



(12) 发明专利申请

(10) 申请公布号 CN 114429156 A

(43) 申请公布日 2022. 05. 03

(21) 申请号 202210073080.8

(22) 申请日 2022.01.21

(71) 申请人 西安电子科技大学  
地址 710071 陕西省西安市太白南路2号

(72) 发明人 张鹏 李亚超 常星烁 王志伟  
郭亮 陈洪猛 陶慧斌 苏毅

(74) 专利代理机构 陕西电子工业专利中心  
61205

代理人 程晓霞 王品华

(51) Int. Cl.

G06K 9/00 (2022.01)

G06K 9/62 (2022.01)

G06N 3/04 (2006.01)

G06N 3/08 (2006.01)

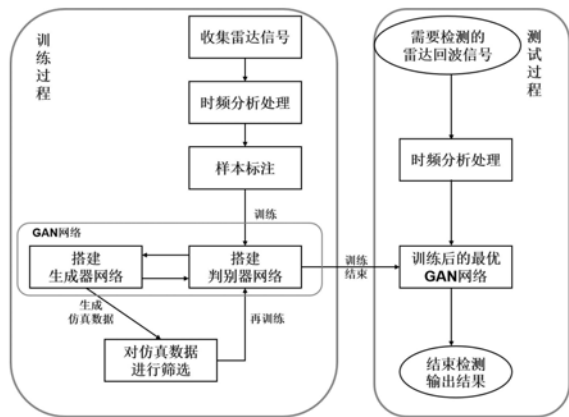
权利要求书3页 说明书17页 附图3页

(54) 发明名称

雷达干扰多域特征对抗学习与检测识别方法

(57) 摘要

本发明公开一种雷达干扰多域特征对抗学习与检测识别方法,解决了雷达信号一维信息信息量不足和准确率依赖于庞大数据集的问题。实现步骤:收集雷达信号;时频分析获取数据集;对无干扰和带干扰的时频数据集样本标注;构建生成器和判别器,组成GAN网络;利用时频数据集对GAN网络训练获取生成图像并筛选用于再训练;GAN网络计算无干扰和有源干扰类型概率;获取检测结果。本发明通过时频分析处理获取雷达信号二维时频信息,通过生成对抗网络训练,大大提高了有无干扰和有源干扰类型检测的准确率,同时通过生成器获取生成图像补充训练集,减小对训练数据数量的需求。用于对雷达信号进行有无干扰检测以及有源干扰类型识别。



1. 一种雷达干扰多域特征对抗学习与检测识别方法,其特征在于,利用时频分析处理,获取原始雷达信号的二维时频域特征;利用生成对抗网络GAN,获取生成图像并筛选生成图像以扩充数据集;利用生成对抗网络GAN,计算雷达信号有无干扰和有源干扰类型的概率,包括有如下步骤:

(1) 收集无干扰和带干扰的雷达信号:收集或仿真一定数量的无干扰和带各类型干扰的雷达信号,作为训练GAN网络所需数据集的基础数据;

(2) 通过时频分析处理获取时频图数据集:对收集的雷达信号进行短时傅里叶变换、取模、对数变换、移动零频点和着色处理得到无干扰和带干扰的雷达信号的时频图数据集;

(3) 对无干扰和带干扰的时频图数据集进行样本标注,并划分训练集和验证集:基于任务需要,对收集或仿真的复杂雷达信号进行分类,首先将收集或仿真的雷达信号分为有干扰信号和无干扰信号;然后将有干扰雷达信号再细分为4种常见的有源干扰样式的雷达信号,对于已分类的无干扰信号以及4种有源干扰信号进行样本标注;最后在每一类信号中设置一定的比例分为训练集数据和验证集数据,将所有的训练集数据进行整合形成训练集,将所有验证集数据进行整合形成验证集;

(4) 构建生成对抗网络GAN的生成器:以经典生成对抗网络GAN的生成器为基础,构建适应数据集图片尺寸的生成器;构建的生成器中包括一个全连接层,以及与全连接层相连接的多个串联的转置卷积层,该转置卷积层是由转置卷积、归一化和激活三种运算依次进行的;

(5) 构建生成对抗网络GAN的判别器,组成生成对抗网络GAN:以经典生成对抗网络GAN的判别器为基础,构建适应数据集图片尺寸的判别器;判别器的结构包括多个串联的卷积层,以及与最后一个卷积层连接的全连接层和与全连接层连接的分类层,其中的卷积层是由卷积、激活和归一化三种运算依次进行的;生成对抗网络GAN的生成器和判别器之间进行数据交互组成了生成对抗网络GAN;

(6) 利用时频图数据集对GAN网络进行训练,并生成大量生成图像:基于已构建的生成对抗网络GAN,首先,分别构建GAN网络生成器的损失函数和判别器的损失函数,对生成器和判别器的性能进行定量描述;然后构建网络的训练目标函数作为网络训练的优化方向;最后基于上述函数对GAN网络生成器和判别器进行训练,并利用纳什均衡状态判定方法得到最优的GAN网络;通过最优GAN网络的生成器生成大量的生成图像;

(7) 对生成的生成图像进行筛选,用以扩充数据集并进行再训练:首先利用生成对抗网络GAN的生成器产生大量的生成图像,针对生成图像的质量参差不齐利用数据多样性评估进行筛选,然后再利用KL距离方法进行筛选,获取与真实数据具有相似特征的生成图像;然后将这类生成图像加入训练集中;最后对生成对抗网络GAN进行再训练,获取最终的训练权重和GAN网络;

(8) 利用GAN网络计算无干扰和有源干扰类型的概率:将验证集中雷达信号某个回波的时频图,即雷达信号根据步骤(2)中时频分析处理的过程进行时频分析处理得到的某个回波的时频图输入到训练好的GAN网络中,即可获得该回波不存在干扰的概率,以及存在各类型有源干扰的概率;

(9) 获取检测结果:利用多分类法判断是否存在干扰以及存在干扰时有源干扰的类型,如果输出概率结果中概率最大的类型为无干扰类型,则认定该回波不存在干扰;否则,认定

该雷达信号的回波存在干扰,并取计算出的有源干扰类型概率中最大的概率值,其对应的有源干扰类型认定为该回波存在的有源干扰类型;结束检测识别,将是否存在干扰的判断结果和存在干扰时有源干扰的类型输出,完成检测识别。

2. 根据权利要求1所述的雷达干扰多域特征对抗学习与检测识别方法,其特征在于,步骤(2)中所述的通过时频分析处理获取时频图数据集,包括由如下步骤:

(2.1) 对雷达信号进行短时傅里叶变换:对雷达信号的每一个回波进行短时傅里叶变换,获取雷达信号的二维时频域特征,存储为二维时频数据 $y(m,n)$ ,短时傅里叶变换公式为:

$$y(m,n) = \sum_{n=-\infty}^{\infty} x(n)w(n-mR)e^{-j\omega n}$$

其中, $x(n)$ 表示雷达信号, $n$ 为雷达信号的长度, $m$ 为短时傅里叶变换的长度, $w(k)$ 表示窗函数, $k$ 为窗函数的长度,使用的窗函数是Hamming窗,窗函数长度为 $i$ 的Hamming窗的计算公式如下式所示:

$$w(k) = 0.54 - 0.46 \cos(2\pi k / (i-1)), k=0, 1, \dots, i-1$$

(2.2) 对二维时频数据取模值:二维时频数据为复数据,不利于存储为图片;对雷达信号的二维时频数据进行取模,求取 $y(m,n)$ 中每个元素的模值,获取时频域图像 $\tilde{y}$ :

$$\tilde{y}(k_1, k_2) = \|y(k_1, k_2)\|_2, \quad k_1 = 0, 1, \dots, m-1 \quad k_2 = 0, 1, \dots, n-1$$

其中, $\|\cdot\|_2$ 表示求复数的二范数;

(2.3) 对时频域图像进行对数变换:对时频域图像进行对数变换的预处理,增强成像效果得到增强时频域图像 $F(m,n)$ :

$$F(m,n) = 10 * \log_e(\tilde{y}(m,n) + 10)$$

(2.4) 移动零频点:将增强时频域图像 $F(m,n)$ 的零频点移动到频谱中间,获得移动零频点后的图像 $\tilde{F}(m,n)$ :

$$\tilde{F}(m,n) = \text{fftshift}(F(m,n))$$

其中, $\text{fftshift}(x)$ 表示将时频图像 $x$ 的 $[f_s/2, f_s]$ 部分移动到 $[-f_s/2, 0]$ 的范围内, $f_s$ 表示时频图像 $x$ 的最高频率;

(2.5) 对时频域图像进行着色处理:对移动零频点后的图像 $\tilde{F}(m,n)$ 进行成像,使用专用的时频图成像方法对 $\tilde{F}(m,n)$ 进行着色处理,获取最终的时频图数据集。

3. 根据权利要求1所述的雷达干扰多域特征对抗学习与检测识别方法,其特征在于,步骤(6)中所述的分别构建GAN网络生成器的损失函数和判别器的损失函数可综合表示为下式,提高损失函数的计算效率:

$$\min_G \max_D L(D, G) = E_{x \sim p(\text{data})} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))]$$

其中 $x$ 表示真实输入, $z$ 表示生成模型的输入数据, $G(z)$ 表示生成的图片, $D(x)$ 表示网络 $D$ 判断图片是否真实的概率与相应的类别,越接近1代表真实性越高;输入随机向量 $z$ 会在生成模型 $G$ 中生成符合真实概率分布 $P$ 的对应样本 $G(z)$ ,判别模型 $G$ 用来判断输入数据的真实性,生成模型和判别模型都是多层感知器的非线性映射函数。

4. 根据权利要求1所述的雷达干扰多域特征对抗学习与检测识别方法,其特征在于,步骤(7)中所述的针对生成图像的质量参差不齐利用数据多样性评估进行筛选,包括有如下步骤:

(7.1) 计算生成图像与训练集图像的相似度:

$$I(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}$$

$$C(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2}$$

$$S(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}$$

其中, X表示生成图像, Y表示训练集图像,  $I(X, Y)$  为亮度相似性,  $C(X, Y)$  为对比度相似性,  $S(X, Y)$  为结构相似性,  $\mu_X$  为图像X的均值,  $\mu_Y$  为图像Y的均值;  $\sigma_X$  为图像X的标准差,  $\sigma_Y$  为图像Y的标准差;  $\sigma_{XY}$  为图像X和Y的协方差,  $C_1$  为亮度相似性常数,  $C_2$  为对比度相似性常数,  $C_3$  为结构相似性常数, 一般取  $C_1 = (K_1L)^2$ ,  $C_2 = (K_2L)^2$ ,  $C_3 = \frac{C_2}{2}$ ;  $K_1 = 0.01$ ,  $K_2 = 0.03$ ,  $L = 255$ ;

(7.2) 计算生成图像与训练集图像的多层级结构相似性:

$$MS-SSIM(X, Y) = [l_m(X, Y)]^{\alpha_m} \prod_{i=1}^M [C_i(X, Y)]^{\beta_i} [S_i(X, Y)]^{\gamma_i}$$

其中,  $MS-SSIM(X, Y)$  为多层级结构相似性指标,  $C_i(X, Y)$  和  $S_i(X, Y)$  是利用迭代方法对图像进行低通滤波和降采样, 在每一个尺度上分别计算出对比度相似性和结构相似性指标,  $l_m(X, Y)$  是在最终的尺度M上计算的亮度相似性指标, M表示在迭代滤波和下采样中使用的卷积数,  $\alpha_m$  用于调整亮度相似性的相对重要性,  $\beta_i$  用于调整对比度相似性的相对重要性,  $\gamma_i$  用于调整结构相似性的相对重要性;

(7.3) 根据  $MS-SSIM(X, Y)$  值的特点筛选生成图像:  $MS-SSIM(X, Y)$  值越小代表数据集多样性越高,  $MS-SSIM(X, Y)$  值越大代表数据集多样性越低; 将丢弃  $MS-SSIM(X, Y)$  值较小的生成图像, 保留  $MS-SSIM(X, Y)$  值适当大的数据用以下一轮筛选, 以提高数据集的多样性。

## 雷达干扰多域特征对抗学习与检测识别方法

### 技术领域

[0001] 本发明属于信号处理技术领域,更进一步涉及雷达信号处理技术领域中的干扰检测识别,具体是一种雷达干扰多域特征对抗学习与检测识别方法。本发明可用于对雷达信号进行有无干扰检测以及有源干扰类型识别。

### 背景技术

[0002] 雷达干扰是破坏和扰乱敌方雷达检测目标的重要手段,可以分为有源干扰和无源干扰。其中,雷达有源干扰针对性更强,破坏性更大,给雷达探测目标带来了严峻的挑战。有源干扰检测识别是抑制雷达有源干扰的第一步,可以分为有无干扰检测和有源干扰类型识别,有无干扰检测是进行有源干扰类型识别的前提,其用于检测雷达回波中是否存在影响信号的干扰存在;有源干扰类型识别是对存在干扰的回波进行干扰类型判断,在压制式干扰、重复转发式干扰、假目标式干扰等多种干扰类型中,确定该回波存在的干扰类型。有源干扰检测识别是雷达抗干扰系统的重要组成部分,其结果直接决定了抗干扰系统对干扰抑制算法的选择,影响到最终的干扰抑制结果。

[0003] 现阶段的雷达有源干扰类型检测识别多停留在对信号的瞬时幅度、频率、相位等信息进行处理,进而对有源干扰类型进行判断。面对日益复杂的干扰环境,仅对信号的一维信息进行处理已无法满足有源干扰检测识别的要求,进而需要对信号进行短时傅里叶变换得到包含更多可用信息的二维时频图。

[0004] 专利CN113534059A(“开集场景下基于深度卷积网络的雷达有源干扰识别方法”)介绍了一种利用深度学习的有源干扰识别方法,其通过深度学习获取有源干扰信号的后验分布,然后通过计算置信分数来实现干扰识别。该方法直接使用信号的一维信息进行训练,对复杂多变的有源干扰适应能力较弱,无法满足日益复杂干扰环境下的有源干扰识别的要求。

[0005] 专利CN113759320A(“基于递归图和深度学习的雷达有源干扰信号识别方法”)介绍了一种基于递归图和深度学习的识别方法,通过采用仿真的方式构建大量的不同类别的干扰仿真信号,并将各一维的干扰仿真信号均转换为二维递归图,利用深度学习进行训练和预测。该方法的精度依赖于庞大的干扰仿真信号数据集,在实际应用中难以收集到大量的雷达信号作为数据集,不能保证该方法的识别准确率。

[0006] 综上,现有的雷达有源干扰信号检测识别方法中存在着适应能力差,仅利用雷达信号一维信息导致信息量不足,以及识别准确率依赖于庞大的数据集的问题。

### 发明内容

[0007] 本发明的目的在于针对现有技术的不足,提出了一种利用信号二维时频域信息的基于对抗学习的雷达干扰多域特征的检测与识别方法。

[0008] 本发明是一种雷达干扰多域特征对抗学习与检测识别方法,其特征在于,利用时频分析处理,获取原始雷达信号的二维时频域特征;利用生成对抗网络GAN,获取生成图像

并筛选生成图像以扩充数据集;利用生成对抗网络GAN,判断雷达信号有无干扰并计算有源干扰类型的概率,包括有如下步骤:

[0009] (1) 收集无干扰和带干扰的雷达信号:收集或仿真一定数量的无干扰和带各类型干扰的雷达信号,作为训练GAN网络所需数据集的基础数据;

[0010] (2) 通过时频分析处理获取时频图数据集:对收集的雷达信号进行短时傅里叶变换、取模、对数变换、移动零频点和着色处理得到无干扰和带干扰的雷达信号的时频图数据集;

[0011] (3) 对无干扰和带干扰的时频图数据集进行样本标注,并划分训练集和验证集:基于任务需要,对收集或仿真的复杂雷达信号进行分类,首先将收集或仿真的雷达信号分为有干扰信号和无干扰信号;然后将有干扰雷达信号再细分为4种常见的有源干扰样式的雷达信号,对于已分类的无干扰信号以及4种有源干扰信号进行样本标注;最后在每一类信号中设置一定的比例分为训练集数据和验证集数据,将所有的训练集数据进行整合形成训练集,将所有验证集数据进行整合形成验证集;

[0012] (4) 构建生成对抗网络GAN的生成器:以经典生成对抗网络GAN的生成器为基础,构建适应数据集图片尺寸的生成器;构建的生成器中包括一个全连接层,以及与全连接层相连接的多个串联的转置卷积层,该转置卷积层是由转置卷积、归一化和激活三种运算依次进行的;

[0013] (5) 构建生成对抗网络GAN的判别器,组成生成对抗网络GAN:以经典生成对抗网络GAN的判别器为基础,构建适应数据集图片尺寸的判别器;判别器的结构包括多个串联的卷积层,以及与最后一个卷积层连接的全连接层和与全连接层连接的分类层,其中的卷积层是由卷积、激活和归一化三种运算依次进行的;生成对抗网络GAN的生成器和判别器之间进行数据交互组成了生成对抗网络GAN;

[0014] (6) 利用时频图数据集对GAN网络进行训练,并生成大量生成图像:基于已构建的生成对抗网络GAN,首先,分别构建GAN网络生成器的损失函数和判别器的损失函数,对生成器和判别器的性能进行定量描述;然后构建网络的训练目标函数作为网络训练的优化方向;最后基于上述函数对GAN网络生成器和判别器进行训练,并利用纳什均衡状态判定方法得到最优的GAN网络;通过最优GAN网络的生成器生成大量的生成图像;

[0015] (7) 对生成的生成图像进行筛选,用以扩充数据集并进行再训练:首先利用生成对抗网络GAN的生成器产生大量的生成图像,针对生成图像的质量参差不齐利用数据多样性评估进行筛选,然后再利用KL距离方法进行筛选,获取与真实数据具有相似特征的生成图像;然后将这类生成图像加入训练集中;最后对生成对抗网络GAN进行再训练,获取最终的训练权重和GAN网络;

[0016] (8) 利用GAN网络计算无干扰和各类有源干扰类型的概率:将验证集中雷达信号某个回波的时频图,即雷达信号根据步骤(2)中时频分析处理的过程进行时频分析处理得到的某个回波的时频图输入到训练好的GAN网络中,即可获得该回波不存在干扰的概率,以及存在各类型有源干扰的概率;

[0017] (9) 获取检测结果:利用多分类法判断是否存在干扰以及存在干扰时有源干扰的类型,如果输出概率结果中概率最大的类型为无干扰类型,则认定该回波不存在干扰;否则,认定该回波存在干扰,并取计算出的有源干扰类型概率中最大的概率值,其对应的有源

干扰类型认定为该回波存在的有源干扰类型;结束检测识别,将是否存在干扰的判断结果和存在干扰时有源干扰的类型输出,完成检测识别。

[0018] 利用时频分析处理获取雷达信号的二维时频域信号,解决了仅利用雷达信号一维信息导致信息量不足的问题;利用GAN网络生成对抗学习的过程解决了适应性差的问题,利用GAN网络的生成器获取生成图像扩充数据集,解决了准确率依赖于庞大的数据集的问题。

[0019] 本发明与现有的技术相比具有以下优点:

[0020] 利用雷达信号二维时频信息提高准确性,由于本发明采用了时频分析处理的方法获取雷达信号的二维时频信息,克服了现有技术仅使用雷达信号一维信息提取特征判断是否存在干扰以及有源干扰类型时准确率低的问题。本发明利用雷达信号的二维时频信息,从图像域的方向出发,采用机器学习的方法来提取各类型有源干扰的特征信息,提高了对有无干扰和有源干扰类型判断的准确性。

[0021] 利用GAN网络生成器获取生成图像并扩充数据集,由于本发明采用了生成对抗网络GAN作为特征提取和判别网络,其特有的生成器可以模拟生成与原始数据有相似特征的生成图像,并扩充数据集,克服了现有机器学习技术对训练数据量要求大,雷达信号数据难收集的问题,使得本发明利用有限多的数据来进行网络的构建和训练。

## 附图说明

[0022] 图1为本发明的流程图;

[0023] 图2为采用本发明方法对干信比为10db的时频图数据进行训练所使用的训练数据和所生成的生成图像;其中图2(a)是无干扰时频图,图2(b)是窄带瞄频式干扰时频图,图2(c)是分段线性式干扰时频图、图2(d)是间歇转发式干扰时频图,图2(e)是重复转发式干扰时频图,图2(f)是窄带瞄频式干扰生成时频图,图2(g)是分段线性式干扰生成时频图、图2(h)是间歇转发式干扰生成时频图,图2(i)是重复转发式干扰生成时频图。

[0024] 图3为采用本发明方法对干信比为20db的时频图数据进行训练所使用的训练数据和所生成的生成图像;其中图3(a)是无干扰时频图,图3(b)是窄带瞄频式干扰时频图,图3(c)是分段线性式干扰时频图、图3(d)是间歇转发式干扰时频图,图3(e)是重复转发式干扰时频图,图3(f)是窄带瞄频式干扰生成时频图,图3(g)是分段线性式干扰生成时频图、图3(h)是间歇转发式干扰生成时频图,图3(i)是重复转发式干扰生成时频图。

## 具体实施方式

[0025] 下面结合附图对本发明详细描述。

[0026] 实施例1

[0027] 现有的对雷达有源干扰信号的检测和识别方法中,要么是通过利用信号的一维信息进行特征提取和卷积网络训练,要么仿真大量的数据作为数据集实现对有源干扰的准确识别,但是在现今日益复杂干扰环境下,雷达信号的一维信息已无法满足检测的需要,真实的雷达信号也难以形成大规模的数据集。针对这些问题,本发明展开研究与实验,提出了一种基于对抗学习的雷达干扰多域特征的检测与识别方法,对本发明的具体实施步骤详细描述。

[0028] 本发明是一种雷达干扰多域特征对抗学习与检测识别方法,参照图1,图1是本发

明的流程框图,本发明利用时频分析处理,获取原始雷达信号的二维时频域特征;利用生成对抗网络GAN,获取生成图像并筛选生成图像以扩充数据集;利用生成对抗网络GAN,计算雷达信号有无干扰和有源干扰类型的概率,包括有如下步骤:

[0029] (1) 收集无干扰和带干扰的雷达信号:收集或仿真一定数量的无干扰和带各类型干扰的雷达信号,作为训练GAN网络所需数据集的基础数据。训练数据是网络的基础,因此收集到的各类带干扰的雷达信号中干扰信号的位置应有一定的变化,干扰信号的强度和覆盖范围也应有所不同。

[0030] (2) 通过时频分析处理获取时频图数据集:对收集的雷达信号进行短时傅里叶变换、取模、对数变换、移动零频点和着色处理得到无干扰和带干扰的雷达信号的时频图数据集。通过时频分析处理将雷达信号的时域信息和频域信息进行关联,获取到雷达信号的二维时频域信息,相对于单纯的一维信息的特征提取过程,二维时频域信息具有更多的可用信息,十分有利于有源干扰类型的识别。

[0031] (3) 对无干扰和带干扰的时频图数据集进行样本标注,并划分训练集和验证集:基于任务需要,对收集或仿真的复杂雷达信号进行分类,首先将收集或仿真的雷达信号分为有干扰信号和无干扰信号;然后将有干扰雷达信号再细分为4种常见的有源干扰样式的雷达信号,对于已分类的无干扰信号以及4种有源干扰信号进行样本标注;最后在每一类信号中设置一定的比例分为训练集数据和验证集数据,将所有的训练集数据进行整合形成训练集,将所有验证集数据进行整合形成验证集。具体包括有如下步骤:

[0032] (3a) 根据任务需求定义有源干扰类型,例如本发明定义有源干扰分别为窄带瞄频式干扰、分段线性式干扰、间歇转发式干扰、重复转发式干扰;首先将无干扰信号组成无干扰数据集,然后将获取的其他时频图数据集根据各个干扰类型进行分类,获取各种有源干扰类型数据集,无干扰数据集和各种有源干扰类型数据集共同组成了基础数据集。

[0033] (3b) 对已获取的基础数据集进行随机抽取,抽取每一类数据集20%的数据构建验证集,剩余的数据进行整合作为训练集,并将训练集的数据打乱,以便在训练网络时更好的使用,上述中抽取比例20%可以根据需求进行适当变化。

[0034] (4) 构建生成对抗网络GAN的生成器:以经典生成对抗网络GAN的生成器为基础,构建适应数据集图片尺寸的生成器;构建的生成器中包括一个全连接层,以及与全连接层相连接的多个串联的转置卷积层,该转置卷积层是由转置卷积、归一化和激活三种运算依次进行的。具体包括有如下步骤:

[0035] (4a) 取一个随机噪声向量 $z$  (长度为100) 以及对应的标签 $c$  (长度为5),将噪声 $z$ 与标签 $c$ 同时输入全连接层 $f_c(\cdot)$ 。

[0036]  $x_1 = f_c(z, c)$

[0037] (4b) 按以下公式对 $x_1$ 进行转置卷积转换:

[0038]  $x_2 = \text{ConvT}(x_1) \in R^{k_1 \times k_2 \times l}$

[0039] 其中 $\text{ConvT}(\cdot)$ 为转置卷积函数, $k_1 \times k_2$ 为卷积核的大小, $l$ 为卷积核的数量。

[0040] (4c) 按以下公式对转换后的结果进行批归一化:

[0041]  $x_3 = \text{BN}(x_2) = \frac{x_2 - \mu}{\sqrt{\sigma^2 + \epsilon}}$

[0042] 其中 $\text{BN}(\cdot)$ 为批量归一化函数, $\mu$ 为该批次样本的平均值, $\sigma^2$ 为样本的方差, $\epsilon$ 项是



为了保持数值稳定性,一般设置为较小的正常数。

[0043] (4d) 按以下公式对批归一化后的结果进行激活:

$$[0044] \quad x_4 = \text{LeakyReLU}(x_3) = \begin{cases} x_3, x_3 > 0 \\ \alpha x_3, x_3 < 0, \alpha = 0.1 \end{cases}$$

[0045] 其中,  $x_4$  为输入向量通过一个卷积层后的卷积结果。

[0046] (4e) 重复上述 (4b) (4c) (4d) 步骤,直至卷积输出结果  $x_k$  与图片大小相同。

[0047] (4f) 按以下公式对  $x_k$  使用激活函数  $\tanh(\cdot)$ :

$$[0048] \quad y = \tanh(x_k) = \frac{e^{x_k} - e^{-x_k}}{e^{x_k} + e^{-x_k}}$$

[0049] 其中  $y$  即为生成器生成的最终结果。

[0050] 生成对抗网络GAN的生成器不仅能与判别器进行对抗学习,快速的提高对无干扰和各类有源干扰类型的识别准确率。同时,生成器自身会生成以假乱真的生成图像,对生成图像合理的利用可以有效的扩充数据集,减少对原始收集数据数量的要求。因此,使用生成对抗网络GAN的生成器是提高对无干扰和各类有源干扰类型识别准确率的重要一环。

[0051] (5) 构建生成对抗网络GAN的判别器,组成生成对抗网络GAN:以经典生成对抗网络GAN的判别器为基础,构建适应数据集图片尺寸的判别器;判别器的结构包括多个串联的卷积层,以及与最后一个卷积层连接的全连接层和与全连接层连接的分层,其中的卷积层是由卷积、激活和归一化三种运算依次进行的;生成对抗网络GAN的生成器和判别器之间进行数据交互组成了生成对抗网络GAN。具体包括有如下步骤:

[0052] (5a) 设训练集图片数量为  $N$  张,记为  $\{I_i\}_{i=1}^N \in R^{\text{row} \times \text{col}}$ ,其中  $\text{row}$ 、 $\text{col}$  分别为图片的长和宽,  $I_i$  为第  $i$  张图片,  $i = 1, 2, \dots, N$ 。

[0053] (5b) 按以下公式对每张训练图片进行卷积操作:

$$[0054] \quad q_1 = \text{Conv}(I_i) \in R^{(\text{row}-k_1+1)/s \times (\text{col}-k_2+1)/s}$$

[0055] 其中  $\text{Conv}(\cdot)$  为卷积函数,  $k_1 \times k_2$  为卷积核的大小,  $s$  为步长,  $1$  为卷积核的数量。

[0056] (5c) 按以下公式对卷积后的结果使用激活函数  $\text{LeakyReLU}(\cdot)$ :

$$[0057] \quad q_2 = \text{LeakyReLU}(q_1) = \begin{cases} q_1, q_1 > 0 \\ \alpha q_1, q_1 < 0, \alpha = 0.1 \end{cases}$$

[0058] (5d) 按以下公式对转换后的结果进行批归一化:

$$[0059] \quad q_3 = \text{BN}(q_2) = \frac{q_2 - \mu}{\sqrt{\sigma^2 + \varepsilon}}$$

[0060] 其中  $q_3$  为训练图片通过一个卷积层后的卷积结果,  $\mu$  为该批次样本的平均值,  $\sigma^2$  为样本的方差,  $\varepsilon$  项是为了保持数值稳定性,主要为了避免被零除,一般设置为较小的正常数。

[0061] (5e) 重复上述 (5b) (5c) (5d) 步骤,直至卷积输出结果  $q_k$  的尺寸与卷积核尺寸相同。

[0062] (5f) 将卷积得到的结果  $q_k$  输入全连接层  $f_c(\cdot)$ 。

$$[0063] \quad s = f_c(q_k)$$

[0064] (5g) 按以下公式对全连接后的结果进行二分类。

[0065]  $validity = Sigmoid(s) = \frac{1}{1 + e^{-s}}$

[0066] 其中Sigmoid(·)为二分类器,目的是为了判断输入图片来源于训练集还是生成器。

[0067] (5h)按以下公式对全连接后的结果进行多分类:

[0068]  $label = Softmax(s) = \frac{e^s}{\sum_j e^j}$

[0069] 其中Softmax(·)为多分类器,label为输入时频图不存在有源干扰以及存在的有源干扰所属各类型的概率。

[0070] (6)利用时频图数据集对GAN网络进行训练,并生成大量生成图像:基于已构建的生成对抗网络GAN,首先,分别构建GAN网络生成器的损失函数和判别器的损失函数,对生成器和判别器的性能进行定量描述;然后构建网络的训练目标函数作为网络训练的优化方向;最后基于上述函数对GAN网络生成器和判别器进行训练,并利用纳什均衡状态判定方法得到最优的GAN网络;通过最优GAN网络的生成器生成大量的生成图像。具体包括有如下步骤:

[0071] (6a)按以下公式构建生成器损失函数:

[0072]  $\min_G L(D, G) = E_{z \sim p(z)}[\log(1 - D(G(z)))]$

[0073] 其中z表示生成模型的输入数据,p(z)是定义在低维的噪声分布,G(z)表示生成的图片,D(x)表示网络D判断图片是否真实的概率与相应的类别,越接近1代表真实性越高,生成器的能力越好。

[0074] (6b)按以下公式构建判别器损失函数:

[0075]  $\max_D L(D, G) = E_{x \sim p(data)}[\log D(x)] + E_{z \sim p(z)}[\log(1 - D(G(z)))]$

[0076] 其中x表示真实输入,p(data)是真实的样本分布,p(z)是定义在低维的噪声分布,G(z)表示生成的图片,D(x)表示网络D判断图片是否真实的概率与相应的类别,越接近1代表分类正确率高,判别器的分类能力越强。

[0077] (6c)按以下公式构建训练目标函数:

[0078]  $L_S = E[\log P(S = \text{real} | X_{\text{real}})] + E[\log P(S = \text{fake} | X_{\text{fake}})]$

[0079]  $L_C = E[\log P(C = c | X_{\text{real}})] + E[\log P(C = c | X_{\text{fake}})]$

[0080] 其中 $L_S$ 为正确的输入数据来源的最大似然估计, $L_C$ 为正确的输入数据类别的最大似然估计,c为生成器与判别器收到的类别标签,s=real代表数据来源于真实图像,s=fake代表数据来源于生成图像, $X_{\text{fake}} = G(z)$ 为生成器的输出, $X_{\text{fake}}$ 为真实图像输入,P(S|X)代表在输入为X的条件下数据来源的概率,P(C|X)代表在输入为X的条件下数据类别的概率。

[0081] 生成器的训练目标为 $\min(L_C - L_S)$ ;判别器的训练目标为 $\max(L_C + L_S)$ 。

[0082] (6d)按以下过程训练生成器:固定判别器,训练生成器:使用生成-判别网络串接进行训练,生成网络通过前向传播可以学习建模真实数据的分布规律;固定判别网络的参数不使其发生变化,选取指定干扰类型的潜在变量作为生成器的输入,生成干扰数据,并由判别器进行判别,判别器将判别结果返回生成网络,计算对应的损失函数梯度进行反向传

播更新网络参数。

[0083] (6e) 按以下过程训练判别器:固定生成器,训练判别器:根据生成对抗模型结构,选取指定干扰类型的潜在变量作为生成器的输入,从数据集中选取真实干扰数据,使得判别器能够估算数据集中选出的真实数据概率,计算损失函数反向传播,因为生成器的参数是固定的,所以返回的损失函数只与判别器的参数有关,不断调整判别器的参数来优化判别器。

[0084] (6f) 训练结束时的纳什均衡状态判定:随着训练过程的继续,当生成器可以生成与真实干扰时频图像最相似的虚假数据,并且判别器无法区分虚假数据与真实数据时,即判别器判断真实来源的概率接近0.5,生成器与判别器在理论上都将获得最优化的结果,当且仅当 $P_{data} = P_{G(z)}$ 时达到全局最优解;此时可以认为整个网络达到了纳什均衡条件,生成器可以生成与真实干扰时频图像最接近的虚假数据,判别器可以获得最佳的判断能力,训练结束。

[0085] (6g) 利用GAN网络的生成器获取生成图像:在获取最优的GAN网络后,利用最优GAN网络的生成器随机生成大量的无干扰和各种有源干扰类型的生成图像。

[0086] (7) 对生成的生成图像进行筛选,用以扩充数据集并进行再训练:首先利用生成对抗网络GAN的生成器产生大量的生成图像,针对生成图像的质量参差不齐利用数据多样性评估进行筛选,然后再利用KL距离方法进行筛选,获取与真实数据具有相似特征的生成图像;然后将这类生成图像加入训练集中;最后对生成对抗网络GAN进行再训练,获取最终的训练权重和GAN网络。具体包括有如下步骤:

[0087] (7a) 对生成图像进行多样性评估与筛选。

[0088] (7b) 按以下公式对生成图像根据KL距离进行筛选。

$$[0089] \quad D(P||Q) = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)}$$

[0090] 其中 $D(P||Q)$ 为KL距离度量值, $p(x)$ 为生成图像, $q(x)$ 为真实图像;根据KL距离度量值,去除 $D(P||Q)$ 值较大的生成图像,保留与真实数据有相似特征的数据。

[0091] (7c) 将筛选出的优良生成图像加入训练集中,按步骤(6)利用时频图数据集对GAN网络进行训练的过程对生成对抗网络GAN进行再训练,直到得到最优的网络结构为止,得到训练好的GAN网络。

[0092] 筛选过程是保证生成图像质量的重要环节,通过筛选过程可以将与训练集数据结构特点差异较大的非优良数据进行剔除,还可以将与训练集数据十分雷同的生成图像进行剔除,保留质量较高的生成图像扩充数据集,实现在有限数据集上进行对无干扰和各类有源干扰类型的准确识别。

[0093] (8) 利用GAN网络计算无干扰和有源干扰类型的概率:将验证集中雷达信号某个回波的时频图,即雷达信号根据步骤(2)中时频分析处理的过程进行时频分析处理得到的某个回波的时频图输入到训练好的GAN网络中,即可获得该回波不存在干扰的概率,以及存在各类型有源干扰的概率。以此类推,将验证集中的所有时频图依次输入到GAN网络中,获得所有回波不存在干扰的概率,以及存在各类型有源干扰的概率。

[0094] (9) 获取检测结果:利用多分类法判断是否存在干扰以及存在干扰时有源干扰的类型,如果输出概率结果中概率最大的类型为无干扰类型,则认定该回波不存在干扰;否

则,认定该雷达信号的回波存在干扰,并取计算出的有源干扰类型概率中最大的概率值,其对应的有源干扰类型认定为该回波存在的有源干扰类型;结束检测识别,将是否存在干扰的判断结果和存在干扰时有源干扰的类型输出,完成检测识别。

[0095] 本发明给出了雷达干扰多域特征对抗学习与检测识别方法的整体技术方案,针对现有技术中存在着适应能力差,仅利用雷达信号一维信息导致信息量不足,以及识别准确率依赖于庞大的数据集的问题,本发明通过时频分析处理获取雷达信号的二维时频域信息来提升信息量,用GAN网络的生成器获取生成图像并扩充数据集,实现对数据集的补充。

[0096] 实现本发明目的的具体思路是:首先将收集到的雷达信号按每一回波进行时频分析处理,然后将获取到的时频图数据集进行样本标注并构建训练集与验证集。接着构建合适的生成对抗网络,再利用数据集对构建好的生成对抗网络进行训练,得到最小损失时的网络权值。然后利用生成对抗网络中的生成器生成一定数量的与原始数据特征相似的数据,并对生成的伪时频图数据进行筛选过滤,用上述筛选后的数据扩充原始数据集。最后利用扩充后的数据集对生成对抗网络进行再训练,得到最优的网络权重。在实际有源干扰识别中,只需将需要检测的回波进行时频分析处理,然后将其输入训练得到的生成对抗网络中,即可得到该回波是否存在干扰和有源干扰类型的检测结果。

[0097] 实施例2

[0098] 雷达干扰多域特征对抗学习与检测识别方法同实施例1,步骤(2)中的通过时频分析处理获取时频图数据集,包括由如下步骤:

[0099] (2.1)对雷达信号进行短时傅里叶变换:本发明对雷达信号的每一个回波进行短时傅里叶变换,获取雷达信号的二维时频域特征,存储为二维时频数据 $y(m,n)$ 。通过短时傅里叶变换可以将雷达信号的时域信息和频域信息进行结合,获取雷达信号的二维时频域复数据信息,使各类有源干扰的特征更加明显、更具有区分度。短时傅里叶变换公式为:

$$[0100] \quad y(m,n) = \sum_{n=-\infty}^{\infty} x(n)w(n-mR)e^{-j\omega n}$$

[0101] 其中, $x(n)$ 表示雷达信号, $n$ 为雷达信号的长度, $m$ 为短时傅里叶变换的长度, $w(k)$ 表示窗函数, $k$ 为窗函数的长度,本发明使用的窗函数是Hamming窗,窗函数长度为 $i$ 的Hamming窗的计算公式如下式所示:

$$[0102] \quad w(k) = 0.54 - 0.46\cos(2\pi k/(i-1)), k=0,1,\dots,i-1$$

[0103] (2.2)对二维时频数据取模值:二维时频数据为复数据,不利于存储为图片,也不利于卷积神经网络的训练;本发明对雷达信号的二维时频数据进行取模,二维时频数据的模值也能很好的体现出各有源干扰的特征,并可以转化为时频域图像进行存储,便于观察,有利于后续样本标注过程的实现,求取 $y(m,n)$ 中每个元素的模值,获取时频域图像 $\tilde{y}$ 。

$$[0104] \quad \tilde{y}(k_1, k_2) = \|y(k_1, k_2)\|_2, \quad k_1 = 0, 1, \dots, m-1 \quad k_2 = 0, 1, \dots, n-1$$

[0105] 其中, $\|\cdot\|_2$ 表示求复数的二范数。

[0106] (2.3)对时频域图像进行对数变换:对时频域图像进行对数变换的预处理,增强成像效果得到增强时频域图像 $F(m,n)$ 。

$$[0107] \quad F(m,n) = 10 * \log_e(\tilde{y}(m,n) + 10)$$

[0108] 雷达有源干扰信号在二维时频中模值一般较高,起伏较大,对数变换可以将起伏

较大的干扰信号的浮动范围进行压缩,使干扰信号在二维时频图上的形状更加清晰完整,便于人工对无干扰和各类有源干扰类型的标注,以及便于GAN网络更好的提取二维时频图中干扰信号的特征。

[0109] (2.4) 移动零频点:将增强时频域图像 $F(m,n)$ 的零频点移动到频谱中间,获得移动零频点后的图像 $\tilde{F}(m,n)$ 。

$$[0110] \quad \tilde{F}(m,n) = \text{fftshift}(F(m,n))$$

[0111] 其中,  $\text{fftshift}(x)$  表示将时频图像 $x$ 的 $[f_s/2, f_s]$ 部分移动到 $[-f_s/2, 0]$ 的范围内,  $f_s$ 表示时频图像 $x$ 的最高频率。

[0112] (2.5) 对时频域图像进行着色处理:对移动零频点后的图像 $\tilde{F}(m,n)$ 进行成像,使用专用的时频图成像方法对 $\tilde{F}(m,n)$ 进行着色处理,获取最终的时频图数据集。着色处理可以将存在干扰雷达信号的时频图中的干扰部分凸显出来,与地杂波区域形成较强的对比,便于人工标注过程的实现,形成的数据集的分类更加准确,有利于后续GAN网络的训练。

[0113] 实施例3

[0114] 雷达干扰多域特征对抗学习与检测识别方法同实施例1-2,步骤(6a)中的生成器损失函数和步骤(6b)中的判别器损失函数可如下式综合表示,提高损失函数的计算效率。

$$[0115] \quad \min_G \max_D L(D, G) = E_{x \sim p(\text{data})} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))]$$

[0116] 其中 $x$ 表示真实输入,  $z$ 表示生成模型的输入数据,  $G(z)$ 表示生成的图片,  $D(x)$ 表示网络 $D$ 判断图片是否真实的概率与相应的类别,越接近1代表真实性越高;输入随机向量 $z$ 会在生成模型 $G$ 中生成符合真实概率分布 $P$ 的对应样本 $G(z)$ ,判别模型 $G$ 用来判断输入数据的真实性,生成模型和判别模型都是多层感知器的非线性映射函数。

[0117] 本发明使用的综合损失函数是对生成对抗网络GAN的生成器损失函数和判别器损失函数的综合表示,综合损失函数可以直接使用在网络的计算过程中,提高了损失函数的计算效率和网络的反向传播效率,有利于网络的训练过程。

[0118] 实施例4

[0119] 雷达干扰多域特征对抗学习与检测识别方法同实施例1-3,步骤(7a)中的对生成图像进行多样性评估与筛选,包括有如下步骤:

[0120] (7a1) 计算生成图像与训练集图像的相似度:

$$[0121] \quad I(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}$$

$$[0122] \quad C(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2}$$

$$[0123] \quad S(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}$$

[0124] 其中,  $X$ 表示生成图像,  $Y$ 表示训练集图像,  $I(X, Y)$ 为亮度相似性,  $C(X, Y)$ 为对比度相似性,  $S(X, Y)$ 为结构相似性,  $\mu_X$ 为图像 $X$ 的均值,  $\mu_Y$ 为图像 $Y$ 的均值;  $\sigma_X$ 为图像 $X$ 的标准差,  $\sigma_Y$ 为图像 $Y$ 的标准差;  $\sigma_{XY}$ 为图像 $X$ 和 $Y$ 的协方差,  $C_1$ 为亮度相似性常数,  $C_2$ 为对比度相似性常数,

$C_3$ 为结构相似性常数,一般取 $C_1 = (K_1L)^2, C_2 = (K_2L)^2, C_3 = \frac{C_2}{2}$ ;本例中 $K_1=0.01, K_2=0.03, L=255$ 。

[0125] 相似度是衡量图像之间不同特征的相似程度,优良的生成图像应该具有训练数据的结构特点的同时,尽可能的与训练数据有一定的差异性,这样的生成图像才可以使网络在训练中学习到的更多的信息。生成图像和训练图像之间的相似度可以作为筛选优良生成图像的重要依据。

[0126] (7a2) 计算生成图像与训练集图像的多层级结构相似性:

$$[0127] \quad MS-SSIM(X, Y) = [l_m(X, Y)]^{\alpha_m} \prod_{i=1}^M [C_i(X, Y)]^{\beta_i} [S_i(X, Y)]^{\gamma_i}$$

[0128] 其中,MS-SSIM(X, Y)为多层级结构相似性指标, $C_i(X, Y)$ 和 $S_i(X, Y)$ 是利用迭代方法对图像进行低通滤波和降采样,在每一个尺度上分别计算出对比度相似性和结构相似性指标, $l_m(X, Y)$ 是在最终的尺度M上计算的亮度相似性指标,M表示在迭代滤波和下采样中使用的卷积数, $\alpha_m$ 用于调整亮度相似性的相对重要性, $\beta_i$ 用于调整对比度相似性的相对重要性, $\gamma_i$ 用于调整结构相似性的相对重要性;

[0129] 对于优良的生成图像来说,首先看重的是生成图像与训练图像的结构相似性,为了让生成图像保留训练图像的结构特征,本例取 $\gamma_i=1.5$ ;其次对比度相似性也是衡量生成图像与训练图像差异的重要标准,为了保证生成图像与训练图像之间具有一定的差异性,本例取 $\beta_i=1$ ;最后关于亮度相似性,其重要程度较低,因此本例取 $\alpha_m=0.5$ 。

[0130] (7a3) 根据MS-SSIM(X, Y)值的特点筛选生成图像:MS-SSIM(X, Y)值越小代表数据集多样性越高,MS-SSIM(X, Y)值越大代表数据集多样性越低;为了保证生成图像保留训练图像的结构特征,两者之间不至于产生巨大的差异性,本发明将丢弃MS-SSIM(X, Y)值较小的生成图像;同时,为了使生成图像与训练图像不会出现雷同的现象,本发明保留MS-SSIM(X, Y)值适当大的数据用以下一轮筛选,通过上述筛选操作,提高了数据集的多样性。

[0131] 本发明实现步骤包括:收集雷达信号;对雷达信号进行时频分析处理;进行样本标注获取数据集;构建生成对抗网络的生成器;构建生成对抗网络的判别器;训练生成对抗网络;获取生成图像并筛选用以扩充数据集;对生成对抗网络进行再训练;对待检测信号进行时频分析处理;投入训练得到的GAN网络中;获取有无干扰检测和有源干扰类型识别结果。本发明通过时频分析处理获取雷达信号的二维时频域特征,通过生成对抗网络的训练,大大提高了有无干扰检测和有源干扰类型识别的准确率,同时通过生成器获取生成图像以补充训练集,减小了对训练数据数量的需求。

[0132] 下面给出一个更加详细的例子,对本发明进一步说明。

[0133] 实施例5

[0134] 雷达干扰多域特征对抗学习与检测识别方法同实施例1-4,参照图1,有如下步骤:

[0135] 步骤1,收集或仿真一定数量的无干扰和带各类型干扰的雷达信号。

[0136] 步骤2,对雷达信号进行时频分析处理获取时频图数据集。

[0137] 所述的时频分析处理获取时频图数据集的具体步骤如下:

[0138] 第1步,按照下式,对雷达信号的每一个回波进行短时傅里叶变换:

$$[0139] \quad y(m, n) = \sum_{n=-\infty}^{\infty} x(n)w(n - mR)e^{-j\omega n}$$

[0140] 其中,  $x(n)$  表示雷达信号,  $w(k)$  表示窗函数,  $n$  为雷达信号的长度,  $m$  为短时傅里叶变换的长度。

[0141] 第2步, 按照下式, 计算时频域结果  $y(m, n)$  中每个元素的模值:

$$[0142] \quad \tilde{y}(k_1, k_2) = \|y(k_1, k_2)\|_2, \quad k_1 = 0, 1, \dots, m-1 \quad k_2 = 0, 1, \dots, n-1$$

[0143] 其中,  $\|\cdot\|_2$  表示求复数的二范数。

[0144] 第3步, 按照下式, 对时频域图像进行对数变换预处理, 增强成像效果:

$$[0145] \quad F(m, n) = 10 * \log_e(\tilde{y}(m, n) + 10)$$

[0146] 第4步, 按照下式, 移动零频点到频谱中间:

$$[0147] \quad \tilde{F}(m, n) = \text{fftshift}(F(m, n))$$

[0148] 其中,  $\text{fftshift}(x)$  表示将图像  $x$  的  $[fs/2, fs]$  部分移动到  $[-fs/2, 0]$  的范围内。

[0149] 第5步, 对  $\tilde{F}(m, n)$  进行成像, 使用专用的时频图成像方法对  $\tilde{F}(m, n)$  进行着色处理, 获取最终的时频图数据集。

[0150] 步骤3, 对时频图数据集进行样本标注: 根据任务需求定义有源干扰类型, 例如本发明定义有源干扰分别为窄带瞄频式干扰、分段线性式干扰、间歇转发式干扰、重复转发式干扰。然后将获取的时频图数据集根据各个干扰类型进行分类, 获取无干扰数据集和各种有源干扰类型数据集。

[0151] 对已获取的数据集进行随机抽取, 抽取20%的数据构建验证集, 剩余的数据作为训练集, 并将训练集的数据打乱, 以便在训练网络时更好的使用。

[0152] 步骤4, 构建生成对抗网络GAN的生成器。

[0153] 取一个随机噪声向量  $z$  (长度为100) 以及对应的标签  $c$  (长度为10), 将噪声  $z$  与标签  $c$  同时输入全连接层  $f_c(\cdot)$ :

$$[0154] \quad x_1 = f_c(z, c)$$

[0155] 按以下公式对  $x_1$  进行转置卷积转换:

$$[0156] \quad x_2 = \text{ConvT}(x_1) \in R^{k_1 \times k_2 \times l}$$

[0157] 其中  $\text{ConvT}(\cdot)$  为转置卷积函数,  $k_1 \times k_2$  为卷积核的大小,  $l$  为卷积核的数量。

[0158] 按以下公式对转换后的结果进行批归一化:

$$[0159] \quad x_3 = \text{BN}(x_2) = \frac{x_2 - \mu}{\sqrt{\sigma^2 + \varepsilon}}$$

[0160] 其中  $\text{BN}(\cdot)$  为批量归一化函数,  $\mu$  为该批次样本的平均值,  $\sigma^2$  为样本的方差,  $\varepsilon$  项是为了保持数值稳定性, 一般设置为较小的正常数。

[0161] 按以下公式对批归一化后的结果进行激活:

$$[0162] \quad x_4 = \text{LeakyReLU}(x_3) = \begin{cases} x_3, & x_3 > 0 \\ \alpha x_3, & x_3 < 0, \alpha = 0.1 \end{cases}$$

[0163] 重复上述转置卷积、归一化和激活的过程, 直至卷积输出结果  $x_k$  与图片大小相同为止。

[0164] 按以下公式对 $x_k$ 使用激活函数 $\tanh(\cdot)$ ：

$$[0165] \quad y = \tanh(x_k) = \frac{e^{x_k} - e^{-x_k}}{e^{x_k} + e^{-x_k}}$$

[0166] 其中 $y$ 即为生成器生成的最终结果。

[0167] 步骤5,构建生成对抗网络GAN的判别器,和生成器进行数据交互组成生成对抗网络GAN。

[0168] 设训练集图片数量为 $N$ 张,记为 $\{I_i\}_{i=1}^N \in R^{\text{row} \times \text{col}}$ ,其中 $\text{row}$ 、 $\text{col}$ 分别为图片的长和宽, $I_i$ 为第 $i$ 张图片, $i=1,2,\dots,N$ 。

[0169] 按以下公式对每张训练图片进行卷积操作：

$$[0170] \quad q_1 = \text{Conv}(I_i) \in R^{(\text{row}-k_1+1)/s \times (\text{col}-k_2+1)/s}$$

[0171] 其中 $\text{Conv}(\cdot)$ 为卷积函数, $k_1 \times k_2$ 为卷积核大小, $s$ 为步长, $l$ 为卷积核数量;按以下公式对卷积后的结果使用激活函数 $\text{LeakyReLU}(\cdot)$ ：

$$[0172] \quad q_2 = \text{LeakyReLU}(q_1) = \begin{cases} q_1, & q_1 > 0 \\ \alpha q_1, & q_1 < 0, \alpha = 0.1 \end{cases}$$

[0173] 按以下公式对转换后的结果进行批归一化：

$$[0174] \quad q_3 = \text{BN}(q_2) = \frac{q_2 - \mu}{\sqrt{\sigma^2 + \varepsilon}}$$

[0175] 其中 $\mu$ 为该批次样本的平均值, $\sigma^2$ 为样本的方差, $\varepsilon$ 项是为了保持数值稳定性,主要为了避免被零除,一般设置为较小的正常数。

[0176] 重复上述卷积、激活和归一化步骤,直至卷积输出结果 $q_k$ 的尺寸与卷积核尺寸相同;

[0177] 按以下公式对卷积输出结果 $q_k$ 进行二分类：

$$[0178] \quad \text{validity} = \text{Sigmoid}(s) = \frac{1}{1 + e^{-s}}$$

$$[0179] \quad s = f_c(q_k)$$

[0180] 其中 $\text{Sigmoid}(\cdot)$ 为二分类器,目的是为了判断输入图片来源于训练集还是生成器, $f_c(\cdot)$ 为全连接层。

[0181] 按以下公式对全连接后的结果进行多分类：

$$[0182] \quad \text{label} = \text{Softmax}(s) = \frac{e^s}{\sum_j e^j}$$

[0183] 其中 $\text{Softmax}(\cdot)$ 为多分类器, $\text{label}$ 为输入时频图不存在有源干扰以及存在的有源干扰所属各类型的概率。

[0184] GAN(Generative Adversarial Networks)网络作为一种结构简单、有效的学习对抗网络,在图像处理领域表现出了良好的性能,能够在其独特的对抗训练过程中,一定程度上提高样本的多样性与分类的泛化能力,最大程度的提取时频图像的深层特征,提高判别器干扰类型的识别能力,同时生成器能够生成与真实时频图像较为相似的伪图像来扩充数据集。其优势为能够在较少的典型雷达信号二维时频图中快速的获取特征信息,并在对抗



学习中利用生成层生成更多有用信息提升网络性能,最终实现对雷达干扰类型的准确识别。

[0185] 步骤6,利用时频图数据集对GAN网络进行训练,并生成大量生成图像:利用构建的训练目标函数来约束生成器和判别器的训练过程,并按照不同的训练方式来对生成器和判别器进行训练和优化,直到达到纳什均衡状态时,GAN网络的结构达到最优,结束训练;通过最优GAN网络的生成器生成大量的生成图像。

[0186] 所述的构建训练目标函数的具体步骤如下:

[0187] 第1步,按照下式,构建生成器损失函数:

$$[0188] \quad \min_G L(D, G) = E_{z \sim p(z)} [\log(1 - D(G(z)))]$$

[0189] 其中z表示生成模型的输入数据,p(z)是定义在低维的噪声分布,G(z)表示生成的图片,D(x)表示网络D判断图片是否真实的概率与相应的类别。

[0190] 第2步,按照下式,构建判别器损失函数:

$$[0191] \quad \max_D L(D, G) = E_{x \sim p(\text{data})} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))]$$

$$[0192] \quad \max_D L(D, G) = E_{x \sim p(\text{data})} [\log D(x)] + E_{z \sim p(z)} [\log(1 - D(G(z)))]$$

[0193] 其中x为真实输入,p(data)是真实的样本分布,p(z)是定义在低维的噪声分布,G(z)表示生成图片,D(x)表示网络D判断图片是否真实的概率与相应的类别。

[0194] 第3步,按照下式,构建训练目标函数:

$$[0195] \quad L_S = E[\log P(S = \text{real} | X_{\text{real}})] + E[\log P(S = \text{fake} | X_{\text{fake}})]$$

$$[0196] \quad L_C = E[\log P(C = c | X_{\text{real}})] + E[\log P(C = c | X_{\text{fake}})]$$

[0197] 其中 $L_S$ 为正确的输入数据来源的最大似然估计, $L_C$ 为正确的输入数据类别的最大似然估计,c为生成器与判别器收到的类别标签,s=real代表数据来源于真实图像,s=fake代表数据来源于生成图像, $X_{\text{fake}} = G(z)$ 为生成器的输出, $X_{\text{fake}}$ 为真实图像输入, $P(S|X)$ 代表在输入为X的条件下数据来源的概率, $P(C|X)$ 代表在输入为X的条件下数据类别的概率。

[0198] 生成器的训练目标为 $\min(L_C - L_S)$ ;判别器的训练目标为 $\max(L_C + L_S)$ 。

[0199] 所述的生成器和判别器的不同的训练方式的具体步骤如下:

[0200] 第1步,生成器的训练方式为,固定判别器,训练生成器:使用生成-判别网络串接进行训练,生成网络通过前向传播可以学习建模真实数据的分布规律。固定判别网络的参数不令其发生变化,选取指定干扰类型的潜在变量作为生成器的输入,生成干扰数据,并由判别器进行判别,判别器将判别结果返回生成网络,计算对应的损失函数梯度进行反向传播更新网络参数。

[0201] 第2步,判别器的训练方式为,固定生成器,训练判别器:根据生成对抗模型结构,选取指定干扰类型的潜在变量作为生成器的输入,从数据集中选取真实干扰数据,使得判别器能够估算数据集中选出的真实数据概率,计算损失函数反向传播,因为生成器的参数是固定的,所以返回的损失函数只与判别器的参数有关,不断调整判别器的参数来优化判别器。

[0202] 所述的纳什均衡状态的具体判定方式如下:

[0203] 当生成器可以生成与真实干扰时频图像最相似的虚假数据,并且判别器无法区分

虚假数据与真实数据时,即判别器判断真实来源的概率接近0.5,生成器与判别器在理论上都将获得最优化的结果,当且仅当 $P_{\text{data}}=P_{G(z)}$ 时达到全局最优解。此时可以认为整个网络达到了纳什均衡条件,生成器可以生成与真实干扰时频图像最接近的虚假数据,判别器可以获得最佳的判断能力,训练结束。

[0204] 第3步,利用GAN网络的生成器获取生成图像:在获取最优的GAN网络后,利用最优GAN网络的生成器随机生成大量的无干扰和各种有源干扰类型的生成图像;

[0205] 步骤7,对生成的生成图像进行筛选,用以扩充数据集并进行再训练:利用多层次结构相似性评估方法对生成图像进行多样性评估,将多层次结构相似性指标值较小的数据丢弃,提高数据集的多样性。然后根据KL距离度量法对生成图像进行再筛选,去除KL距离度量值较大的数据,保证生成图像与真实数据具有相似结构特征。最后将筛选出的优良生成图像加入训练集,根据步骤6的过程进行再训练,得到最优的GAN网络结构。

[0206] 所述多层次结构相似性评估方法的具体步骤如下:

[0207] 第1步,按照下式,计算生成图像与真实图像的相似度:

$$[0208] \quad l(X, Y) = \frac{2\mu_X\mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}$$

$$[0209] \quad C(X, Y) = \frac{2\sigma_X\sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2}$$

$$[0210] \quad S(X, Y) = \frac{\sigma_{XY} + C_3}{\sigma_X\sigma_Y + C_3}$$

[0211] 其中, $l(X, Y)$ 为亮度相似性, $C(X, Y)$ 为对比度相似性, $S(X, Y)$ 为结构相似性。

[0212] 第2步,按照下式,计算生成图像与真实图像的多层级结构相似性:

$$[0213] \quad \text{MS-SSIM}(X, Y) = [l_m(X, Y)]^{\alpha_m} \prod_{i=1}^M [C_i(X, Y)]^{\beta_i} [S_i(X, Y)]^{\gamma_i}$$

[0214] 其中,MS-SSIM(X, Y)为多层次结构相似性指标, $C_i(X, Y)$ 和 $S_i(X, Y)$ 是利用迭代方法对图像进行低通滤波和降采样,在每一个尺度上分别计算出对比度相似性和结构相似性指标, $l_m(X, Y)$ 是在最终的尺度M上计算的亮度相似性指标, $\alpha_m$ 、 $\beta_i$ 、 $\gamma_i$ 用于调整不同组件的相对重要性,M表示在迭代滤波和下采样中使用的卷积数。

[0215] 所述KL距离度量法的具体计算公式如下:

$$[0216] \quad D(P||Q) = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)}$$

[0217] 其中 $D(P||Q)$ 为KL距离度量值, $p(x)$ 为生成图像, $q(x)$ 为真实图像。

[0218] 步骤8,利用GAN网络计算有无干扰和有源干扰类型的概率:将需要检测的回波信号根据步骤2的过程进行时频分析处理,然后将时频图输入到训练好的GAN网络中,即可获得该回波是否存在干扰的概率,如果存在干扰,还可获得该有源干扰的类型及其概率。

[0219] 步骤9,结束检测输出结果:利用多分类法判断是否存在干扰以及存在干扰时有源干扰的类型,如果输出概率结果中概率最大的类型为无干扰类型,则认定该雷达信号的回波不存在干扰;否则,认定该回波存在干扰,并取计算出的有源干扰类型概率中最大的概率值,其对应的有源干扰类型认定为该回波存在的有源干扰类型;给出该回波是否存在干扰

和存在干扰时有源干扰的类型,结束检测,将是否存在干扰的判断结果和存在干扰时有源干扰的类型输出,完成基于对抗学习的雷达干扰多域特征的检测与识别。

[0220] 下面结合仿真实验对本发明的效果再做说明。

[0221] 实施例6

[0222] 雷达干扰多域特征对抗学习与检测识别方法同实施例1-5。

[0223] 仿真实验条件:

[0224] 本发明仿真实验的硬件测试平台是:处理器为CPU intel Xeon E5-1630 v4,主频为3.70GHz,GPU NVIDIA GeForce RTX 2080Ti,内存64GB;软件平台为:Windows 10家庭版,64位操作系统,python3.6。

[0225] 仿真实验1:

[0226] 仿真实验1是采用本发明方法对干信比为10db的时频图数据进行训练,并使用生成器生成对应有源干扰类型的生成时频图,如图2所示,其中图2(a)是本发明仿真实验1训练数据中的一张无干扰时频图,图2(b)、图2(c)、图2(d)和图2(e)分别是本发明仿真实验1训练数据中的干信比为10db的窄带瞄频式干扰时频图、分段线性式干扰时频图、间歇转发式干扰时频图和重复转发式干扰时频图,由上述类型的数据构成仿真实验1的数据集,并利用该数据集对本发明构建的GAN网络进行训练。图2(f)、图2(g)、图2(h)和图2(i)分别是经本发明训练好的GAN网络中的生成器生成的窄带瞄频式干扰生成时频图、分段线性式干扰生成时频图、间歇转发式干扰生成时频图和重复转发式干扰生成时频图。将上述生成时频图加入到训练集中对GAN网络进行再训练,得到最终的GAN网络权重。利用验证集对训练好的GAN网络进行验证,验证结果的混淆矩阵如表1所示,其中Class1表示无有源干扰数据,Class2表示窄带瞄频式干扰,Class3表示分段线性式干扰,Class4表示间歇转发式干扰,Class5表示重复转发式干扰。

[0227] 表1仿真实验1验证结果的混淆矩阵

	Class1	Class2	Class3	Class4	Class5
Class1	206	0	0	9	0
Class2	0	211	0	0	0
Class3	0	0	202	0	0
Class4	0	0	0	184	0
Class5	0	2	0	0	220

[0229] 通过仿真实验1的训练得到GAN网络,利用验证集对该网络进行验证,表1为验证结果的混淆矩阵,可以看出对所有的无干扰数据、分段线性式干扰数据和重复转发式干扰数据都能准确的识别,仅有9张间歇转发式干扰错误识别为了无干扰,2张窄带瞄频式干扰错误识别为了重复转发式干扰,综合识别准确率为98.94%,验证了本发明雷达干扰多域特征对抗学习与检测识别方法在识别雷达信号是否存在干扰以及存在干扰时干扰类型的有效性。本实施例在有限数据集上进行训练,正确识别了近99%的验证集数据,是一种准确率极

高的雷达有无干扰检测和雷达有源干扰类型识别的方法。

[0230] 实施例7

[0231] 雷达干扰多域特征对抗学习与检测识别方法同实施例1-5,实验仿真条件同实施例6。

[0232] 仿真实验2:

[0233] 仿真实验2是采用本发明方法对干信比为20db的时频图数据进行训练,并使用生成器生成对应有源干扰类型的生成时频图,如图3所示,其中图3(a)是本发明仿真实验2训练数据中的一张无干扰时频图,图3(b)、图3(c)、图3(d)和图3(e)分别是本发明仿真实验2训练数据中的干信比为20db的窄带瞄频式干扰时频图、分段线性式干扰时频图、间歇转发式干扰时频图和重复转发式干扰时频图,由上述类型的数据构成仿真实验2的数据集,并利用该数据集对本发明构建的GAN网络进行训练。图3(f)、图3(g)、图3(h)和图3(i)分别是经本发明训练好的GAN网络中的生成器生成的窄带瞄频式干扰生成时频图、分段线性式干扰生成时频图、间歇转发式干扰生成时频图和重复转发式干扰生成时频图。将上述生成时频图加入到训练集中对GAN网络进行再训练,得到最终的GAN网络权重。利用验证集对训练好的GAN网络进行验证,验证结果的混淆矩阵如表2所示,其中Class1表示无有源干扰数据,Class2表示窄带瞄频式干扰,Class3表示分段线性式干扰,Class4表示间歇转发式干扰,Class5表示重复转发式干扰。

[0234] 表2仿真实验2验证结果的混淆矩阵

[0235]

	Class1	Class2	Class3	Class4	Class5
Class1	197	0	2	5	0
Class2	0	199	0	0	0
Class3	0	0	201	2	0
Class4	0	0	0	183	0
Class5	0	0	0	0	208

[0236] 通过仿真实验2的训练得到GAN网络,利用验证集对该网络进行验证,表2为验证结果的混淆矩阵,可以看出对所有的无干扰数据、窄带瞄频式干扰数据和重复转发式干扰数据都能准确的识别,仅有2张分段线性式干扰和7张间歇转发式干扰存在识别错误,综合识别准确率达到99.10%,验证了本发明雷达干扰多域特征对抗学习与检测识别方法在不同干信比下都具有极高的准确率,说明了本发明具有较好的适应能力,对不同强度的雷达干扰都可以准确识别。

[0237] 简而言之,本发明的雷达干扰多域特征对抗学习与检测识别方法,解决了雷达信号一维信息的信息量不足和识别准确率依赖于庞大的数据集的技术问题。其实现步骤包括:收集无干扰和带干扰的雷达信号;通过时频分析处理获取时频图数据集;对无干扰和带干扰的时频图数据集进行样本标注;构建生成对抗网络GAN的生成器;构建生成对抗网络GAN的判别器,组成生成对抗网络GAN;利用时频图数据集对GAN网络进行训练,并生成大量

生成图像;对生成的生成图像进行筛选,用以扩充数据集并进行再训练;利用GAN网络计算无干扰和有源干扰类型的概率;获取检测结果。本发明通过时频分析处理获取雷达信号的二维时频域特征,利用二维时频域图构建数据集并在生成对抗网络GAN上进行训练,大大提高了有无干扰检测和有源干扰类型识别的准确率,同时通过生成器获取生成图像以补充训练集,减小了对训练数据数量的需求。本发明可用于对雷达信号进行有无干扰检测以及有源干扰类型识别。

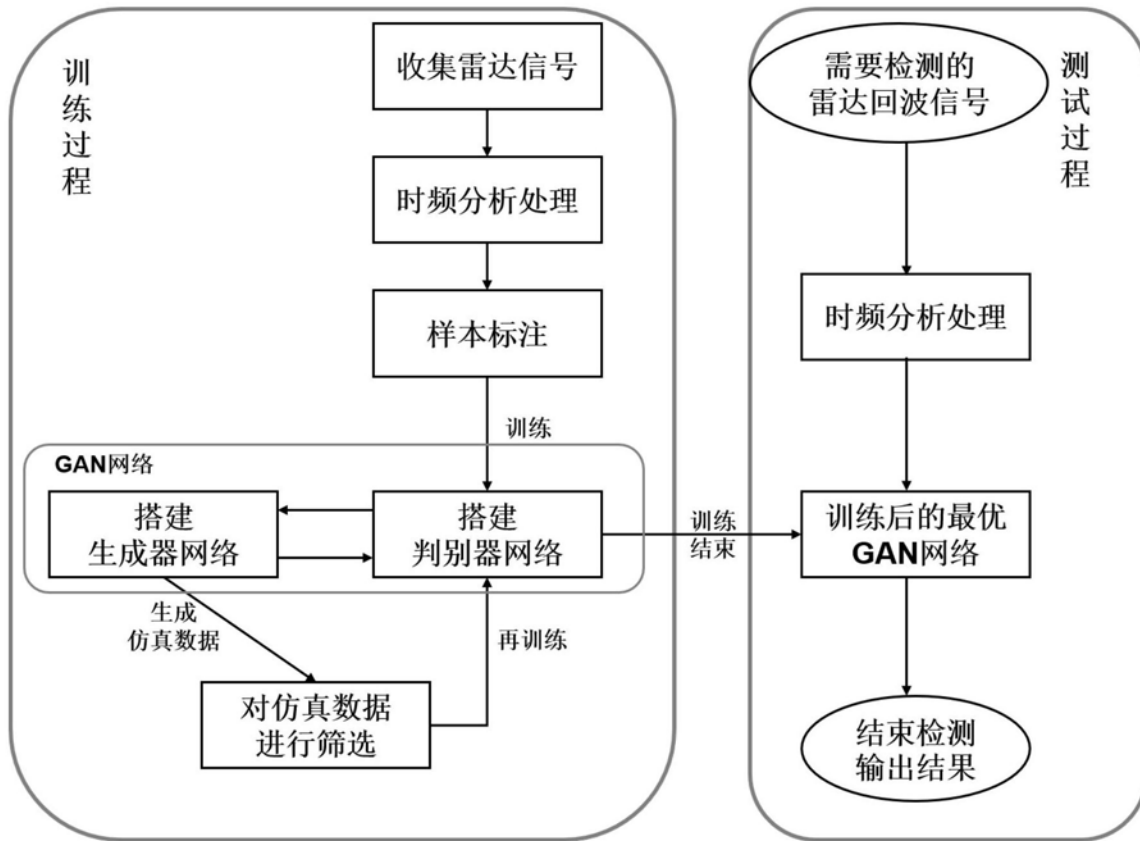


图1




图2




图3