

4-19-2022

Radar Remote Sensing Data Augmentation Method Based on Generative Adversarial Network

Xu Kang

Beijing Institute of Remote Sensing Equipment, Beijing 100854, China; xkang88@sina.com

Xiaofeng Zhang

Beijing Institute of Remote Sensing Equipment, Beijing 100854, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Radar Remote Sensing Data Augmentation Method Based on Generative Adversarial Network

Abstract

Abstract: In the research field of radar remote sensing, both the completeness and diversity of radar data samples cannot meet the requirement of effective training of deep learning models, and the models are prone to over-fitting, which significantly limits the wide application of deep learning techniques in this field. *Targeting on the needs of intelligent application in radar remote sensing, a microwave imaging radar suited data augmentation method is proposed to solve the issue of insufficient radar data samples by leveraging the general framework of generative adversarial network. Aiming at the features of radar samples being not obvious, the label smoothing regularization technique is utilized to automatically classify the augmented radar samples.* The augmented samples together with the real samples are collaboratively used to implement the robust training of deep learning models. The proposed method is verified by the experiments based on the extensive open-source radar remote sensing data.

Keywords

deep learning, radar remote sensing, generative adversarial network, data augmentation

Recommended Citation

Xu Kang, Xiaofeng Zhang. Radar Remote Sensing Data Augmentation Method Based on Generative Adversarial Network[J]. Journal of System Simulation, 2022, 34(4): 920-927.

基于生成对抗神经网络的雷达遥感数据增广方法

康旭, 张晓峰

(北京遥感设备研究所, 北京 100854)

摘要: 在雷达探测领域, 数据样本无论在完备性还是多样性上, 均不能满足深度学习模型有效训练的要求, 模型极易出现过拟合现象, 从而限制了相关技术在雷达探测领域的广泛应用。面向雷达探测领域的智能化应用需求, 针对雷达数据样本不足问题, 提出基于生成对抗神经网络的微波成像体制雷达数据增广方法。针对雷达数据样本特征不显著问题, 结合标签平滑正则化方法, 实现增广数据样本的自动标注, 通过构建增广样本与真实样本协同的深度学习模型训练框架, 实现模型在小规模雷达数据样本集上的鲁棒训练。基于公开雷达探测数据集, 验证了该方法的有效性。

关键词: 深度学习; 雷达遥感探测; 生成对抗神经网络; 数据增广

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)04-0920-08

DOI: 10.16182/j.issn1004731x.joss.20-0953

Radar Remote Sensing Data Augmentation Method Based on Generative Adversarial Network

Kang Xu, Zhang Xiaofeng

(Beijing Institute of Remote Sensing Equipment, Beijing 100854, China)

Abstract: In the research field of radar remote sensing, both the completeness and diversity of radar data samples cannot meet the requirement of effective training of deep learning models, and the models are prone to over-fitting, which significantly limits the wide application of deep learning techniques in this field. Targeting on the needs of intelligent application in radar remote sensing, a microwave imaging radar suited data augmentation method is proposed to solve the issue of insufficient radar data samples by leveraging the general framework of generative adversarial network. Aiming at the features of radar samples being not obvious, the label smoothing regularization technique is utilized to automatically classify the augmented radar samples. The augmented samples together with the real samples are collaboratively used to implement the robust training of deep learning models. The proposed method is verified by the experiments based on the extensive open-source radar remote sensing data.

Keywords: deep learning; radar remote sensing; generative adversarial network; data augmentation

引言

物联网、无线通信、云计算等技术的广泛应用, 标志着人类信息社会已进入大数据时代。以深度学习为代表的人工智能方法, 得益于其层级化、自适应提取数据结构特征的能力, 在大数据时代得以崭露头角, 并在图像分类、目标检测等

典型应用场景中取得突破, 引发各界关注。

深度学习方法是一类基于数据驱动模式的机器学习方法, 需依托大量有效的数据样本才能实现模型的鲁棒训练。然而, 在雷达探测领域, 要获取海量、真实的探测数据, 仍然是非常具有挑战性的任务。不同于其他领域的数据获取方式, 雷达探测数据的收集过程更加依赖于专用探测设备, 并在相对

收稿日期: 2020-12-01

修回日期: 2021-01-30

第一作者: 康旭(1988-), 男, 回族, 博士, 工程师, 研究方向为人工智能、机器学习、强化学习、雷达系统仿真等。

E-mail: xkang88@sina.com

严格的数据处理流程下,才能获取有效的数据样本。正是高精度的探测设备要求与复杂的数据处理流程,提高了获取雷达数据样本的门槛,极大地限制了数据获取的源头,其数据积累规模不可与互联网大数据同日而语。除通过雷达实测方式获取数据样本外,也有学者尝试利用数字仿真^[1]和半实物仿真^[2]方式获取雷达数据样本,这两类方法虽然解决了数据样本不足问题,但无法保障数据的真实性。综上所述,通过传统方式获取的雷达探测数据通常无法兼顾数据样本的完备性、多样性与真实性,不能满足深度学习模型的要求,从而限制了人工智能技术在雷达探测领域的广泛应用。因此,如何实现高效、高质量的雷达探测数据仿真,成为该领域亟待解决的关键问题。

文献[3]提出一种智能化的数据生成模型,即生成对抗神经网络(generative adversarial network, GAN),它能以无监督学习的方式,获取已有数据隐含的特征分布,并合成全新的数据样本。此后,GAN的一系列衍生模型被广泛应用于光学图像生成^[4-7]、语音生成^[8-9]、文本生成^[10-11]等诸多领域。随着GAN相关技术的不断发展,模型的数据生成能力得到不断增强,生成样本的特征更趋近于真实数据。文献[12]将GAN模型生成的数据样本应用于图像分类任务中,从而有效缓解了数据样本缺失和样本分布不均衡问题。GAN模型的数据创造能力,为解决小规模样本集条件下的深度学习模型有效训练问题,开辟了新路径,也为推动雷达探测领域的智能化发展,提供了全新的技术思路。

本文面向雷达探测领域对于数据样本的迫切需求,基于GAN模型的基本框架,构建了适用于微波成像体制雷达的数据增广模型,以实现高效、高质量的雷达探测数据仿真。此外,针对雷达微波成像特征不显著问题,结合标签平滑正则化方法(label smoothing regularization, LSR),实现增广数据样本的自动标注。通过增广样本与真实样本协同的训练过程,实现深度学习模型在小规模

雷达探测样本集上的有效训练。最后,基于公开的雷达探测数据集(moving and stationary target acquisition and recognition, MSTAR),验证了该数据增广方法的有效性。

1 方法

1.1 生成对抗神经网络

基本的生成对抗神经网络架构包含2个子网络模型:生成模型(generative model)和判别模型(discriminative model),分别用符号“G”、“D”表示,并以图1所示的方式层级连接。生成对抗神经网络的训练过程,采用生成模型与判别模型交替迭代训练的形式,并分别制定相互对抗博弈式的优化目标。生成模型的优化目标,旨在学习真实数据样本 S_{real} 的特征分布,进而生成足以“以假乱真”的数据样本 S_{gen} ,令判别模型无法分辨数据真伪。判别模型的优化目标,旨在提升分辨数据样本的能力,以正确区分真实数据样本和生成模型伪造的数据样本。通过生成模型与判别模型不断交替进行对抗训练,不仅判别网络分辨数据真伪的能力得到了提升,生成模型合成数据样本的质量也得到提升。




图1 生成对抗神经网络基本架构

Fig. 1 Basic framework of generative adversarial network

1.2 成像体制雷达数据增广方法

目前,生成对抗神经网络已经广泛应用于光学图像数据生成^[4-7]。雷达遥感图像虽然在成像机理上与光学图像不同,但其数据的组织形式与光学图像并没有本质区别。因此,本文结合雷达探测数据基本特点,利用生成对抗神经网络基本框架,构建了适用于微波成像体制雷达的生成对抗

神经网络，命名为“Radar-GAN”，如图2所示。

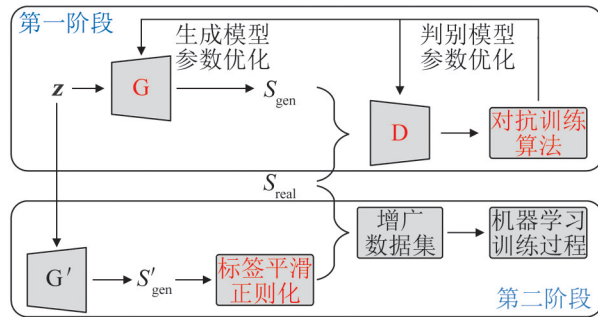


图2 数据扩增方法架构

Fig. 2 Framework of proposed data augmentation method

如图2所示，基于Radar-GAN的数据扩增方法架构包含4个基本模块：生成网络模型、判别网络模型、对抗训练算法，以及标签平滑正则化方法。数据扩增方法的执行过程可分为2个阶段：①Radar-GAN模型对抗训练过程。该过程中Radar-GAN从真实样本 S_{real} 中学习数据特征分布，并具备合成新样本的能力；②数据扩增过程。利用第一阶段训练后的生成模型 G' 合成高质量的数据样本，并利用标签平滑正则化方法对Radar-GAN合成样本进行分类标记，随后合成的数据样本与真实样本共同构成了扩增数据集，用于实现合成数据与真实数据协同的机器学习模型训练过程。

(1) 生成网络模型结构设计。生成网络模型的结构设计，借鉴了传统光学图像生成网络模型DCGAN(deep convolutional generative adversarial networks)^[4]中采用的反卷积结构，并通过对网络

结构进行优化调整，以适应雷达遥感数据生成任务。Radar-GAN生成网络模型的输入 z ，是由正态分布 $N(0, \sigma^2)$ 产生的高维随机向量，表示对某个隐含空间上的数据分布进行采样。生成网络模型的目标，是将隐含空间上的数据采样映射到雷达遥感图像数据所对应的高维空间。为了实现该映射过程，生成网络模型采用了6个层次化连接的反卷积(Deconvolution)结构。如图3所示，这6个反卷积结构分别用符号“Decon1~Decon6”表示，其中以符号“Decon1~Decon5”表示的前5个反卷积结构都各自包含3组基本操作：反卷积层、批次标准化层和基于ReLU函数的激活层。Decon6反卷积结构包含2组操作：反卷积层和基于Tanh函数的激活层。Radar-GAN生成网络模型的输出为具有单通道的雷达遥感合成图像。

(2) 判别网络模型结构设计。如图3所示，判别网络模型同样包含6个层次化连接的基本结构，这其中的前5个结构为卷积(Convolution)结构，用符号“Con1~Con5”表示。每个卷积结构都包含3组基本操作：卷积层、批次标准化层和基于Leaky-ReLU函数的激活层。第6个基本结构为全连接(fully connected)结构，用符号“FC”表示，它包含2组基本操作：全连接层和基于Sigmoid函数的激活层。判别网络模型，本质上是二分类器，它以雷达遥感图像数据作为输入，输出为(0, 1)区间上的数值，以表示输入样本的置信度。当网络输出趋近于1时，则说明网络将输入样本判定为真实数据，反之则为假。




图3 Radar-GAN模型结构

Fig. 3 Structure of Radar-GAN model

(3) 损失函数设计与对抗训练算法。生成网络模型的损失函数用“ L_G ”表示, 用于量化生成网络模型“欺骗”判别网络模型的能力。损失函数可形式化为

$$L_G = \log(1 - D(G(z))) \quad (1)$$

作为二分类器, 判别网络模型的损失函数“ L_D ”包含2个部分: 判别生成样本 S_{gen} 的误差损失和判别真实样本 S_{real} 的误差损失。损失函数可形式化为

$$L_D = \underbrace{\log(1 - D(S_{real}))}_{\text{判别 } S_{real} \text{ 的误差损失}} + \underbrace{\log(D(G(z)))}_{\text{判别 } S_{gen} \text{ 的误差损失}} \quad (2)$$

基于上述损失函数, Radar-GAN的对抗训练过程在算法1中给出。

算法1: Radar-GAN对抗训练算法

输入: 批次大小 m , 总迭代次数 \maxIter , 更新率 η , 生成网络模型与判别网络模型的子迭代次数 n_G 与 n_D

输出: 生成网络模型参数 θ_G , 判别网络模型参数 θ_D

$\theta_G, \theta_D \leftarrow$ 随机初始值;

局部变量 $t \leftarrow 0$;

while $t < \maxIter$ do

$B_z = \{z_k\}_{k=1}^m \leftarrow$ 生成 m 个随机向量 z ;

$B_{real} = \{S_{real}\}_{k=1}^m \leftarrow$ 随机抽取 m 个真实数据样本;

for $e_G = 1$ to n_G do

$\theta_G \leftarrow \theta_G - \eta \nabla_{\theta_G} \frac{1}{m} \sum_{k=1}^m L_G(B_z; \theta_G, \theta_D)$;

for $e_D = 1$ to n_D do

$\theta_D \leftarrow \theta_D - \eta \nabla_{\theta_D} \frac{1}{m} \sum_{k=1}^m L_D(B_z; B_{real}; \theta_G, \theta_D)$;

$t \leftarrow t + 1$;

return θ_G, θ_D ;

(4) 标签平滑正则化方法。当Radar-GAN模型经过充分的对抗训练后, 即可使用参数优化后的生成模型 G' 合成高质量雷达数据样本。然而, 由于对抗训练过程中, 生成模型采用的输入是随机向量, 导致生成模型输出样本的类别不具有可控性。此外, 相较于传统的光学图像, 雷达图像通常

具有较强的斑点噪声且图像特征不显著, 难以进行人工样本识别标注。综合考虑上述两方面因素, 本文使用标签平滑正则化方法^[13-14]对合成样本进行类别标注, 最终实现雷达探测数据样本增广。标签平滑正则化方法, 广泛应用于计算机视觉领域^[14], 用于实现标注与非标注数据协同的半监督学习过程。本文采用均一化的标签平滑标注方法对合成数据样本进行类别标注, 这些合成样本可视作正则化因子, 减小机器学习模型陷入过拟合的几率。

令 $K \in \mathbb{R}$ 表示真实雷达图像数据集中目标类别的总数, 则合成样本 S_{gen} 的类别标注向量 $V_{gen} \in \mathbb{R}^K$ 可表示为

$$V_{gen} = [1/K, 1/K, \dots, 1/K] \quad (3)$$

2 验证

2.1 数据集信息

MSTAR数据集, 是由美国国防部高级研究计划局公开发布的雷达遥感探测数据集。该数据集包含10类前苏联军事目标车辆的雷达成像信息。观测雷达为工作在X波段的高分辨率聚束式合成孔径雷达(synthetic aperture radar, SAR), 分辨率精度为0.3 m×0.3 m。通过对MSTAR数据进行处理, 可得到各类军事目标车辆分别在探测俯仰角15°和17°下的SAR图像, 图像尺寸为128像素×128像素, 各类目标车辆的样本数量分布, 如表1所示。

表1 MSTAR数据集中各类目标样本数量
Table 1 Sample numbers of different targets in MSTAR dataset

| 目标类别 | 俯仰角 15° | 俯仰角 17° |
|---------|---------|---------|
| BMP2 | 196 | 233 |
| BTR70 | 196 | 233 |
| T72 | 196 | 232 |
| BRT60 | 195 | 256 |
| 2S1 | 274 | 299 |
| BRDM2 | 274 | 298 |
| D7 | 274 | 299 |
| T62 | 273 | 299 |
| ZIL131 | 274 | 299 |
| ZSU23/4 | 274 | 299 |
| 合计 | 2 426 | 2 747 |

图4展示了MSTAR数据集中所包含的10类目标车辆的SAR图像和相对应的光学图像。




图4 MSTAR数据集中各类目标的SAR图像及相对应的光学图像

Fig. 4 SAR images and corresponding optical images of different targets in MSTAR dataset

2.2 Radar-GAN参数设定与模型优化

在1.2节中，分别介绍了生成模型与判别模型的基本结构，本节将给出各个结构所使用的参数设定。在生成模型中，反卷积层Decon1~Decon6使用的卷积核尺寸均为：4×4，卷积核个数依次为：1 024、512、256、128、64、1，卷积核移动步长依次为：1、2、2、2、2、2。生成模型所需的输入数据，为具有128个维度的随机向量 $\mathbf{z} \in \mathbb{R}^{128}$ 。在判别模型中，卷积层Con1~Con5使用的卷积核尺寸均为：4×4，卷积核个数依次为：64、128、256、512、1 024，卷积核移动步长均为：2。

Radar-GAN模型基于PyTorch软件框架实现。模型的参数优化过程借助于PyTorch软件的自动微分求解机制，实现梯度计算与误差反向传播，并依据算法1执行对抗训练和参数更新，最终通过充分迭代达到纳什均衡。与算法1相关的输入参数设定包括：批次大小 $m=128$ ，网络参数更新速率 $\eta=10^{-4}$ ，迭代次数 $\max Iter=10^5$ ， $n_G=n_D=5$ 。模型实现与算法执行依托的硬件平台为搭载了NVIDIA GeForce RTX 2080ti GPU的深度学习工作站。

2.3 实验设定与结果分析

(1) 增广样本数据质量与泛化能力分析。作为数据增广模型，Radar-GAN合成样本的特征应与真实样本相近。本节面向典型的雷达目标分类任务，通过比较多种分类模型在数据增广前后分类能力的变化，以验证数据增广方法的有效性、合成样本的数据质量以及合成样本对不同模型的普适性。

首先依据2.2节中关于Radar-GAN的参数设定，将模型应用于观测俯仰角为17°的MSTAR数据集上(下文用“17#”表示该数据集)并进行对抗训练，使G网络模型具备SAR图像合成能力。随后，用G网络模型合成与17#数据集规模相当的合成样本集，并基于LSR方法进行标注，这些合成样本与原17#数据样本共同构成了增广数据集(下文用“17#Ex”表示该数据集)。

本文选用5种典型的分类模型，包括Boost、SVM、FCN、LeNet、DCNN，分别在17#和17#Ex数据集上进行分类训练，并将训练后的模型应用于观测俯仰角为15°的MSTAR数据集(下文用“15#”表示该数据集)进行分类测试，分类准确率如表2所示。各分类模型的基本信息如下：

Boost^[15]为基于Boost提升方法的SAR图像分类模型。

SVM^[16]为基于支持向量机的SAR图像分类模型。

FCN为含有2个隐含层的全连接神经网络分类模型。

LeNet^[17]为面向手写数字识别任务的浅层卷积神经网络模型。为了使LeNet模型能适用于MSTAR数据集，本文对LeNet网络全连接层的参数进行了调整。

DCNN^[18]为基于深度卷积神经网络的SAR图像分类模型。

如表2所示，各分类模型皆通过在17#Ex上的训练取得了优于17#训练的分类结果，准确率提升

幅度在 1%~4% 之间, 其中以 FCN 模型的提升效果最为明显, 我们认为这是由于 FCN 模型采用了全连接结构, 参数规模庞大, 在小规模的 17# 训练集上极易陷入过拟合。实验结果表明, 数据增广方法有助于提升典型机器学习模型的训练效果, 验证了数据增广方法的有效性以及合成样本的泛化能力, 同时也从侧面证明合成样本与真实样本具有相似特征, 数据质量较高。

表 2 各分类模型在 15# 测试集上的分类准确率
Table 2 Classification accuracy of different models on 15# testing dataset %

| 数据集 | Boost | SVM | FCN | LeNet | DCNN |
|-------|-------------|-------------|-------------|-------------|-------------|
| 17# | 92.8 | 93.1 | 92.4 | 95.5 | 96.1 |
| 17#Ex | 93.3 | 95.2 | 96.2 | 96.7 | 97.2 |

(2) 样本增广规模分析。对于机器学习模型而言, 除数据样本质量外, 训练集样本规模也将影响模型的训练效果。本节仍面向雷达目标分类任务, 通过探究各分类模型在不同样本增广规模条件下分类准确率的变化, 以揭示样本增广规模对于机器学习模型的影响。

首先参照上节中的步骤得到训练好的 G 网络模型, 用于合成雷达数据样本, 并限定合成样本集的规模为 17# 数据集规模的 0.5~2.5 倍。随后, 将这些合成样本集分别与 17# 数据集混合, 形成增广数据集, 下文用符号“17#Ex0.5~17#Ex2.5”表示这些数据集。再将上节中提到的 5 种典型分类模型, 分别应用于 17# 数据集与增广数据集进行分类训练, 并在 15# 数据集上进行分类测试, 各模型分类准确率如表 3 所示。通过分析结果得知, 大多数分类模型在“17#Ex0.5~17#Ex1.0”增广数据集上取得了最好的训练效果, 测试分类准确率最高。这表明, 模型训练效果与数据增广规模之间并非是线性关联关系, 过多引入合成数据样本, 将使增广数据集中的样本主体由真实数据变为合成数据, 而合成样本特征不可能无限接近于真实样本, 从而导致了分类准确率的下降。

(3) 模型增广能力分析。为了验证 Radar-GAN 模型结构对于 SAR 图像增广任务的适用性, 本节将 Radar-GAN 与近期提出的生成对抗神经网络模型 wGAN-cp^[5]、wGAN-gp^[19]、LSGAN^[20] 进行对比, 通过比较典型分类模型在增广数据集上分类能力的变化, 以量化分析模型的增广能力。

表 3 各分类模型在不同数据增广规模下的分类准确率
Table 3 Classification accuracy of different models under different data augmentation scale %

| 数据集 | Boost | SVM | FCN | LeNet | DCNN |
|----------|-------------|-------------|-------------|-------------|-------------|
| 17# | 92.8 | 93.1 | 92.4 | 95.5 | 96.1 |
| 17#Ex0.5 | 94.5 | 94.3 | 93.2 | 95.8 | 96.5 |
| 17#Ex1.0 | 93.3 | 95.2 | 96.2 | 96.7 | 97.2 |
| 17#Ex1.5 | 92.7 | 94.6 | 95.2 | 96.1 | 97.3 |
| 17#Ex2.0 | 93.1 | 95.0 | 94.9 | 95.6 | 95.9 |
| 17#Ex2.5 | 92.2 | 93.1 | 93.5 | 94.6 | 94.3 |

分别选用 Radar-GAN、wGAN-cp、wGAN-gp、LSGAN 模型在 17# 数据集上进行对抗训练, 并实现 17# 数据集规模的翻倍增广。随后, 将典型的分类模型, 分别应用于各增广模型构建的增广数据集上进行分类训练, 并在 15# 数据集上比较分类结果。如表 4 所示, 在 Radar-GAN 增广集下训练的分类模型, 取得了最优的分类结果。

表 4 各分类模型在不同增广数据集上训练后取得的测试分类准确率

Table 4 Classification accuracy of each classification model after training on different augmented training sets %

| 模型 | Boost | SVM | FCN | LeNet | DCNN |
|-----------|-------------|-------------|-------------|-------------|-------------|
| wGAN-cp | 89.5 | 88.7 | 89.3 | 91.1 | 91.1 |
| wGAN-gp | 91.2 | 90.5 | 90.2 | 94.8 | 95.2 |
| LSGAN | 92.9 | 93.3 | 94.7 | 95.4 | 95.6 |
| Radar-GAN | 93.3 | 95.2 | 96.2 | 96.7 | 97.2 |

(4) 合成样本示例。为了直观展示 Radar-GAN 模型的 SAR 图像生成能力, 选取了训练过程中输出的部分合成样本作为示例。图 5 展示了 Radar-GAN 在经过 100、1 000、10 000 次迭代训练后合成的 SAR 图像样本。从图 5 中可以看出合

成样本逐渐清晰化、样本特征向真实数据逼近的趋势。




图5 Radar-GAN对抗训练过程中输出的合成样本
Fig. 5 Output synthetic samples of Radar-GAN in its adversarial training process

3 结论

本文面向微波成像体制雷达，提出一种基于生成对抗神经网络的雷达数据样本增广方法，大量基于公开、实测雷达探测数据集的实验表明，本文提出的数据增广方法，有助于提升机器学习模型在雷达探测样本集上的训练效果。此外，本文还验证了不同增广样本规模对机器学习模型训练效果的影响。接下来，将通过在数据增广模型中增加类别控制性约束，实现模型合成样本的分类输出。

参考文献:

- [1] 赵健, 张智, 李帅. 雷达电磁环境仿真研究[J]. 舰船电子对抗, 2009, 32(5): 71-74.
Zhao Jian, Zhang Zhi, Li Shuai. Study of Electromagnetic Environment Simulation for Radar[J]. Shipboard Electronic Countermeasure, 2009, 32(5): 71-74.
- [2] 张文辉, 张永宁, 田雨书, 等. 基于SystemVue的复杂电磁环境中雷达半实物仿真[J]. 火控雷达技术, 2018, 47(2): 85-90.
Zhang Wenhui, Zhang Yongning, Tian Yushu, et al. System Vue Based Hardware-in-loop Simulation of Radar in Complicated Electromagnetic Environment[J]. Fire Control Radar Technology, 2018, 47(2): 85-90.
- [3] Goodfellow I, Pouget-Abadie J, Mirza M, et al.

- Generative Adversarial Nets[C]// Advances in Neural Information Processing Systems. Montreal: MIT Press, 2014: 2672-2680.
- [4] Radford A, Metz L, Chintala S, et al. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks[C]// International Conference on Learning Representations. San Juan, Puerto Rico: ICLR, 2016: 1-16.
- [5] Adler J, Lunz S. Banach Wasserstein Gan[C]// Advances in Neural Information Processing Systems. Montréal: MIT Press, 2018: 6754-6763.
- [6] Zhu J Y, Park T, Isola P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks [C]// IEEE International Conference on Computer Vision. Venice: IEEE Computer Society, 2017: 2223-2232.
- [7] Hussein S A, Tիրer T, Giryes R. Image-Adaptive GAN Based Reconstruction[C]// AAAI Conference on Artificial Intelligence. New York: AAAI, 2020: 3121-3129.
- [8] Kumar K, Kumar R, de Boissiere T, et al. Melgan: Generative Adversarial Networks for Conditional Waveform Synthesis[C]// Advances in Neural Information Processing Systems. Vancouver: MIT Press, 2019: 14910-14921.
- [9] Yang S, Xie L, Chen X, et al. Statistical Parametric Speech Synthesis Using Generative Adversarial Networks Under a Multi-task Learning Framework[C]// 2017 IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). Okinawa: IEEE, 2017: 685-691.
- [10] Zhang Y, Gan Z, Fan K, et al. Adversarial Feature Matching for Text Generation[C]// 34th International Conference on Machine Learning Learning. Sydney: ACM, 2017: 4006-4015.
- [11] Yu L, Zhang W, Wang J, et al. Seqgan: Sequence Generative Adversarial Nets with Policy Gradient[C]// Thirty-first AAAI Conference on Artificial Intelligence. San Francisco: AAAI, 2017.
- [12] Zheng Z, Zheng L, Yang Y, et al. Unlabeled Samples Generated by GAN Improve the Person Re-Identification Baseline in Vitro[C]// International Conference on Computer Vision. Venice: IEEE, 2017: 3774-3782.
- [13] Hou J, Zeng H, Cai L, et al. Multi-Label Learning with Multi-Label Smoothing Regularization for Vehicle Re-Identification[J]. Neurocomputing (S0925-2312), 2019, 345: 15-22.
- [14] Zheng Z, Zheng L, Yang Y. Unlabeled Samples Generated by Gan Improve the Person Re-identification

- Baseline in Vitro[C]// IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 3754-3762.
- [15] Sun Y, Liu Z, Todorovic S, et al. Adaptive Boosting for SAR Automatic Target Recognition[J]. IEEE Transactions on Aerospace and Electronic Systems(S0018-9251), 2007, 43(1): 112-125.
- [16] Zhao Q, Principe J C. Support Vector Machines for SAR Automatic Target Recognition[J]. IEEE Transactions on Aerospace and Electronic Systems (S0018-9251), 2001, 37(2): 643-654.
- [17] Lecun Y, Bottou L. Gradient-Based Learning Applied to Document Recognition[J]. IEEE (S0018-9219), 1998, 86(11): 2278-2324.
- [18] Chen S, Wang H, Xu F, et al. Target Classification Using the Deep Convolutional Networks for SAR Images[J]. IEEE Transactions on Geoscience and Remote Sensing (S0196-2892), 2016, 54(8): 4806-4817.
- [19] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved Training of Wasserstein Gans[C]// Advances in Neural Information Processing Systems. Long Beach: MIT Press, 5767-5777.
- [20] Mao X, Li Q, Xie H, et al. Least Squares Generative Adversarial Networks[C]// IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2794-2802.