

基于卷积神经网络的多雷达协同抗欺骗式干扰方法

赵珊珊, 申琦, 苗嘉宁

(南京邮电大学电子与光学工程学院, 南京 210023)

摘要: 现有多站融合技术聚焦于利用回波的幅度相关性和空间定位等直观特征, 同时人工特征提取的全面性不足, 易导致信号资源的浪费、特征提取不全和判别算法不够通用等问题。为解决这些问题, 创新性地提出了一种融合多雷达协同检测与卷积神经网络的干扰识别策略, 利用卷积神经网络深入挖掘回波数据中的未知信息, 提取真假目标在多维深层特征上的差异, 超越单一的空间相关性差异, 实现欺骗干扰判别。最后, 仿真实验验证了提出方法抗欺骗干扰的可行性, 并分析了目标尺寸、多站雷达布站和相位误差对所提算法的影响。

关键词: 电子抗干扰; 多雷达协同检测; 卷积神经网络; 抗欺骗式干扰; 干扰判别

中图分类号: TN973

文献标志码: A

Multi-radar Collaborative Anti-deception Jamming Method Based on Convolutional Neural Network

ZHAO Shanshan, SHEN Qi, MIAO Jianing

(College of Electronic and Optical Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Existing multi-station fusion technologies focus on utilizing intuitive features such as echo amplitude correlation and spatial location. However, the comprehensiveness of manual feature extraction is insufficient, which can easily lead to signal resource waste, incomplete feature extraction, and limited generalization of discrimination algorithms. To address this issue, this paper innovatively proposes a jamming identification strategy that integrates multi-radar cooperative detection with convolutional neural network. This approach leverages convolutional neural networks to deeply explore unknown information in echo data, extracting differences between real and false targets in multidimensional deep features, surpassing single spatial correlation differences, and achieving deception jamming identification. Finally, simulation experiments validate the feasibility of the proposed method in resisting deception jamming and analyze the effects of target size, multi-station radar deployment and phase errors on the proposed algorithm.

Key words: electronic anti-interference; multi-radar cooperative detection; convolutional neural network; anti-deception jamming; jamming discrimination

引言

雷达主要面临的一种干扰方式是有源欺骗式干扰, 这种干扰会捕获、储存并预估目标信号的参数,

基金项目: 国家自然科学基金(61801233); 装备预研重点实验室基金(JKW202209)。

收稿日期: 2024-09-15; **修订日期:** 2024-11-27

然后根据预估的参数产生相应的干扰信号,转发给雷达以欺骗雷达^[1]。欺骗式干扰通过生成仿真目标的有源假目标,诱导雷达误判,因此抗欺骗式干扰的主要任务就是鉴别出真假目标^[2]。多站雷达组网技术通过数据级^[3]与信号级^[4]的协同处理,显著增强了抗欺骗式干扰的能力。数据级抗欺骗式干扰聚焦于组网雷达独立进行目标探测的过程,并将数据传输至融合中心进行协同处理。信号级抗欺骗式干扰通过融合信号特征,依据真假目标在空间散射特性上的差异来识别并剔除假目标^[5],并全面传输各接收站的目标回波信号至融合中心。该方法融合层次深入,探测信息广泛,显著增强了抗干扰性能。

在大多数组网雷达中,抗干扰技术通常专注于窄带雷达设计。然而,相较于窄带雷达,宽带雷达具备更高的分辨率和优越的抗干扰性能。文献[6]在理论上分析了多视角一维距离像去相关的内在机制,并提出了一种新的宽带雷达组网条件下的抗欺骗式干扰方法,该方法利用一维距离像的相关性差异进行干扰鉴别。此外,高效稳定地融合多站雷达系统捕获的目标回波数据是信号处理技术的关键问题。传统方法往往依赖于幅度相关或空间位置等单一特征进行融合,但存在人工提取不全导致的信号资源浪费等问题。为应对这些挑战,本文将卷积神经网络(Convolutional neural network, CNN)引入抗欺骗式干扰中。

目前,神经网络以其自学习、自组织、非线性及并行分布式处理能力,成为有效解决问题的信息处理方法^[7]。近年来,神经网络技术在计算机视觉^[8]、目标检测^[9]、语音识别^[10]和高光谱数据分类等领域表现突出,发展迅速。在大数据特征提取领域,深度神经网络模型如CNN^[11]、深度信念网络^[12]、循环神经网络^[13]等展现出显著潜力,并已有效应用于干扰对抗领域^[14-18],包括基于一维CNN的一维高分辨距离像(High resolution range profile, HRRP)雷达目标分类^[19]、高分辨率距离像识别^[20]及干扰信号分类^[21]。针对合成孔径雷达(Synthetic aperture radar, SAR)弹幕干扰,提出了基于CNN的检测与分类新方法^[22];此外,还设计了双分支CNN架构,通过独立处理视觉和拓扑特征,并进行交互融合,实现更高效的特征提取与分类^[23]。

本文创新性地将卷积神经网络用于宽带组网雷达信号级抗欺骗式干扰,利用CNN的多层结构实现对目标特征的高效提取与分类。具体地,将同一目标在多个雷达站的一维距离像按行排列,形成二维参数矩阵作为CNN的输入,通过网络训练优化参数,利用多层网络提取真假目标的多维度差异,实现对真实性的联合鉴别^[23]。

1 信号模型

宽带组网雷达系统由 M 个发射站 $T_m(m=1, 2, \dots, M)$ 和 N 个接收站 $R_n(n=1, 2, \dots, N)$ 组成,在探测区域内,存在 K 个真实目标,为保护真实目标,干扰机实施欺骗式干扰,通过对发射信号进行参数估计,调制后转发形成 Q 个有源假目标。

设各宽带雷达时间和相位同步已完成,在各接收站中,利用匹配滤波分离不同发射站发射信号,构成 $M \times N$ 个独立的发射-接收通道, (m, n) 通道表示由第 m 个发射站 T_m 和第 n 个接收站 R_n 组成,其回波信号 $r_{mn}(t)$ 可以表示为

$$r_{mn}(t) = e_{mn}(t) + j_{mn}(t) + n_{mn}(t) \quad (1)$$

式中:时间 t 满足 $0 \leq t \leq T$, T 为一个脉冲重复间隔的时间; $e_{mn}(t)$ 代表 (m, n) 通道中的真实目标回波信号, $j_{mn}(t)$ 代表欺骗干扰信号, $n_{mn}(t)$ 代表噪声。

针对宽带雷达信号,真实目标因多个强散射中心而产生复合回波,该回波为各散射中心回波信号的矢量和。若第 k 个真实目标在 (m, n) 通道的一维距离像用 $X_{mn|PT, k}$ 来表征,它是一个 $A_p \times 1$ 维的矢量, A_p 为第 k 个真实目标所占据的距离单元的个数。可以表述为

$$X_{mn|PT, k} = \zeta_{mn|PT, k} + n_{mn, k} \quad (2)$$

式中: $\mathbf{n}_{mn,k} \sim \text{CN}(0_{A_p \times 1}, \sigma_{mn}^2 \mathbf{I}_{A_p})$ 是服从复高斯分布的噪声矢量, $0_{A_p \times 1}$ 是维数为 $A_p \times 1$ 的全零矢量, \mathbf{I}_{A_p} 是 $A_p \times A_p$ 维的单位阵。 $\zeta_{mn|PT,k}$ 是第 k 个真实目标在 (m,n) 通道的一维信号矢量, 假设每个距离单元内的回波信号独立同分布, 那么 $\zeta_{mn|PT,k} \sim \text{CN}(0_{A_p \times 1}, \sigma_{PT,k}^2 \mathbf{I}_{A_p \times 1})$ 。根据文献[23], 由于接收站位置各异, 真实目标的散射信号对各接收站呈现不同视角, 导致其一维距离像在各接收站视角下差异显著, 从而在不同宽带雷达接收站视角差异较大时, 这些一维距离像之间不相关, 因此, $\rho(\zeta_{mn|PT,k}, \zeta_{m'n'|PT,k}) \approx 0$, $m \neq m'$ 或 $n \neq n'$ 。

为了模拟真实目标的回波特性, 将有源假目标也建模为距离扩展目标。第 q 个有源假目标在 (m,n) 通道的一维距离像 $\mathbf{X}_{mn|FT,q}$ 是一个 $B_h \times 1$ 的矢量, 可以表述为

$$\mathbf{X}_{mn|FT,q} = \zeta_{mn|FT,q} + \mathbf{n}_{mn,q} \quad (3)$$

式中: $\mathbf{n}_{mn,q} \sim \text{CN}(0_{B_h \times 1}, \sigma_{mn}^2 \mathbf{I}_{B_h})$ 是服从复高斯分布的噪声矢量, $0_{B_h \times 1}$ 是维数为 $B_h \times 1$ 的全零矢量, \mathbf{I}_{B_h} 是 $B_h \times B_h$ 维的单位阵。 $\zeta_{mn|FT,k}$ 是第 k 个有源假目标在 (m,n) 通道的一维信号矢量,

由于干扰机通过截获真实目标信号, 采样并存储数据后, 进行参数估计, 据此生成假目标信号。调制后转发至各接收站, 确保同一发射信号的调制干扰信号在各接收站中保持强相关性, 因此, $\rho(\zeta_{mn|FT,q}, \zeta_{m'n'|FT,q}) \approx 1$ 。

真假目标一维距离像在不同接收站中相关性的差异是宽带雷达组网信号级协同抗欺骗式干扰的基础。在以上建立的真实目标和假目标一维距离像信号模型基础上, CNN 的输入信号不再是单个接收站的一维距离像, 而是对多个接收站的一维距离像进行了联合处理, 具体的输入信号模型如图1所示, 将不同接收站接收到的同一目标的一维距离像按行排序组成 CNN 的输入。即每个雷达站所获取的同一目标(真实目标或假目标)的一维距离像为一行, 将多个雷达站的信息共同构建一个二维参数矩阵, 这一矩阵为 CNN 的输入。图1中, N 为接收站个数, P 为目标所占据距离单元的个数, ϵ_n^p 表示真实目标在第 n 个接收站第 p 个距离单元的回波, γ_n^p 表示假目标在第 n 个接收站第 p 个距离单元的回波, 输入的二维参数矩阵的每一行表示目标在每个接收站的一维距离像。

ϵ_1^1	ϵ_1^2	\cdots	ϵ_1^P
ϵ_2^1	ϵ_2^2	\cdots	ϵ_2^P
\vdots	\vdots	ϵ_n^p	\vdots
ϵ_N^1	ϵ_N^2	\cdots	ϵ_N^P

真实目标在第1个接收站的一维距离像
真实目标在第2个接收站的一维距离像
 \vdots
真实目标在第 N 个接收站的一维距离像

或

γ_1^1	γ_1^2	\cdots	γ_1^P
γ_2^1	γ_2^2	\cdots	γ_2^P
\vdots	\vdots	γ_n^p	\vdots
γ_N^1	γ_N^2	\cdots	γ_N^P

假目标在第1个接收站的一维距离像
假目标在第2个接收站的一维距离像
 \vdots
假目标在第 N 个接收站的一维距离像

图1 CNN 的输入

Fig.1 Input from CNN

2 CNN 鉴别算法

CNN 是一种包含卷积运算的深度前馈神经网络^[24], 它能够稳定地提取目标特征, 这使其在雷达信号处理领域的应用尤为突出。针对雷达系统中的干扰问题, 本节设计了一种端到端的干扰对抗系统。该系统核心在于利用目标在多个接收站的一维距离像原始采样序列作为输入, 省去了复杂的时频图像转换步骤, 有效避免了信息的潜在损失。通过 CNN 网络结构, 系统能自动从原始采样序列中提取真假目标的多样基本特征。相比传统干扰判别方法, CNN 不仅突破了人工特征提取的单一性局限, 还能跨雷达系统和空间位置稳定判别。此外, CNN 强大的数据拟合能力能适应数据分布, 有效降低噪声对判

别效果的影响,提高了干扰识别的可行性与准确性。

从总体结构上看,CNN 网络由多个卷积层、池化层和全连接层组成。输入数据为多站接收的一维距离像叠成的二维矩阵,这种结构使得 CNN 网络能够同时考虑多个站的回波信息,更好地挖掘多维特征。

2.1 卷积层

如图 2 所示,卷积层通过执行卷积运算来检测输入数据的局部特征,是 CNN 中负责特征提取的核心模块。在多站宽带雷达系统中,不同接收站和不同距离单元的信号可能存在细微的差异,这些差异对于区分目标回波和欺骗干扰信号至关重要,因此在特征提取过程中,选用两个卷积层。对于卷积层 1,采用大小为 3×3 的卷积核,步长为 1,

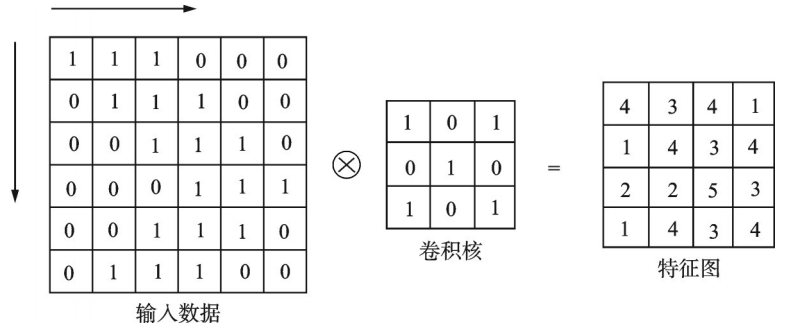


图 2 卷积层过程

Fig.2 Convolutional layer process

生成 16 个特征图,这一设置有助于提取输入二维矩阵中不同接收站和不同距离单元的局部特征,有效地捕获了输入二维矩阵中的局部细节特征。对于卷积层 2,同样使用 3×3 的卷积核,步长为 1,但特征图个数增加到 32,通过增加特征图的数量,可以进一步捕捉更复杂的特征模式,提高对目标回波和欺骗干扰信号的区分能力。经过卷积后,会生成特定大小的特征图,这些特征图将为后续的目标识别和处理提供关键信息。特征图大小可表示为

$$O = \frac{(K - F + 2 \times A)}{S} + 1 \quad (4)$$

式中: K 为输入数据的大小, F 为卷积核的大小, A 为 0 填充的大小,且 $A = (F - 1)/2$, S 为步长。

2.2 池化层

因为输入数据维数较高,且卷积层在窗口滑动卷积过程中有大量重叠区域,使得输出特征块存在大量冗余信息。引入池化层可通过降维减少数据量和参数,进而降低模型计算复杂度。同时,提取输入数据的重要特征,在一定程度上减少过拟合现象。选用两个池化层,对于池化层 1,其大小为 2×2 ,步长为 2,采用最大池化方式。该池化层的作用是减少冗余信息,降低计算量,同时保留显著特征,增强模型的鲁棒性。对于池化层 2,其大小为 2×2 ,步长为 1,同样采用最大池化。这一层进一步对特征进行下采样,提取更抽象的特征表示。池化层采用最大池化方法的原因如图 3 所示,因为在目标回波信号中,可能存在特定距离单元上的强回波峰值,这些峰值可能是目标的重要特征。最大池化可以确保这些峰值在池化后仍然得以保留,而不会被均值池化所平滑掉,在降低特征维度的同时保留重要的特征信息。通过池化层的处理,网络能够更好地关注到数据的全局结构,同时减少了计算量,提高了效率。通过多个卷积层和池化层的组合,网络能够逐步提取出回波数据中的深度特征。




图 3 池化层过程

Fig.3 Pooling layer process

2.3 全连接层

在多层卷积和池化后,CNN 需要应用一个全连接层将卷积层和池化层提取并将处理得到的特征图

进行整合和映射,以实现目标回波和欺骗干扰信号的分类。根据系统所需的鉴别情况,全连接层设置神经元个数为 2,将提取的特征映射到最终的分类空间,这两个神经元分别对应真实目标和假目标的分类结果。激活函数采用 Sigmoid 函数,其表达式为

$$f(x)=\frac{1}{1+e^{-x}}$$

(5)

作为网络的激活函数,Sigmoid 可以模拟神经元映射过程,并且其输出范围有限,数据在传递过程中不易发散。对于模型训练参数,通过训练过程对 CNN 的各项参数进行了反复调整和优化。初始学习率设置为 0.001,以控制模型在训练过程中的参数更新幅度。采用 Softmax 作为分类函数,对于分类数为 2 的情况,全连接层将输入的特征图映射为 2×1 大小的输出向量 $z=[z_1,z_2]$ 作为 Softmax 分类器的输入,获得输出向量的表达式为

$$u=w*z$$

(6)

式中 w 为全连接层的权向量。

在分类过程中,对于类别 i ,Softmax 输出为

$$p(i)=\frac{\exp(z_i)}{\sum_{j=1}^2\exp(z_j)}$$

(7)

式中: $\exp(z_i)$ 表示分类器中作用于类别 i 的分数, $\sum_{j=1}^2\exp(z_j)$ 是对两个类别分数的求和。

根据融合后的特征对输入数据进行分类,判断是否为欺骗干扰信号。损失函数选择交叉熵损失函数,用于衡量模型预测与真实标签之间的差异。为了防止过拟合,引入 Dropout 机制,保留概率为 0.5,即在训练过程中随机忽略一部分神经元的输出。模型的最大迭代次数设定为 240,以确保充分的训练和收敛。最终确定了网络基础参数的相关配置如表 1,2 所示。

表 1 CNN 网络参数表 I

Table 1 CNN network parameter table I			
层名称	尺寸	步长	特征
卷积层 1	卷积核大小: 3×3	步长: 1	特征图个数: 16
卷积层 2	卷积核大小: 3×3	步长: 1	特征图个数: 32
池化层 1	大小: 2×2	步长: 2	最大池化
池化层 2	大小: 2×2	步长: 1	最大池化
全连接层	神经元个数: 2	—	—

表 2 CNN 网络参数表 II

Table 2 CNN network parameter table II	
名称	参数
初始学习率	0.001
分类函数	Softmax
损失函数	交叉熵损失函数
Dropout 保留概率	0.5
最大迭代次数	240

将各雷达站真假目标一维距离像组成的二维参数矩阵放入已经训练好的卷积神经网络中,该网络可根据训练结果自动对真假目标进行分类,从而达到鉴别假目标的目的。

3 仿真实验与性能分析

雷达发射信号为线性调频信号,信号带宽为 400 MHz,载频为 4 GHz。发射站的位置坐标为 $[0,0,0]$ km,接收站的位置坐标分别为 $[0,0,0]$ km、 $[10,0,0]$ km、 $[20,0,0]$ km 和 $[30,0,0]$ km。为了更好的欺骗效果,假设真实目标的信噪比(Signal-to-noise ratio, SNR)和假目标的干噪比(Jamming-to-noise ratio, JNR)是相等的。对于每个 SNR 和 JNR,两个真实目标和两个假目标分别产生 1 200 组测试样本,将 4 800 组测试样本放入训练好的 CNN 模型中,计算目标的鉴别概率。

3.1 不同目标尺寸下目标鉴别概率

在本节所设置的仿真参数下,对尺寸分别为 $D=20, 25, 30$ m的3种目标进行仿真实验,仿真结果如图4所示,实验分析了不同SNR和JNR条件下,目标尺寸对目标鉴别概率的影响和真假目标的鉴别概率变化情况。

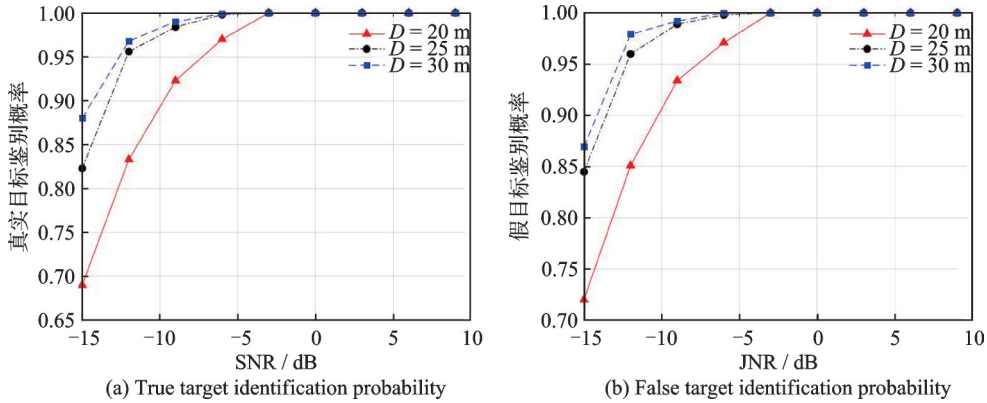


图4 3种目标尺寸下目标鉴别概率

Fig.4 Probability of target identification under three target sizes

由图4可以看出,随着SNR和JNR的增加,低SNR条件下的目标鉴别概率逐渐上升,并在SNR和JNR达到 -3 dB时,目标鉴别概率接近1。

对比不同目标尺寸下的鉴别概率,可以看出,目标尺寸越大,目标的鉴别概率越高。这是因为目标尺寸越大,其一维距离像占据的距离单元个数越多,相应的2D-CNN的二维输入参数矩阵增大,CNN所提取的真假目标特征更加明显,导致目标的鉴别概率增高。

3.2 不同布站情况下目标鉴别概率

为分析接收站布站位置对目标鉴别概率的影响,在本节所设置的仿真参数下,对接收站的布站分3种情况讨论。布站1:接收站的位置坐标分别为 $[0, 0, 0]$ km、 $[10, 0, 0]$ km、 $[20, 0, 0]$ km和 $[30, 0, 0]$ km;布站2:接收站的位置坐标分别为 $[0, 0, 0]$ km、 $[20, 0, 0]$ km、 $[40, 0, 0]$ km和 $[60, 0, 0]$ km;布站3:接收站的位置坐标分别为 $[0, 0, 0]$ km、 $[10, 0, 0]$ km和 $[20, 0, 0]$ km。在此仿真参数下,对尺寸 $D=20$ m的目标进行仿真实验,仿真结果如图5所示。

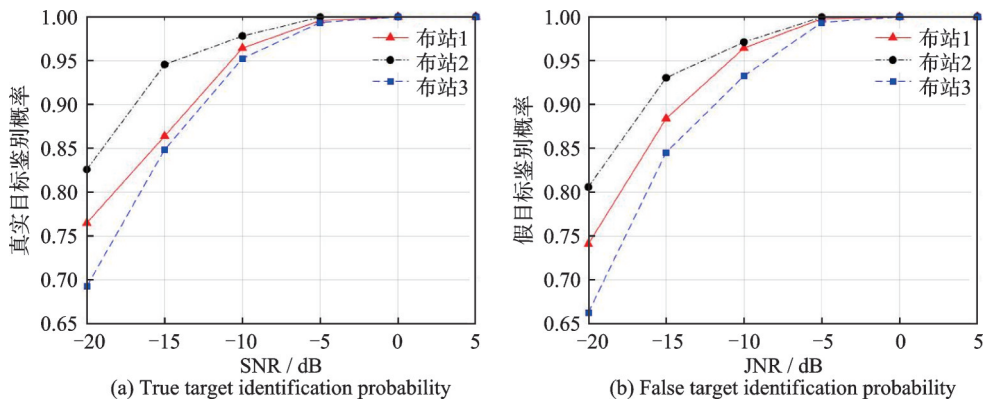


图5 不同布站情况下目标鉴别概率

Fig.5 Probability of target identification under different stations

由图5可以看出,布站位置的变化对目标鉴别概率有较为明显的影响,当雷达接收站位置较少时,二维参数矩阵的行数较少,神经网络学习到的特征较少,目标鉴别性能较差;当接收站位置相同,不同接收站探测目标的视角差距较大时,不同接收站接收到的真实目标一维距离像相关性越小,真实目标和假目标的二维参数矩阵差异更大,目标鉴别概率更好。

3.3 相位误差下目标鉴别概率

相位误差将带来假目标一维距离像去相关,从而导致抗欺骗干扰性能的下降。为分析相位误差对目标鉴别概率的影响,本文考虑在不同假目标相关系数下,对提出算法进行仿真分析。在本节所设置的仿真参数下,对尺寸 $D=20$ m 的目标进行仿真实验,仿真结果如图6所示,实验分析了不同 SNR 和 JNR 下,假目标相关系数对目标鉴别概率的影响和真假目标的鉴别概率变化情况。

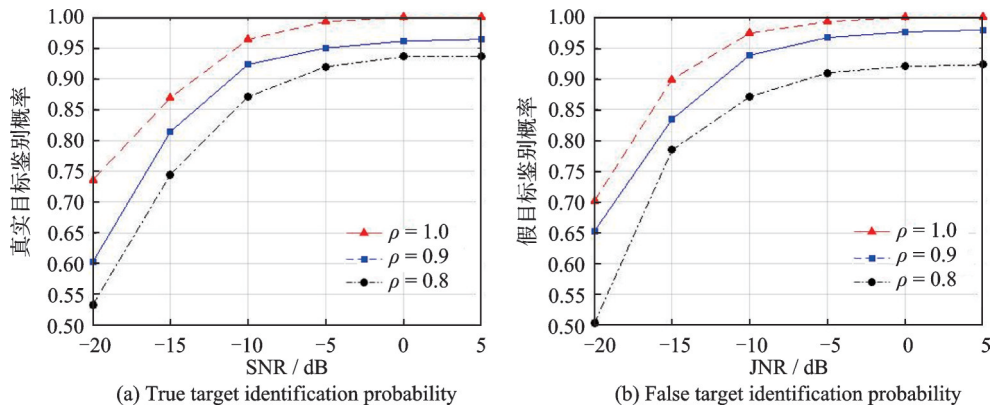


图6 相位同步对目标鉴别概率的影响

Fig.6 Effect of phase synchronization on the probability of target identification

图6中 ρ 为假目标相关系数。由图6可以看出,假目标相关系数越接近于1,目标的鉴别概率越高,当假目标相关系数减小,目标鉴别概率有较为明显的下降。这是因为相位对齐误差将带来假目标一维距离像去相关,真假目标的相关系数差异越小,相应的真假目标CNN的二维输入参数矩阵差异越小,CNN所提取的真假目标特征不明显,导致目标的鉴别概率降低。在这种条件下,所提算法性能将下降。

4 结束语

本文利用二维CNN提取真假不同维度的差异对真假目标进行目标鉴别。首先,建立了CNN的输入信号模型。其次,介绍了典型的CNN结构,包括卷积层、池化层和全连接层等多个模块,在多模块的共同作用下,可对不同目标进行特征提取、识别分类。然后,提出了基于CNN的抗欺骗式干扰方法,搭建了针对多站宽带雷达系统抗欺骗干扰的CNN网络模型,并对网络参数进行了设计。最后,仿真实验验证了所提算法的有效性,并分析了SNR和JNR、目标尺寸和接收站布站情况对目标鉴别概率的影响以及时间和相位同步对系统性能的影响。本文信号级鉴别算法可与数据级协同假目标鉴别算法进行级联使用,进一步提高欺骗式干扰鉴别性能。

参考文献:

- [1] 黄大通,邢世其,徐伟,等.一种多干扰机幅-频协同调制的SAR-GMTI欺骗干扰方法[J].信号处理,2022,38(3):445-456.
HUANG Datong, XING Shiqi, XU Wei, et al. A SAR-GMTI deception interference method based on multi-interference carrier-amplitude-frequency cooperative modulation[J]. Signal Processing, 2022, 38(3): 445-456.

- [2] 李亚南, 韩壮志, 曹文浩. 雷达抗干扰性能测试与评估方法研究[J]. 现代雷达, 2022, 44(9): 79-84.
LI Yanan, HAN Zhuangzhi, CAO Wenhao. Research on radar anti-interference performance testing and evaluation methods [J]. Modern Radar, 2022, 44(9): 79-84.
- [3] 赵珊珊, 张林让, 周宇, 等. 组网雷达点迹信息融合抗假目标干扰方法[J]. 电子科技大学学报, 2014, 43(2): 207-211.
ZHAO Shanshan, ZHANG Linrang, ZHOU Yu, et al. Method for fusion of networked radar track information to resist false target interference[J]. Journal of University of Electronic Science and Technology of China, 2014, 43(2): 207-211.
- [4] ZHAO Shanshan, ZHANG Linrang, ZHOU Yu, et al. Discrimination of active false targets in multistatic radar using spatial scattering properties[J]. IET Radar, Sonar & Navigation, 2016, 10(5): 817-826.
- [5] ZHAO Shanshan, ZHANG Linrang, ZHOU Yu, et al. Signal fusion-based algorithms to discriminate between radar targets and deception jamming in distributed multiple-radar architectures[J]. IEEE Sensors Journal, 2015, 15(11): 6697-6706.
- [6] 赵珊珊, 苗嘉宁, 刘子威. 宽带雷达组网协同抗欺骗式干扰方法[J]. 信号处理, 2024, 40(9): 1738-1747.
ZHAO Shanshan, MIAO Jianing, LIU Ziwei. A networked broadband radar cooperative anti-spoofing interference method[J]. Signal Processing, 2024, 40(9): 1738-1747.
- [7] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313 (5786): 504-507.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [9] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups[J]. IEEE Signal Processing Magazine, 2012, 29(6): 82-97.
- [10] CHEN Y, LIN Z, ZHAO X, et al. Deep learning-based classification of hyperspectral data[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2094-2107.
- [11] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18 (7): 1527-1554.
- [12] LI X, LEGLAIVE S, GIRIN L, et al. Audio-noise power spectral density estimation using long short-term memory[J]. IEEE Signal Processing Letters, 2019, 26(6): 918-922.
- [13] GOODFELLOW I, POUGETABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems . Montreal, Canada: [s.n.], 2014: 2672-2680.
- [14] WANG X, HUANG G, ZHOU Z, et al. Radar emitter recognition based on the short time Fourier transform and convolutional neural networks[C]//Proceedings of the 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI). [S.l.]: IEEE, 2017: 1-5.
- [15] WANG D L, CHEN J. Supervised speech separation based on deep learning: An overview[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2018, 26(10): 1702-1726.
- [16] WILLIAMSON D S, WANG Y, WANG D L. Complex ratio masking for monaural speech separation[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2015, 24(3): 483-492.
- [17] SCHMIDHUBER J. Deep learning in neural networks: An overview[J]. Neural Networks, 2015, 61: 85-117.
- [18] 李梓瑜, 葛芬, 张劲东, 等. 基于深度强化学习的雷达智能抗干扰决策 FPGA 加速器设计[J]. 数据采集与处理, 2023, 38(5): 1151-1161.
LI Ziyu, GE Fen, ZHANG Jindong, et al. Design of FPGA accelerator for radar intelligent anti-interference decision based on deep reinforcement learning [J]. Data Acquisition and Processing, 2023, 38(5): 1151-1161.
- [19] 李璐, 李泽宇, 冯超. 基于一维卷积神经网络的 HRRP 雷达目标分类方法[J]. 火控雷达技术, 2023, 52(4): 143-147.
LI Lu, LI Zeyu, FENG Chao. A target classification method for HRRP radar based on one-dimensional convolutional neural network [J]. Fire Control Radar Technology, 2023, 52(4): 143-147.
- [20] 殷和义, 郭尊华. 一维卷积神经网络用于雷达高分辨率距离像识别[J]. 电讯技术, 2018, 58(10): 1121-1126.
YIN Heyi, GUO Zunhua. One-dimensional convolutional neural network for radar high-resolution range image recognition[J]. Telecommunication Technology, 2018, 58(10): 1121-1126.
- [21] SHAO G, CHEN Y, WEI Y. Convolutional neural network-based radar jamming signal classification with sufficient and

limited samples[J]. IEEE Access, 2020, 8: 80588-80598.

- [22] JUNFEI Y, JINGWEN L, BING S, et al. Barrage jamming detection and classification based on convolutional neural network for synthetic aperture radar[C]//Proceeding of IGARSS 2018 IEEE International Geoscience and Remote Sensing Symposium. [S.l.]: IEEE, 2018: 4583-4586.

- [23] 张翼鹏, 卢东东, 仇晓兰, 等. 基于散射点拓扑和双分支卷积神经网络的 SAR 图像小样本舰船分类[J]. 雷达学报, 2024, 13(2): 411-427.

ZHANG Yipeng, LU Dongdong, QIU Xiaolan, et al. SAR image ship classification with small sample using scatter point topology and dual-branch convolutional neural network[J]. Journal of Radar, 2024, 13(2): 411-427.

- [24] LIU J, GONG M, ZHANG M, et al. An anti-jamming method in multistatic radar system based on convolutional neural network[J]. IET Signal Processing, 2022, 16(2): 220-231.

作者简介:



赵珊珊(1989-), 通信作者, 女, 副教授, 硕士生导师, 研究方向: 雷达信号处理、雷达自适应抗干扰技术和阵列信号处理等, E-mail: zss@njupt.edu.cn。



申琦(2000-), 男, 硕士研究生, 研究方向: 雷达信号处理、多传感器数据融合等, E-mail: Shinqii@163.com。



苗嘉宁(2000-), 女, 硕士研究生, 研究方向: 雷达信号处理、宽带雷达抗干扰技术等, E-mail: miaojianing2021@163.com。

(编辑: 陈琚)