

杂波条件下利用一维卷积神经网络的 认知雷达波形设计

赵俊龙, 李伟, 甘奕夫, 邹鲲

(西安空军工程大学信息与导航学院, 710077, 西安)

摘要: 针对单准则设计的波形难以满足雷达多状态和多任务的问题,提出了一种杂波条件下利用一维卷积神经网络的认知雷达波形设计(CRWD-1D-CNN)方法。首先,设定环境变量,并根据互信息准则和信干噪比准则来构建训练集和测试集;其次,根据数据集的一维数据形式和采样点数,设计一个包含3个卷积层、2个全连接层的1D-CNN模型;最后,使用训练集对1D-CNN模型进行训练,利用1D-CNN对一维数据之间非线性关系的学习能力来学习互信息准则和信干噪比准则,然后,使用训练后的1D-CNN生成波形。为衡量雷达综合性能,提出了一种目标最终识别率指标。实验结果表明,采用CRWD-1D-CNN方法设计的波形作为雷达发射信号时,与使用互信息准则生成的波形相比,雷达综合性能平均提升0.64%,与使用信干噪比准则生成的波形相比平均提升2.13%,证明了CRWD-1D-CNN方法可联合互信息准则和信干噪比准则,提高雷达综合性能。

关键词: 波形设计;互信息准则;信干噪比准则;一维卷积神经网络

中图分类号: TN951 **文献标志码:** A

DOI: 10.7652/xjtuxb202104008 **文章编号:** 0253-987X(2021)04-0069-08



OSID 码

A Design Method of Cognitive Radar Waveform Using One-Dimensional Convolutional Neural Network in the Presence of Clutter

ZHAO Junlong, LI Wei, GAN Yifu, ZOU Kun

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

Abstract: A design method of cognitive radar waveform (CRWD-1D-CNN) using one-dimensional convolutional neural network (1D-CNN) in the presence of clutter is proposed to solve the problem that the waveform designed using single-criterion is difficult to satisfy the radar multi-state and multi-task. Firstly, environment variables are set, and a training set and a test set are constructed according to the mutual information (MI) criterion and the signal-to-interference and noise ratio criterion (SINR); Secondly, a 1D-CNN model containing 3 convolutional layers and 2 full connection layers is designed based on the data form and the number of sampling points; Finally, the 1D-CNN model is trained with the training set, and the learning ability of the 1D-CNN is made use of to learn the MI criterion and SINR criteria, then the trained 1D-CNN is used to generate waveform. An index of target final recognition rate and an index of target recognition rate index are proposed to measure the comprehensive performance of radar. Simulation results show that when the waveform designed by CRWD-1D-CNN method is used as radar transmitting signal, the overall performance of the radar is improved by 0.64% and 2.13% on average

compared with using the waveforms generated by using MI and SINR criteria. These results prove that the CRWD-1D-CNN method can effectively combine the MI criterion and SINR criterion, and improve the comprehensive performance of radar.

Keywords: waveform design; mutual information criterion; signal to interference and noise ratio criterion; one-dimensional convolutional neural network

2006年,加拿大学者 Haykin 根据海豚、蝙蝠等生物的回波定位系统首次提出认知雷达的概念^[1]。与传统雷达相比,认知雷达具有智能信号处理、发射机与接收机之间形成闭环反馈、保存雷达回波信息等特点^[2-3]。作为未来雷达的主要发展趋势,认知雷达通过与环境的交互,改变雷达发射波形,使雷达更适应环境。因此,波形设计是认知雷达中最重要组成部分之一^[4-5]。

波形设计的本质是准则函数加约束条件的最优求解问题^[6]。其中,准则函数的选择取决于雷达任务。针对目标参数估计或目标识别任务,Bell 提出用最大化目标与雷达回波之间的互信息量(MI)来设计波形^[7],更多的互信息量意味着可以通过回波获取更多关于目标的信息,减小目标的不确定性,更清晰的刻画目标特征,该方法被称为 MI 方法。Guo 等证明了在目标参数估计问题上,MI 方法与最小均方差(MMSE)方法是等价的^[8]。对于高斯噪声下特定目标的检测问题,Guerci 与 Pillai 提出信干噪比(SINR)准则来最大化雷达接收信号的信干噪比设计最优检测波形,并取得了良好的结果^[9],该方法称为 SINR 方法。上述文献仅考虑了噪声对波形设计的影响,而忽略了杂波的影响。为解决杂波条件下目标识别和目标检测问题,Romero 等针对确定目标和扩展目标在噪声和杂波背景下,通过 MI 方法和 SINR 方法分别设计波形,并推导出 MI 方法与 SINR 方法之间的关系,为波形设计领域提供了比较完整的理论^[10]。随着雷达技术的发展,雷达任务和工作模式日趋多样化,不仅需要进行目标检测,同时还需要对目标参数进行估计和目标识别,基于单个准则设计的雷达波形已经难以满足需求,这就需要更加灵活的波形设计框架来联合不同的设计准则进行雷达波形设计^[11]。然而,由于不同准则之间的数学关系难以建立,或者建立的数学关系缺乏针对性,因此学术界对这一领域的研究还较少。

深度学习对函数的拟合能力为联合不同准则问题提供一种解决思路。当下,随着硬件计算能力的提升,深度学习成为研究热点,其可有效提取数据特征,学习数据之间的内在规律,并在图像处理、机器

翻译、自动驾驶等领域^[12-13]取得了前所未有的成就。近年来,基于不同应用场景,学者们提出了一系列深度学习模型,其中,卷积神经网络(CNN)是应用最为广泛的模型之一,常用于二维数据处理。随着技术需要,适用于处理一维数据的一维卷积神经网络(1D-CNN)逐渐应用在语音识别^[14]、自然语言处理领域^[15],也广泛应用在雷达领域^[16]。为解决联合不同准则问题,本文提出一种杂波条件下利用 1D-CNN 的认知雷达波形设计方法(CRWD-1D-CNN)。

本文首先分析了 MI 方法和 SINR 方法设计波形的过程,得到了目标函数的表达式,并设定环境信息,使用两准则设计信号,构建训练集;其次,介绍了 1D-CNN 网络结构,提出使用 1D-CNN 来联合 MI 方法和 SINR 方法的流程图。在此基础上,根据训练集数据形式设计了 1D-CNN 模型;最后,对 1D-CNN 模型进行训练和测试,并通过实验仿真,对比 1D-CNN 生成信号、MI 方法信号和 SINR 方法信号对应的检测概率、目标识别率以及雷达综合性能指标,证明了本方法可联合 MI 方法和 SINR 方法,提高雷达综合性能。

1 信号模型与波形设计方法

1.1 信号模型

图 1 为扩展目标信号模型图,其中 $x(t)$ 是时宽为 T 、带宽为 W 的雷达发射信号,扩展目标脉冲响应 $h(t)$ 为有限时间 T_h 内的零均值随机过程, $c(t)$ 为随机杂波脉冲响应, $n(t)$ 为雷达接收机端加性高斯白噪声, $y(t)$ 是雷达接收机接收信号, $r(t)$ 为持续时间为 T_r 的理想低通滤波器。 $x(t)$ 的傅里叶变换为 $X(f)$, $h(t)$ 的傅里叶变换为 $H(f)$, $c(t)$ 的功率谱密度(PSD)为 $S_c(f)$, 噪声 $n(t)$ 的功率谱密度为 $S_n(f)$ 。设 T 远大于 T_h 和 T_r ,即低通滤波器持续




图 1 扩展目标信号模型

Fig. 1 Extended target signal model

时间相对较短,可忽略其影响。

由于 $\mathbf{h}(t)$ 是在时间 T 内的局部平稳过程,所以不能用 PSD 来描述。但可以使用能量谱密度(ESD)来描述,定义 ESD 为

$$\xi(f) = E[|\mathbf{H}(f)|^2] \quad (1)$$

式中: $E(\cdot)$ 表示取期望; $\mathbf{H}(f)$ 的均值和方差分别为

$$\mu(f) = E[\mathbf{H}(f)] \quad (2)$$

$$\sigma^2(f) = E[|\mathbf{H}(f) - \mu(f)|^2] \quad (3)$$

其中 $\sigma^2(f)$ 为目标能量谱方差(ESV),由于扩展目标是 0 均值随机过程,故 $\sigma^2(f) = E[|\mathbf{H}(f)|^2]$,即 ESV 与 ESD 等价,可用 ESV 描述 0 均值有限时间随机过程。由图 1 可知,雷达接收信号为

$$\mathbf{y}(t) = x(t) * \mathbf{h}(t) + x(t) * \mathbf{c}(t) + \mathbf{n}(t) \quad (4)$$

1.2 MI 方法

目标与雷达接收信号之间的互信息量为^[10]

$$I_M = I(\mathbf{y}(t); \mathbf{h}(t) | x(t)) =$$

$$T_y \int_w \ln \left[1 + \frac{\sigma^2(f) |X(f)|^2}{T_y \{S_c(f) |X(f)|^2 + S_n(f)\}} \right] df \quad (5)$$

式中: $T_y = T + T_h$ 是雷达接收信号持续时间。由于式(5)中的被积函数是凹函数,因此联合能量限制 $\int_w |X(f)|^2 df \leq E_x$,可使用拉格朗日乘法对此问题进行求解如下

$$|X(f)|^2_{MI} = \max[0, N(f)(A_{MI} - M(f))] \quad (6)$$

式中: A_{MI} 是由能量限制 $\int_w \max[0, N(f)(A_{MI} - M(f))] df \leq E_x$ 决定的常数; E_x 是雷达发射机能量; $N(f) = \frac{\sigma^2(f)}{2T_y S_c(f) + \sigma^2(f)}$; $M(f) = \frac{T_y S_n(f)}{\sigma^2(f)}$ 。

上述过程即为 MI 方法设计波形的过程。

1.3 SINR 方法

雷达接收机接收信号的信干噪比^[10]为

$$R_{SIN} = \int_w \frac{\sigma^2(f) |X(f)|^2}{S_c(f) |X(f)|^2 + S_n(f)} df \quad (7)$$

积分内函数为凹函数,结合能量限制,使用拉格朗日乘法技术求解得到优化波形为

$$|X(f)|^2_{SINR} = \max[0, K(f)(A_{SINR} - D(f))] \quad (8)$$

式中: A_{SINR} 是由能量限制 $\int_w \max[0, K(f)(A_{SINR} - D(f))] df \leq E_x$ 决定的常数, $K(f) = \frac{\sqrt{\sigma^2(f) S_n(f)}}{S_c(f)}$,

$D(f) = \sqrt{\frac{S_n(f)}{\sigma^2(f)}}$ 。该过程为 SINR 方法设计波形的

过程。

当信号经由存在干扰或噪声的环境时,最佳传输信号在频域的能量分布应避开干扰或噪声能量较强的频点,具有特定的能量谱分布。由 MI 方法和 SINR 方法设计波形的过程可知,两方法设计波形时将扩展目标、杂波和噪声建模为随机过程,并使用能量谱方差 $\sigma^2(f)$ 描述目标特性,用功率谱密度 $S_c(f)$ 和 $S_n(f)$ 来描述杂波和噪声特性。由式(6)和式(8)可知,忽略信号的相位信息,仅从频域出发,即得到最优信号的频域能量分布的幅度谱平方,达到信号设计的目的。

2 基于 1D-CNN 的雷达波形设计

2.1 1D-CNN 模型

自 2012 年 AlexNet 在 ImageNet 大规模视觉识别竞赛(ILSVRC)中取得前所未有的精度并夺冠^[17]以来,CNN 已经在计算机视觉领域取得了极大成就。典型的 CNN 可有效提取二维数据的结构特征,通常用于处理图片等二维数据,为适应语音、文本等一维数据的处理,许多学者也提出了 1D-CNN 模型^[18]。1D-CNN 结构如图 2 所示,通常由输入层、卷积层、池化层、全连接层、输出层等网络层组成。

卷积层具有稀疏连接和权值共享的特征。稀疏连接可避免全连接神经网络参数过多问题,而权值共享则可减小网络的过拟合。1D-CNN 卷积层中为一维卷积核,卷积层的作用是使用一维卷积核在前一层输出特征图上平滑移动进行卷积操作,提取数据特征。如图 2 所示,第 l 卷积层的第 j 个输出的卷积特征图为

$$x_j^l = f \left(\sum_{i=1}^{N_G} x_i^{l-1} \otimes k_{ij}^l + b_j^l \right) \quad (9)$$

式中: $\otimes$ 表示卷积操作; N_G 为第 l 卷积层的输入特征图数; k_{ij}^l 表示第 l 卷积层第 i 个输入特征图与第 j 个输出特征图之间对应的卷积核; b_j^l 为偏置; $f(\cdot)$ 为激活函数。

卷积层之后为池化层,其作用为对卷积特征图进行下采样操作,减小特征维度,提高特征鲁棒性。通常有最大池化和平均池化两种函数,最大池化仅保留局部特征中最大的数据点,而平均池化将局部特征数据取平均操作,具体池化操作的选区由任务性质而定。

经卷积层和池化层处理之后的数据可称之为原始数据的深层特征,全连接层的目的是将这些深层特征进行展平操作,来完成回归或识别任务。




图 2 1D-CNN 结构图

Fig. 2 Structure of 1D-CNN

2.2 基于 1D-CNN 的雷达波形设计流程

由于联合不同准则进行波形设计面临目标函数难以建立的问题,神经网络的学习能力为该问题提供一种解决思路。神经网络的本质就是拟合函数,给定输入和输出数据,经过训练,神经网络即可拟合输入数据与输出数据之间的非线性关系,也即函数关系。此时神经网络内部参数具备刻画输入数据与输出数据之间非线性关系的能力,而这些参数的确定是由给定数据决定的。当输入数据给定为目标、杂波、噪声等环境信息,而输出数据一部分是由 MI 方法根据环境信息设计的信号,另一部分是 SINR 方法设计的信号,经过训练,神经网络便可同时完成对 MI 方法函数和 SINR 方法函数的拟合,从而达到联合 MI 方法和 SINR 方法的目的。

基于上述思想,本文提出一种杂波条件下使用 1D-CNN 的认知雷达波形设计方法,其设计信号的思想如图 3 所示。由图 3 可知,本文方法主要分为 3 个部分:首先,分析 1D-CNN 进行波形设计时的影

响因素,因为利用 MI 方法和 SINR 方法进行波形设计时的影响变量为目标、杂波、噪声,故 1D-CNN 的影响因素同样为目标、杂波、噪声等环境信息,在此基础上设定环境信息,并分别使用 MI 方法和 SINR 方法根据这些信息来设计信号;其次,随机选取一部分 MI 方法信号和一部分 SINR 方法信号,并和与之相应的环境信息共同组成训练集,然后根据训练集数据形式设计相应的 1D-CNN 模型;最后,使用训练集对设计的 1D-CNN 模型进行训练,并测试其性能。

2.3 1D-CNN 的设计

本文设计了一个由输入层、卷积层 1、池化层 1、卷积层 2、池化层 2、卷积层 3、池化层 3、Dropout 层、Flatten 层、全连接层 1、全连接层 2 及输出层组成的 1D-CNN 模型,各层详细参数如图 4 所示。本文所用数据是在 $\sigma^2(f)$ 、 $S_c(f)$ 、 $S_n(f)$ 上采样 100 点得到的,且训练样本为 6 000 组,设定输入层信道为 1,故输入数据尺寸为 (6 000, 300, 1)。图 4 中,32 @




图 3 CRWD-1D-CNN 方法流程

Fig. 3 Flow chart of CRWD-1D-CNN method




图4 本文设计的1D-CNN模型图

Fig. 4 The designed 1D-CNN model

(11×1)表示32个维度为(11,1)的一维卷积核。

为减小网络的过拟合,在将数据展平前加入Dropout层,其作用是在训练过程中将部分神经元随机失活,使得神经网络以较少的神经元完成训练,从而避免过拟合问题。Dropout层丢失率设为0.5。

在卷积层提取的特征进入全连接层之前,需要Flatten层对提取到的特征进行展平操作,使之转换为更适应于全连接层处理的数据形式。由于1D-CNN在本文执行回归任务,故在输出层前添加两层全连接层。最后输出对应MI准则和SINR方法生成波形的频域能量分布对应的采样点数据,故第2个全连接层神经元数量设为100,第一个全连接层神经元数量设为300。

本模型中卷积层激活函数为Relu函数,第一个全连接层激活函数为Sigmoid函数,第2个全连接层不设激活函数。本文损失函数使用平均绝对误差(MAE),给定输入,设模型预测输出为 y_i^p ,该输入对应真实数据为 y_i ,则其损失函数为

$$L = \frac{\sum_{i=1}^n |y_i - y_i^p|}{n} \quad (10)$$

本文使用Adam优化算法,其中学习率 $\epsilon = 0.01$,迭代2000次,每次迭代批次数设为100。

3 实验仿真

本实验是在TensorFlow, MATLAB2017, Python3.6和CUDA9.0的环境架构中进行的,计算机的处理器为i5-7300 HQ,显卡为GTX1050,内存为8 GB。

假设某雷达中心频率 $f_c = 10$ GHz,带宽 $W = 100$ MHz,工作频带为 $[9.95, 10.05]$ GHz。发射信号时宽为10 ms,其频带内采样点为100。本文采取计算机模拟仿真的方法进行实验数据的选取,为保证数据的充分性,设定4000组杂波,杂波PSD通

常为高斯分布^[19],对于 $i \in [1, 4000]$,设 $S_{cc}(f) = B \exp(-0.8\alpha(f-f_i)^2)$,其中 $f_i = f_c + W/2 - 2.5 \times 10^4 i$ 为杂波中频, $B = 7.9577 \times 10^{-16}$ 为目标脉冲响应的谱方差强度, α 表示谱方差随频率变化率,取 $\alpha = 1 \times 10^{-13}$ 。为保证目标数据的非相关性,对于每组杂波,随机产生一组目标能量谱方差,借鉴文献[7,10],本文将目标能量谱方差幅度与杂波功率谱密度幅度取为相同值,共生成4000组目标能量谱方差。假设雷达接收机端噪声为高斯白噪声,为尽可能体现雷达工作环境中噪声远远低于目标的关系,噪声功率谱密度取为 $S_n(f) = kT = 4.1430 \times 10^{-21}$ J,其中 $T = 300$ K为噪声有效温度, $k = 1.381 \times 10^{-23}$ J/K为玻尔兹曼常数。将上述每个杂波对应的目标和噪声构成一组环境信息,共生成4000组环境信息。

获得环境信息之后,分别使用MI方法和SINR方法根据上述4000组环境信息设计波形,对于每种准则信号随机抽取3000组环境信息与其对应环境信息组成包含6000组样本的训练集,剩下1000组环境信息作为测试集。然后,使用训练集对设计的1D-CNN模型进行训练。最后,使用测试集中的环境信息对训练完成的模型进行测试。

每组环境信息包含3个变量,即杂波功率谱密度、目标能量谱方差、噪声能量谱方差。测试集中包含1000组环境信息,随机抽取一组如图5所示的环境信息,其中图5a为杂波的能量谱密度 $S_c(f)$,图5b是噪声的功率谱密度 $S_n(f)$,由上述内容可知, $S_n(f)$ 为固定值,图5c是目标的能量谱方差 $\sigma^2(f)$ 。

在雷达发射功率 $P = 100$ W时,使用图5中的环境信息对训练完成的1D-CNN模型进行测试,并与MI方法和SINR方法信号进行对比,结果如图6所示。由图6可知,3种信号在分配能量时都避开了杂波较强的频点。MI方法信号频带较宽,各频点分配的能量相对较低。SINR方法信号频带相对较




图5 用于测试的3个环境信息变量

Fig. 5 Three environmental information variables for testing




图6 3种方法生成信号的频域能量分布图

Fig. 6 Frequency-domain energy distribution of 3 signals




图7 不同功率下3种方法生成信号对应的互信息

Fig. 7 MI of 3 signals under different transmit power

窄,此窄带内频点能量较高。这是由于 MI 方法信号为获取目标更多信息,需将能量分配到目标不同散射模式的频点处,而 SINR 方法信号只需将能量分配到目标最大反射模式的频点处。但是反射较弱的频点可能包含较为明显的目标特征,可用于目标识别。所以,MI 方法信号通常用于目标识别,SINR 方法信号用于目标检测。CRWD-1D-CNN 方法生成的信号频带介于两信号之间,可兼顾目标不同的散射模式,既可获得关于目标的较多信息,又可维持较高的信干噪比,实现了 MI 方法与 SINR 方法的平滑过渡。

本文使用蒙特卡罗方法对不同能量下 1D-CNN 模型进行测试。给定发射机能量,使用测试集中环境信息对训练完成的 1D-CNN 模型进行测试,生成 1 000 组波形。对 1 000 组波形的互信息指标和 SINR 指标取平均,得到该能量下的互信息和信干噪比指标,其结果如图 7~图 9 所示。

图 7 为雷达不同发射功率下 MI 方法、SINR 方法和 CRWD-1D-CNN 方法生成信号对应的互信息量指标。由图可见,3 种方法生成信号对应的互信息量都随雷达发射功率的增加而增加,且 CRWD-1D-CNN 生成信号对应的互信息量要比 SINR 方法信号

平均高出 20.10%,比 MI 方法信号平均低 8.24%。

根据统计判决理论,雷达检测可视为假设检验问题,解决该问题的基本方法为经典奈曼-皮尔逊(NP)定理,根据 NP 定理构造雷达检测器,得雷达检测概率为^[20]

$$P_d = Q(Q^{-1}(P_{FA}) - \sqrt{R_{SIN}}) \quad (11)$$

式中: $Q(x) = \int_x^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}t^2\right) dt$ 为右尾概率;

R_{SIN} 为信干噪比; P_{FA} 为虚警概率。根据发射波形计算 SINR,进而得到检测概率。

图 8 为雷达不同发射功率下,3 种方法生成的信号对应的信干噪比。在虚警率 $P_{FA} = 10^{-4}$ 时,根据式(11),可由图 8 中数据得到如图 9 所示的检测概率。由图 9 可知,CRWD-1D-CNN 方法生成的信号对应的检测概率随雷达发射功率增加而增加,且要比 MI 方法信号对应的信干噪比平均高出 10.40%,比 SINR 方法信号平均低 6.43%。

为衡量雷达综合性能,本文提出一种目标最终识别率指标。定义

$$P_c = P_d P_r \quad (12)$$

式中: P_c 为目标最终识别率,可作为衡量雷达综合性能的指标; P_d 为检测概率; P_r 为目标识别率。




图 8 不同功率下 3 种方法生成的信号对应信干噪比
Fig. 8 SINR of 3 signals under different transmit power




图 9 不同功率下 3 种方法生成的信号对应检测概率
Fig.9 Detection probability of 3 signals under different transmit power

P_r 随目标与回波之间的互信息量增加而增加,但两者缺乏直接函数关系。本文提出一种用互信息量来衡量 P_r 的方法,定义

$$P_r = \frac{I_{mx}}{I_{mxnc}}$$

(13)

式中: I_{mx} 为杂波条件下发射信号为 $x(t)$ 时,目标与回波之间的互信息量; I_{mxnc} 为不存在杂波时,目标与回波之间可获得的最大互信息量。

表 1 为 3 种方法生成的信号对应平均检测概率、平均识别概率和平均最终目标识别率。由表 1 可知,采用 CRWD-1D-CNN 方法生成的信号平均检
表 1 3 种方法生成信号对应的平均检测概率、平均识别率和平均最终目标识别率

Table 1 Average detection probability, average recognition rate and average final target recognition rate of 3 methods

方法	P_d	P_r	P_c
CRWD-1D-CNN	0.692 7	0.128 5	0.089 0
MI	0.588 7	0.140 3	0.082 6
SINR	0.757 0	0.089 4	0.067 7

测概率和平均识别率均介于两准则信号之间,即 1D-CNN 可在 MI 方法和 SINR 方法之间实现权衡,而 CRWD-1D-CNN 方法信号的目标最终识别率要比 MI 方法信号高 0.64%,比 SINR 方法信号高 2.13%,证明了 CRWD-1D-CNN 方法可联合 MI 方法和 SINR 方法生成信号,提高雷达综合性能。

4 结 论

本文提出了一种杂波条件下使用 1D-CNN 的认知雷达波形设计方法 CRWD-1D-CNN。利用 1D-CNN 对一维数据之间非线性关系的映射能力,实现了 MI 方法与 SINR 方法之间的联合。为衡量雷达综合性能,提出了一种新的最终目标识别率和利用互信息来衡量的目标识别率指标。实验结果表明,当使用 CRWD-1D-CNN 方法所生成的波形作为发射信号时,与 MI 方法生成信号和 SINR 方法生成信号相比,雷达综合性能指标均得到提升,证明了 CRWD-1D-CNN 方法所生成的波形可满足雷达同时进行检测和识别任务的需求,为联合不同准则进行多任务雷达波形设计提供了一种新的解决方案。与波形设计领域许多文献相同,本文仅得到了最优信号的能量谱分布,并没有根据能量谱合成时域信号。根据给定的能量谱合成时域信号是信号处理领域的另一重要分支,是本文的后续研究方向。

参考文献:

[1] HAYKIN S. Cognitive radar: a way of the future [J]. IEEE Signal Processing Magazine, 2006, 23(1): 30-40.

[2] GUERCI J R. Cognitive radar: the knowledge-aided fully adaptive approach [M]. London, UK: Artech House, 2010: 34-36.

[3] 龚逸帅,李开明,张群,等. 面向成像任务的宽带 MI-MO 雷达认知波形设计 [J]. 西安交通大学学报, 2018, 52(6): 114-121.

GONG Yishuai, LI Kaiming, ZHANG Qun, et al. Cognitive waveform optimization of wideband MIMO radars for imaging tasks [J]. Journal of Xi'an Jiaotong University, 2018, 52(6): 114-121.

[4] TAN Q J O, ROMERO R A. Air vehicle target recognition with jammer nulling adaptive waveforms in cognitive radar using high-fidelity RCS responses [C] // 2018 International Conference on Radar. Piscataway, NJ, USA: IEEE, 2018: 8557289.

[5] 柏婷,郑娜娥,李海文. 面向邻近目标分辨的 MIMO 雷达波形设计方法 [J]. 西安交通大学学报, 2018, 52

- (4): 125-131.
- BAI Ting, ZHENG Na'e, LI Haiwen. A waveform design of MIMO radars for identification of neighboring targets [J]. Journal of Xi'an Jiaotong University, 2018, 52(4): 125-131.
- [6] ZHANG J D, ZHU D Y, ZHANG G. Multi-objective waveform design for cognitive radar [C]// IEEE CIE International Conference on Radar. Piscataway, NJ, USA; IEEE, 2011: 580-583.
- [7] BELL M R. Information theory and radar waveform design [J]. IEEE Transactions on Information Theory, 1993, 39(5): 1578-1597.
- [8] GUO D, SHAMAI S, VERDU S. Mutual information and minimum mean-square error in Gaussian channels [J]. IEEE Transactions on Information Theory, 2005, 51(4): 1261-1282.
- [9] PILLAI S U, YOULA D C, OH H S, et al. Optimum transmit-receiver design in the presence of signal-dependent interference and channel noise [J]. IEEE Transactions on Information Theory, 2002, 46(5): 577-584.
- [10] ROMERO R A, BAE J, GOODMAN N A. Theory and application of SNR and mutual information matched illumination waveforms [J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(2): 912-927.
- [11] HAYKIN S, XUE Yanbo, DAVIDSON T N. Optimal waveform design for cognitive radar [C]// 42nd Asilomar Conference on Signals, Systems and Computers. Los Alamitos, CA, USA; IEEE Computer Society, 2008: 3-7.
- [12] YUAN Chengsheng, XIA Zhihua, JIANG Leqi, et al. Fingerprint liveness detection using an improved CNN with image scale equalization [J]. IEEE Access, 2019, 7: 26953-26966.
- [13] CHEN K, ZHAO T, YANG M, et al. A neural approach to source dependence based context model for statistical machine translation [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26(2): 266-280.
- [14] CHOWDHURY A, ROSS A. Fusing MFCC and LPC features using 1D triplet CNN for speaker recognition in severely degraded audio signals [J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 1616-1629.
- [15] SUN Kaili, LI Yuan, DENG Dunhua, et al. Multi-channel CNN based inner-attention for compound sentence relation classification [J]. IEEE Access, 2019, 7: 141801-141809.
- [16] KIM S, HAN G. 1D CNN based human respiration pattern recognition using ultra wideband radar [C]// 1st International Conference on Artificial Intelligence in Information and Communication. Piscataway, NJ, USA; IEEE, 2019: 411-414.
- [17] 孟月波, 纪拓, 刘光辉, 等. 编码-解码多尺度卷积神经网络人群计数方法 [J]. 西安交通大学学报, 2020, 54(5): 149-157.
- MENG Yuebo, JI Tuo, LIU Guanghui, et al. Encoding-decoding multi-scale convolutional neural network for crowd counting [J]. Journal of Xi'an Jiaotong University, 2020, 54(5): 149-157.
- [18] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Image net classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 1097-1105.
- [19] HABIBUR R. Fundamental principles of radar [M]. Boca Raton, FL, USA; CRC Press, 2019: 64-65.
- [20] STEVEN M K, 罗鹏飞. 统计信号处理基础: 估计与检测理论 [M]. 北京: 电子工业出版社, 2014: 425-445.

(编辑 刘杨)