苏宁远,陈小龙,关键,等.基于卷积神经网络的海上微动目标检测与分类方法[J].雷达学报,2018,7(5):39-48.
- [13] 王璐璐,王宏强,王满喜,等.雷达目标检测的最优波形设计综述[J].雷达学报,2016,5(5): 487-498.
- [14] 秦楚雄,张连海.基于 DNN 的低资源语音识别特征提取技术[J].自动化学报,2017,43(7):1208-1219.
- [15] LECUN Y, BENGIO Y, HINTON G. Deep Learning [J]. Nature, 2015, 521(7553): 436-444.
- [16] 何琬,刘进,朱肖晶.基于深层神经网络的电力负荷预测[J].环境与可持续发展,2016(1):83-87.
- [17] 高莹莹,朱维彬.深层神经网络中间层可视化建模[J].自动化学报,2015,41(9):1627-1637.

(编辑:徐敏)