

# 小样本条件下基于数据增强和 WACGAN 的 雷达目标识别算法

朱克凡,王杰贵,刘有军

(国防科技大学电子对抗学院,安徽合肥 230037)

**摘要:** 目前小样本条件下高分辨距离像雷达目标识别算法存在识别率较低、识别率稳定度较差等问题,对此,本文提出了基于数据增强和加权辅助分类生成对抗网络(Weighted Auxiliary Classifier Generative Adversarial Networks, WACGAN)的雷达目标识别算法.该算法首先根据雷达目标散射特性,通过时间镜像数据增强方法扩充数据集,然后将扩充数据集输入 WACGAN,通过自动选择高质量的生成样本,使判别器在标签样本监督学习的基础上得到进一步优化,最后直接利用判别器实现对雷达目标的有效识别.仿真实验结果表明,本文算法在不增加识别时间的基础上,有效提高了小样本条件下对雷达目标的识别率和识别稳定度.

**关键词:** 雷达目标识别;数据增强;生成对抗网络

**中图分类号:** TN959.1+7

**文献标识码:** A

**文章编号:** 0372-2112(2020)06-1124-09

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2020.06.012

## Radar Target Recognition Algorithm Based on Data Augmentation and WACGAN with a Limited Training Data

ZHUKe-fan, WANG Jie-gui, LIU You-jun

(Electronic Countermeasure Institute of National University of Defense Technology, Hefei, Anhui 230037, China)

**Abstract:** At present, the existing high-resolution range profile radar target recognition algorithm with limited training data still has several drawbacks (e. g., low recognition accuracy and poor recognition stability). To this end, an efficient radar target recognition algorithm is developed in this paper, which is based on data augmentation and Weighted Auxiliary Classifier Generative Adversarial Networks (WACGAN). Specifically, we expand data set by using the data augmentation method based on time mirroring, and the radar target scattering characteristics is considered. After that, the WACGAN with expanded data set is used to automatically select high-quality generated samples and further optimize the discriminator, which has been improved through the supervised learning. Then, the optimized discriminator is used to recognize radar target. Finally, several numerical experiments have been carried out to demonstrate that, under the condition of limited training data, the proposed algorithm possesses higher recognition accuracy and better recognition stability without increasing recognition time.

**Key words:** radar target recognition; data augmentation; generative adversarial network

### 1 引言

雷达目标识别在精确制导、对空情报等军事领域具有重要作用,是雷达研究的一个重要方向.高分辨距离像雷达能获取目标一维距离像等细微特征,较好的识别雷达目标,所以基于高分辨距离像雷达的目标识别技术研究是雷达研究的一个重要热点<sup>[1-3]</sup>.

在现代战争中,当雷达的脉冲重复频率较低或者

目标是先进的非合作目标或隐身目标时,通常难以获取足够多的训练样本,由于小样本无法很好体现目标特性,导致方法识别率较低.针对小样本问题,常见的解决方法有两种,一种是采用在小样本条件下具有良好预测能力的识别方法,如最近邻分类器、支持向量机(Support Vector Machine, SVM)等,另一种是通过生成新样本扩充数据集来提高识别效果.文献[3]基于雷达目标回波的雷达散射截面积(Radar-Cross Section, RCS)和

频谱熵值特征,采用 SVM 实现对地面目标的分类识别,但由于人工提取的特征属于浅层特征,且特征提取过程中损失了数据信息,导致算法识别率较低.文献[4]使用卷积神经网络(Convolutional Neural Networks, CNN)挖掘数据深层特征,对雷达目标进行识别,但 CNN 网络参数较多,需要大量样本来防止过拟合,不适用于小样本条件.文献[5]基于合成孔径雷达(Synthetic Aperture Radar, SAR)图像特性,先提出了三种数据增强方法扩充数据集,然后使用 CNN 实现对 SAR 图像的有效识别.文献[6]利用合成少数类过采样技术(Synthetic Minority Oversampling Technique, SMOTE)扩充数据集以提高识别率,但由于 SMOTE 算法可能会模糊多数类与少数类的边界以及使用噪声合成新样本,生成样本质量较差,数据集扩充效果不理想.

文献[7]先通过生成对抗网络(Generative Adversarial Networks, GAN)产生一定数量逼近真实样本分布的生成样本,实现扩充数据集的目的,然后将扩充数据集输入 CNN 以提高算法识别率;文献[8,9]使用 Wasserstein GAN(WGAN)扩充数据集;文献[10,11]使用条件 GAN(Condition GAN, CGAN)扩充数据集.上述方法的识别率较 CNN 都有一定提高,但存在两个方面的问题:一是由于 GAN 及其改进方法训练过程的稳定性和收敛性难以保证,生成样本质量参差不齐,使用质量较差的生成样本扩充数据集会降低识别效果,导致识别率波动较大,稳定度较差;二是上述方法采用先生成样本扩充数据集,再进行识别的方式,产生了新的超参数——生成样本数量,需要进行多次实验以选择合适的生成样本数,增加了实验复杂程度.文献[8]通过人工选择方式,选取质量较好的生成样本扩充数据集,但人工选择增加了成本.

针对以上问题,本文提出了基于数据增强和加权辅助分类生成对抗网络(Weighted Auxiliary Classifier Generative Adversarial Networks, WACGAN)的雷达目标识别算法.该算法首先利用时间镜像数据增强方法对数据集进行扩充;然后通过 WACGAN 产生并自动选择高质量的生成样本优化判别器,降低了低质量生成样本对网络的影响,解决了 GAN 生成样本质量参差不齐导致识别率稳定度较差的问题,提高了算法对目标的识别稳定程度;最后使用 WACGAN 的判别器直接对雷达目标进行分类识别,无需人工选择生成样本数,降低了实验复杂程度.

## 2 基于时间镜像的数据增强

### 2.1 雷达目标回波建模

现代雷达辐射源信号常采用脉冲压缩信号,如相位编码信号、线性调频(Linear Frequency Modulation, LFM)信号等,使用脉冲压缩技术可使雷达具有很高的

径向分辨力,当雷达目标的尺寸大于径向分辨力时,运动目标占据多个距离单元,此时可以使用多散射点模型来模拟目标回波信号.

当雷达发射机发射的是 LFM 信号时,幅度归一化后可以表示为

$$S(t) = a(t) \exp[j2\pi(f_0 t + \frac{1}{2} k t^2)] \quad (1)$$

式中: $a(t)$ 是信号包络, $f_0$ 是中心频率, $k$ 为调频斜率.当点目标 $i$ 的距离为 $R_i$ 时,反射的回波信号为

$$S_i(t) = a_i(t - t_i) \exp\{j2\pi[f_0(t - t_i) + \frac{1}{2} k (t - t_i)^2]\} \quad (2)$$

式中: $t_i = \frac{2R_i}{c}$ , $c$ 为光速.对于径向上具有多个散射点分布的目标,回波信号相当于各散射点反射信号的叠加,则回波信号可以表示为

$$S(t) = \sum_i a_i(t - t_i) \exp\{j2\pi[f_0(t - t_i) + \frac{1}{2} k (t - t_i)^2]\} \quad (3)$$

接收机采用变频技术对接收信号进行处理,首先产生一个与发射信号斜率相同的 LFM 参考信号

$$S_o(t) = a_o(t - t_o) \exp\{j2\pi[f_0(t - t_o) + \frac{1}{2} k (t - t_o)^2]\} \quad (4)$$

式中: $t_o = \frac{2R_o}{c}$ , $R_o$ 为目标参考距离.混频后

$$S(t) = \sum_i A_i(t) \exp\{j2\pi[f_m t + \varphi]\} \quad (5)$$

式中: $A_i(t) = a_i(t - t_i) a_o(t - t_o)$ , $f_m = k(t_i - t_o)$ , $\varphi = f_0(t_i - t_o) + \frac{1}{2} k(t_o^2 - t_i^2)$ .

### 2.2 时间镜像数据增强方法

为有效扩充训练样本数,借鉴文献[12]所述计算机视觉中的数据增强方法——翻转,本文提出了时间镜像数据增强方法,对现有雷达目标回波信号进行时间镜像运算,实现扩充数据集的目的.

混频后的雷达目标回波数据如式(5)所示,令

$$t = \tau_o - t' \quad (6)$$

对混频信号进行时间镜像操作,通过引入镜像参数 $\tau_o$ ,获取时间 $t$ 关于时间轴 $\frac{\tau_o}{2}$ 的镜像时间 $t'$ .

假设回波信号经过时间镜像后存在镜像目标,其时间 $t'$ 与原目标时间 $t$ 关于时间轴以 $\frac{\tau_o}{2}$ 成对称关系,则镜像目标回波数据可以表示为

$$S(t') = \sum_i a_i(\tau_o - t' - t_i) a_o(\tau_o - t' - t_o) \times \exp\{j2\pi[f_m(\tau_o - t') + \varphi]\}$$

$$= \sum_i A_i(t') \exp\{j2\pi[k(t_0 - t_i)t' + \varphi']\} \quad (7)$$

式中:

$$A_i(t') = a_i(\tau_0 - t' - t_i) a_o(\tau_0 - t' - t_0) \quad (8)$$

$$\varphi' = k\tau_0(t_i - t_0) + \varphi \quad (9)$$

由于  $\varphi'$  和  $\varphi$  只是初相,与时间  $t'$  无关,分析时可以忽略. 此时设  $t_0 - t_i = t_i' - t_0$ , 即

$$t_i' = 2t_0 - t_i \quad (10)$$

则式(7)可以表示为

$$S(t') = \sum_i A_i(t') \exp\{j2\pi[k(t_i' - t_0)t' + \varphi']\} \quad (11)$$

当  $\tau_0 = 2t_0$  时,则式(8)可以表示为

$$A_i(t') = a_i(t_i' - t') a_o(t_0 - t') \quad (12)$$

此时镜像目标回波信号可以表示为

$$S(t') = \sum_i a_i(t_i' - t') a_o(t_0 - t') \cdot \exp\{j2\pi[k(t_i' - t_0)t' + \varphi']\} \quad (13)$$

对比式(5)和式(13),可以将镜像目标看成由多个回波到达时间为  $t_i'$  的散射点组成. 设  $t_i - t_0 = \Delta t^i$ , 则原目标的各散射点回波到达时间为

$$t_i = t_0 + \Delta t^i \quad (14)$$

镜像目标的各散射点回波到达时间  $t_i'$  为

$$t_i' = 2t_0 - t_i = t_0 - \Delta t^i \quad (15)$$

比较式(14)和式(15),可以发现原目标与镜像目标对应散射点的回波到达时间关于时间点  $t_0$  成对称关系.

将式(6)、式(15)和  $\tau_0 = 2t_0$  代入式(12),则各散射点回波的包络信息

$$\begin{aligned} A_i(t') &= a_i(t_i' - t') a_o(t_0 - t') \\ &= a_i(t - t_i) a_o(t - t_0) \\ &= A_i(t) \end{aligned} \quad (16)$$

式中:  $t = 2t_0 - t'$ ,  $t$  与  $t'$  关于时间轴以  $t_0$  成对称关系,则原目标与镜像目标对应散射点的包络信息也关于时间点  $t_0$  成对称关系.

由镜像目标和原目标对应散射点关系看出,镜像目标与原目标的散射点组成结构相同,方向相反. 原目标和镜像目标的各散射点镜像关系如图1所示.




图1 散射点镜像关系图

时间镜像数据增强方法产生了增强样本,从 RCS、频谱熵值等浅层特征考虑,增强样本并没有增加相应目标特征信息,但时间镜像数据增强方法能够有效扩充训练样本数,在小样本条件下,增强数据集映射到 CNN 学习到的特征空间后,提高了原数据集在特征空间的覆盖范围,有利于分类器选择较好的分类面,提高分类器识别性能.

### 3 基于数据增强和 WACGAN 的雷达目标识别算法

#### 3.1 辅助分类生成对抗网络

GAN<sup>[13]</sup> 由生成器  $G$  和判别器  $D$  组成,其中生成器  $G$  的作用是根据输入的噪声序列  $z$  来尽量产生服从真实数据分布  $P_{\text{data}}$  的生成样本  $G(z)$  以欺骗判别器  $D$ ,而  $D$  的作用是判断输入样本是真实样本  $x$  还是生成样本  $G(z)$ ,  $G$  与  $D$  之间相互对抗,互相促进,在不断的对抗中,两者会达到纳什均衡,最终  $G$  能够捕获到  $x$  的分布并产生能够以假乱真的  $G(z)$ ,而  $D$  则由于无法正确区分  $x$  和  $G(z)$ ,输出逼近一个固定值.

判别器的损失函数如下所示:

$$\begin{aligned} \max_D V(D, G) &= E_{x \sim P_{\text{data}}(x)} [\log(D(x))] + \\ &E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \end{aligned} \quad (17)$$

式中:  $D(x)$  为  $D$  判断输入的  $x$  为真实样本的概率;  $D(G(z))$  表示生成样本通过判别器后,被判断为真实样本的概率.

生成器的损失函数如下所示:

$$\max_G V(D, G) = E_{z \sim P_z(z)} [\log(D(G(z)))] \quad (18)$$

由于 GAN 是无监督的学习,生成样本不可控,所以 Augustus 等人在 GAN 的基础上进行了改进,提出了辅助分类生成对抗网络 (Auxiliary Classifier GAN, ACGAN)<sup>[14]</sup>. ACGAN 将噪声  $z$  和标签  $y$  同时输入  $G$ ,并在  $D$  中增加一个辅助分类器,使得  $D$  在判断输入样本是否为真实样本的同时完成分类任务. 所以将单个样本输入 ACGAN 中,判别器会输出两个值,一个是输入样本被判断为真实样本的概率,另一个是预测类别. 同样的,ACGAN 的损失函数由判别损失  $L_S$  和分类损失  $L_C$  组成.

$$L_S = E_{x \sim P_{\text{data}}(x)} [\log(D_S(x))] + E_{z \sim P_z(z)} [\log(1 - D_S(G(z, y)))] \quad (19)$$

$$L_C = -E_{x \sim P_{\text{data}}(x)} [L_D(y_x | x)] - E_{z \sim P_z(z)} [L_D(y | G(z, y))] \quad (20)$$

式中:  $L_S$  是判断数据真实与否的损失函数,  $L_C$  是数据分类准确性的损失函数,  $D_S(x)$  表示判别器  $D$  判断输入的  $x$  为真实样本的概率;  $D_S(G(z, y))$  表示  $D$  判断输入的  $G(z, y)$  为真实样本的概率;  $L_D(y_x | x)$  表示  $D$  对

$x$  的分类损失,  $y_x$  是  $x$  的真实类别;  $L_D(y|G(z, y))$  表示对生成样本  $G(z, y)$  的分类损失,  $y$  表示生成样本的标签.

则 ACGAN 判别器的损失函数如下所示:

$$\max_D V(D, G) = L_S + L_C \quad (21)$$

生成器的损失函数如下所示:

$$\max_G V(D, G) = L_C - L_S \quad (22)$$

### 3.2 加权辅助分类生成对抗网络

由于 ACGAN 基于 GAN 的博弈论思想, 依然存在训练过程不稳定, 生成样本质量参差不齐的问题, 且文献[21]中 ACGAN 的分类损失  $L_C$  采用交叉熵损失函数, 其平等的累加各生成样本损失来训练网络, 当生成样本质量较差时, 判别器  $D$  的识别效果反而会降低.

对此, 本文在 ACGAN 的基础上进行了改进, 增加了权值系数, 提出了 WACGAN 模型, 使判别器  $D$  在监督学习的基础上, 能够根据权值大小选择高质量的生成样本以进一步优化识别网络, 对目标实现更好的分类识别. 同时, 本文将判别概率  $D_S$  引入权值系数  $W$  中, 使判别器可以根据判别概率  $D_S$  自动选择高质量的生成样本来进一步优化网络, 则 WACGAN 判别器的加权判别损失  $L'_S$  可以表示为

$$L'_S = E_{x \sim P_{\text{real}}(x)} [W_f(D_S(x)) \log(D_S(x))] + E_{z \sim P_r(z)} [W_f(D_S(G(z, y))) \log(1 - D_S(G(z, y)))] \quad (23)$$

式中:  $W_f(D_S(x))$  表示由判别概率  $D_S(x)$  所决定的真实样本权值,  $W_f(D_S(G(z, y)))$  表示由判别概率  $D_S(G(z, y))$  所决定的生成样本权值.

WACGAN 使用加权判别损失  $L'_S$  的目的是促使判别器  $D$  更加关注于对高质量的生成样本 ( $D_S(G(z, y)) \rightarrow 1$ ) 和被判断为假的真实样本 ( $D_S(x) \rightarrow 0$ ) 的判别, 而尽量忽略低质量的生成样本 ( $D_S(G(z, y)) \rightarrow 0$ ) 和被判断为真的真实样本 ( $D_S(x) \rightarrow 1$ ), 既对于  $D_S(G(z, y)) \rightarrow 1$  和  $D_S(x) \rightarrow 0$  的样本, 权重应增加, 对于  $D_S(G(z, y)) \rightarrow 0$  和  $D_S(x) \rightarrow 1$  的样本, 权重应减少. 则真实样本的权值系数可以表示为

$$W_f(D_S(x)) = (1 - D_S(x))^\gamma \quad (24)$$

式中:  $\gamma$  是表示权值衰减程度的参数.

生成样本的权值系数可以表示为

$$W_f(D_S(G(z, y))) = D_S(G(z, y))^\gamma \quad (25)$$

为了有效减少低质量生成样本对判别器的影响, 借鉴文献[15]所提 Focal loss 的思想并参考其实验结果, 令  $\gamma = 2$ . 此时, WACGAN 判别器的加权判别损失  $L'_S$  可以表示为

$$L'_S = E_{x \sim P_{\text{real}}(x)} [(1 - D_S(x))^2 \log(D_S(x))] +$$

$$E_{z \sim P_r(z)} [D_S(G(z, y))^2 \log(1 - D_S(G(z, y)))] \quad (26)$$

WACGAN 判别器的损失函数如下所示:

$$\max_D V(D, G) = L'_S + L_C \quad (27)$$

生成器的损失函数保持不变, 使用判别损失  $L_S$  和分类损失  $L_C$  进行计算, 如式(22)所示.

WACGAN 通过权值系数, 使判别器能够根据判别概率  $D_S$  自动选择高质量的生成样本进一步优化网络, 减少低质量生成样本对判别器的影响, 提高了判别器的识别稳定程度.

### 3.3 本文算法实现步骤

- (1) 根据式(7)对数据集进行时间镜像操作;
- (2) 从扩充的数据集中随机采样  $m$  个样本  $x$ , 从正态分布中随机产生  $m$  个噪声序列  $z$  并与标签  $y$  连接作为噪声样本;
- (3) 将样本  $x$  与噪声样本作为一批训练样本输入 WACGAN, 根据判别器的输出结果, 获取判别损失  $L_S$ , 加权判别损失  $L'_S$  和分类损失  $L_C$ ;
- (4) 将损失  $L_S, L'_S, L_C$  通过梯度回传来训练生成器和判别器, 其中为了防止生成器生成能力过强, 判别器每训练 5 次, 生成器训练 1 次.
- (5) 取出 WACGAN 的判别器, 作为雷达目标识别网络实现对雷达目标的分类识别.

## 4 实验结果与分析

### 4.1 数据集参数设置

实验数据集由 Pycharm 编程软件生成, 仿真参数设置: LFM 信号载频为 3GHz, 调频周期为 0.1ms, 调频带宽为 100MHz, 中频采样频率为 5MHz. 数值仿真实验对地面目标进行目标识别, 分别为卡车、摩托车和人. 取 1 个调频周期内的采样数据作为 1 个样本, 通过计算可知样本大小为  $1 \times 500$ , 类别标签采用独热码方式表示, 维度是  $1 \times 3$ , 标签经过平滑处理, 将表示类别的离散标签 (1, 0, 0) 替换为 (0.9, 0, 0). 训练样本集与测试样本集分别独立产生.

### 4.2 网络模型设计

由于文献[16]提出的深度卷积生成对抗网络 (Deep Convolution GAN, DCGAN) 优化了网络结构, 提高了 GAN 训练的稳定性, 在图像生成中有了广泛应用, 因此本文所提 WACGAN 中也采用 DCGAN 结构. 生成器的网络结构如表 1 所示, 其中生成器的输入由  $1 \times 100$  噪声序列和  $1 \times 3$  类别标签组成.

分类器采用 CNN 结构, 其中第三个卷积层输出的 (30, 12) 特征图经过尺度变换成 360 维的特征向量, 分别输入输出层 1 和输出层 2, 获取判别概率和分类结果, 网络结构如表 2 所示.

表 1 WACGAN 生成器结构

输入层: $1 \times 100$ 噪声序列 + $1 \times 3$ 类别标签
全连接层: $103 \rightarrow 128 * 62$ 尺度变换: $128 * 62 \rightarrow (128, 62)$ 归一化层
转置卷积层: out = 128, kernel = 4, stride = 2, padding = 1 ReLU 激活函数, 归一化层
转置卷积层: out = 64, kernel = 4, stride = 2, padding = 1 ReLU 激活函数, 归一化层
转置卷积层: out = 32, kernel = 4, stride = 2, padding = 1 ReLU 激活函数
转置卷积层: out = 1, kernel = 5, stride = 1, padding = 0 Sigmoid 激活函数
输出层: $1 \times 500$ 生成样本

表 2 WACGAN 判别器结构

输入层: $1 \times 500$ 时序信号	
卷积层: out = 6, kernel = 18, stride = 4, padding = 1 ReLU 激活函数, 归一化层	
卷积层: out = 12, kernel = 14, stride = 4, padding = 0 ReLU 激活函数, 归一化层	
卷积层: out = 30, kernel = 8, stride = 2, padding = 1 ReLU 激活函数, 归一化层 尺度变换: $(30, 12) \rightarrow 360$	
输出层 1 (判别概率)	全连接层: $360 \rightarrow 1$ Sigmoid 激活函数
输出层 (分类结果)	全连接层: $360 \rightarrow 3$ Sigmoid 激活函数

### 4.3 仿真分析

#### 4.3.1 WACGAN 生成样本

仿真实验采用 Adam 优化器, 学习率为 0.001, 动量为 0.5, 每个批次 16 个样本, 通过添加高斯白噪声的方法对数据进行加噪处理. 采用信噪比为  $-8\text{dB}$  的仿真目标回波采样数据作为网络输入, 训练集三类目标样本数均为 480, 共 1440 个样本.

实验中首先对训练数据集采取时间镜像数据增强方法, 然后将扩充数据集输入 WACGAN, 对生成器和判别器进行训练. 将含有相同噪声不同标签的噪声样本输入训练好的生成器, 生成样本如图 2 所示.

从图 2 可以看出, 虽然生成器的输入噪声相同, 但与不同的类别标签相结合后, 各生成样本差异明显, 表明生成器学习到真实样本分布, 能够产生高质量的生成样本.

#### 4.3.2 识别效果分析

##### 4.3.2.1 增强样本对识别效果的影响

为了展示增强样本对原始数据集样本分布的影响, 通过自编码器实现样本分布可视化, 实验采用信噪比为  $-8\text{dB}$  的仿真目标回波采样数据作为网络输入, 训练集三类目标样本数均为 480, 共 1440 个样本.

首先, 通过时间镜像数据增强方法, 每类目标 1:1 的产生 480 个增强样本, 并结合原始样本与增强样本形成增强数据集, 然后使用原始数据集训练自编码器, 最后将原始数据集和增强数据集分别输入到训练好的自编码器, 获取自编码器输出作为样本分布. 原始数据集和增强数据集在二维特征空间下的样本分布如图 3 所示.

从图 3(a) 可以看出, 由于训练集样本数较少, 三类目标在特征空间下的覆盖率较小, 且样本分布较分散; 而对比图 3(a)、(b) 可以看出, 增强样本提高了原始数据集在特征空间下的覆盖程度, 有效扩充了训练样本, 有助于分类器选取较好的分类面.




图 2 不同标签下的生成样本

为了体现增强样本对算法识别性能的影响, 在不同的增强样本数下对算法识别效果进行分析. 使用增强数据集分别对 CNN 和 WACGAN 进行训练, 两种方法的识

别效果如图 4 所示, 其中由于时间镜像数据增强方法只能根据真实样本 1:1 的产生增强样本, 所以本次实验每类目标的增强样本数最多为 480 个.

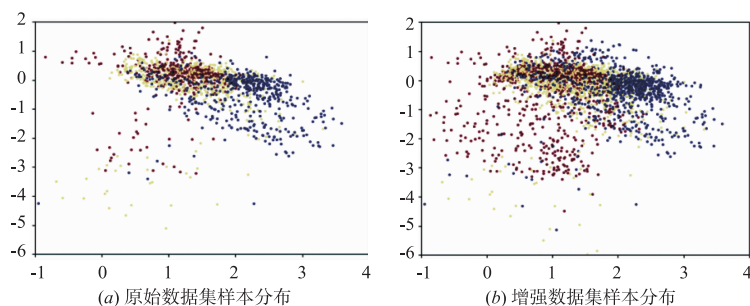


图3 数据集样本分布




图4 不同增强样本数下的识别效果

从识别效果可以看出,在小样本条件下,时间镜像数据增强方法和 WACGAN 都能够有效提高识别效果.

#### 4.3.2.2 小样本条件下的识别效果分析

为了进一步验证本文所提时间镜像数据增强方法和 WACGAN 应用在小样本条件下的有效性,在信噪比为  $-8\text{dB}$ ,训练集三类目标样本数均为 480,共 1440 个样本,测试集三类目标样本数均为 128,共 384 个样本的条件下进行识别实验.由于文献[7~9]所用 GAN 与 WGAN 的识别方法不能直接应用于多分类任务,所以实验中对文献[10,11]所提 CGAN + CNN 的识别方法进行对比.识别方法分别为 CNN,CGAN + CNN,ACGAN,WACGAN,数据增强 + CNN,数据增强 + WACGAN.其中 CGAN + CNN 采用文献[10]所提方法,利用 CGAN 生成样本扩充数据集,然后将扩充数据集输入 CNN 进行训练,对比实验中 CGAN 每类目标生成 200 个样本;ACGAN 和 WACGAN 的判别器结构与 CNN 结构相同,只是判别器的输出层同时输出分类结果和判别概率.进行蒙特卡洛实验,得到的识别结果如图 5 所示.

图 5(a)为小提琴图,其轮廓展示实验结果的密度分布,图中的横线代表中位数;图 5(b)为盒状图,单个盒形标注自上至下代表统计的最大值、上四分位、中位数、下四分位和最小值,其中绿色标记点代表离群点.从图 5 可以看出,由于训练集样本数较少,测试集可能与训练集样本差异较大,且网络训练过程中容易出现拟合现象,导致 CNN 的识别率较低,且识别率波动较大.通过比较数据增强 + CNN 和 CNN 算法的识别结果可以看出,数据增强方法有效扩充了数据集,提高了算法识别效果.将 WACGAN 算法与 ACGAN 和 CGAN + CNN 算法识别结果进行对比,可以看出,WACGAN 的识别率分布更加集中,波动幅度最小,说明使用 WACGAN 能够自动选择高质量生成样本优化网络,有效减少低质量生成样本对分类的影响,算法识别精度较高,波动较小.将数据增强方法与 WACGAN 相结合,算法识别率最高,识别效果分布也最集中.

几种方法蒙特卡洛实验的平均识别率和识别率标准差如表 3 所示.

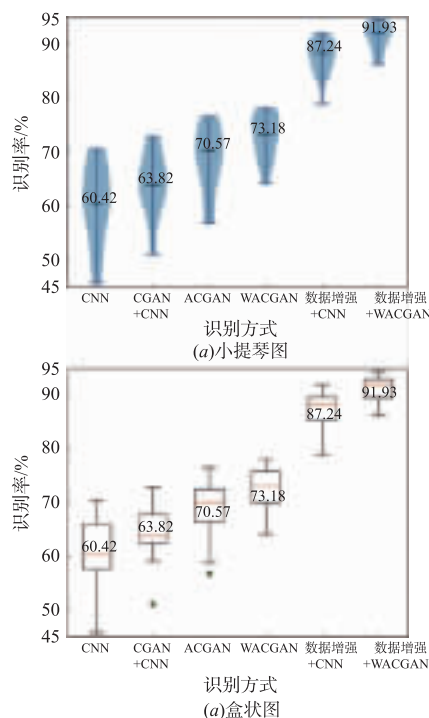


图5 蒙特卡洛实验结果

从表 3 可以看出,数据增强 + WACGAN 识别算法的平均识别率最高且识别率标准差最低,充分说明了本文算法的有效性.

不同方法的识别混淆矩阵如图 6 所示,其中混淆矩阵中每一列表示目标所属的真实类别,每一行表示识别结果,标签从上至下,从左至右依次为卡车,摩托车和人.可以看出,由于样本数较少且信噪比较低,单纯使用 CNN 无法有效识别卡车和摩托车;而 ACGAN、CGAN + CNN 和 WACGAN 识别算法均能在 CNN 的基础上提高对卡车和摩托车的识别效果,但相比之下,WACGAN 的提升效果最明显,识别率最高;数据增强 + CNN 方法,能够识别三类目标,但对卡车和摩托车的识别率相对较低;使用数据增强 + WACGAN 的识别方法能够有效识别三类目标,且对卡车和摩托车的识别率均高于其他四种方法,对人的识别率与其他四种方法的最高识别率相同,充分证明了本文所提方法的有效性.

表 3 平均识别率和识别率标准差

识别方法	CNN	CGAN + CNN	ACGAN	WACGAN	数据增强 + CNN	数据增强 + WACGAN
识别率 (%)	60.42	64.08	68.49	72.92	87.51	91.31
标准差 (%)	7.09	5.84	6.22	4.04	3.11	2.47

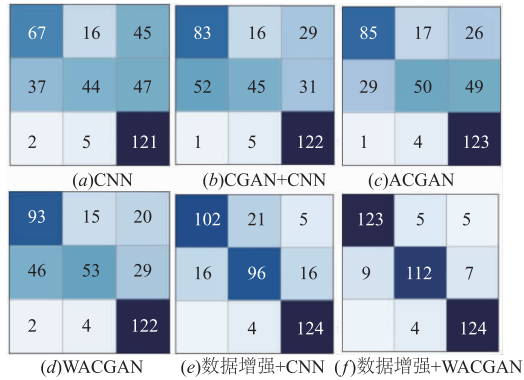


图6 识别混淆矩阵

#### 4.3.2.3 不同信噪比条件下的识别效果分析

为了进一步说明基于数据增强和 WACGAN 的雷达目标识别算法在小样本条件下的优势,对本文所提数据增强 + WACGAN、数据增强 + CNN、WACGAN、ACGAN、CNN、SVM、SMOTE + CNN 和 CGAN + CNN 等 8 种识别方法进行对比分析.其中 SVM 算法采用文献[3]的识别方法,基于频谱熵值和 RCS 特征实现目标识别;SMOTE + CNN 采用文献[6]所提算法,使用 SMOTE 算法生成样本以扩充数据集,对比实验中使用 SMOTE 每类目标生成 200 个样本;CGAN + CNN 采用文献[10]所提方法,对比实验中 CGAN 每类目标生成 200 个样本.同时为了验证本文所提识别算法的鲁棒性,在不同信噪比条件下进行识别实验.训练集三类目标样本数均为 480,共 1440 个样本,测试集三类目标样本数均为 128,共 384 个样本,用添加高斯白噪声的方法对数据进行加噪处理,信噪比分别是  $-10\text{dB}$ ,  $-8\text{dB}$ ,  $-6\text{dB}$ ,  $-4\text{dB}$ ,  $-2\text{dB}$ .进行蒙特卡洛实验,各方法的平均识别率如图 7 所示.

从图 7 可以看出,在当前实验条件下,基于数据增强和 WACGAN 的识别算法较 CNN 至少提高了 6.57%,较 CGAN + CNN 至少提高了 3.89%,较传统基于特征的 SVM 识别算法至少提高了 18.77%.仿真实验结果证明了本文方法应用在小样本条件下的优越性.

不同方法识别测试集所用时间如表 4 所示.

表 4 各方法识别时间

识别方法	数据增强 + WACGAN	CNN	SVM	CGAN + CNN
识别时间	0.021s	0.022s	4.984s	0.023s

从表 4 可以看出,由于 CNN 在识别过程中只涉及




图7 八种方法在不同信噪比下的平均识别率

前向传播,本文所提基于数据增强 + WACGAN 的雷达目标识别算法与 CNN 的识别时间是一致的;而传统基于特征的 SVM 识别算法由于其识别过程中需要提取数据特征,识别时间远远长于 CNN 的识别时间.

## 5 结论

针对小样本条件下高分辨距离像雷达目标识别算法识别率较低、识别率稳定度较差等问题,本文提出了基于数据增强和 WACGAN 的雷达目标识别算法.该算法先通过时间镜像数据增强方法扩充数据集,然后使用 WACGAN 产生并自动选择高质量生成样本进一步优化判别器,提高判别器的识别效果和识别稳定程度.仿真实验结果表明,本文算法在不增加识别时间的基础上,识别率较传统基于特征提取的 SVM 识别算法提高了 18.77%,较 CGAN + CNN 识别算法提高了 3.89%,充分证明了本文算法的有效性.

## 参考文献

- [1] Feixiang Zhao, Liu Y, Huo K, et al. Radar HRRP target recognition based on stacked autoencoder and extreme learning machine[J]. Sensors, 2018, 18(1): 173.
- [2] Feng B, Chen B, Liu H. Radar HRRP target recognition with deep networks[J]. Pattern Recognition, 2017, 61: 379 - 393.
- [3] 陈志仁, 顾红, 苏卫民, 王钊. 改进的支持向量机低分辨雷达目标分类算法[J]. 系统工程与电子技术, 2017, 39(11): 2456 - 2462.

- CHEN Z R, GU H, SU W M, et al. Improved support vector machine target classification algorithm for low-resolution radar [J]. *Systems Engineering and Electronics*, 2017, 39(11): 2456 – 2462. (in Chinese)
- [4] HU G, WANG K J, PENG Yuan, et al. Deep learning methods for underwater target feature extraction and recognition [J]. *Computational Intelligence and Neuroscience*, 2018, 2018(3): 1 – 10.
- [5] Ding J, Chen B, Liu H, et al. Convolutional neural network with data augmentation for SAR target recognition [J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 364 – 368.
- [6] SUN X J, LI J R, GU L, et al. Identifying the characteristics of the hypusination sites using SMOTE and SVM algorithm with feature selection [J]. *Current Proteomics*, 2018, 15(2): 111 – 118.
- [7] FIORE U, SANTIS A D, PERLA F, et al. Using generative adversarial networks for improving classification effectiveness in credit card fraud detection. [J]. *Information Sciences*, 2017, 479: 448 – 455.
- [8] HU C, XIONG D H, ZHANG Q Y. et al. Parallel connected generative adversarial network with quadratic operation for SAR image generation and application for classification [J]. *Sensors* 2019, 19(4): 871.
- [9] IYASS H, JAYANT S G, VINCENT F. Anomaly detection with Wasserstein GAN [DB/OL]. <https://arxiv.org/pdf/1812.02463.pdf>, 2018-12-02.
- [10] VIVEK K S, SANTIAGO R, HATEM A R, et al. Conditional Generative Adversarial and Convolutional Networks for X-ray Breast Mass Segmentation and Shape Classification [DB/OL]. <https://arxiv.org/pdf/1805.10207.pdf>, 2018-05-10.
- [11] VIVEK K S, HATEM A. R, SANTIAGO R, et al. Breast Tumor Segmentation and Shape Classification in Mammograms Using Generative Adversarial and Convolutional Neural Network [DB/OL]. <https://arxiv.org/pdf/1809.01687.pdf>, 2018-09-01.
- [12] Shorten C, Khoshgoftaar T M. A Survey on Image Data Augmentation for Deep Learning. [DB/OL]. <https://link.springer.com/article/10.1186/s40537-019-0197-0>, 2019-06-01.
- [13] GOODFELLOW I J, POUGET Abadie J, MIRZA M, XU B, et al. Generative adversarial nets [A]. *Proceedings of the 27th International Conference on Neural Information Processing Systems [C]*. New York, Curran Associates, 2014. 2672 – 2680.
- [14] ODENA A, OLAH C, SHLENS J. Conditional Image Synthesis with Auxiliary Classifier GANs [DB/OL]. <https://arxiv.org/pdf/1610.09585.pdf>, 2016-10-09.
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [A]. *IEEE International Conference on Computer Vision [C]*. Washington: IEEE Computer Society, 2017. 2999 – 3007.
- [16] ALEC R, LUKE M, SOUMITH C. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks [DB/OL]. <https://arxiv.org/pdf/1511.06434.pdf>, 2015-11-06.

#### 作者简介



**朱克凡** 男, 1994 年出生, 山东青岛人. 现为国防科技大学硕士研究生, 主要研究方向为雷达目标识别.



**王杰贵** 男, 1969 年生, 现为国防科技大学电子对抗学院副教授、硕士生导师, 研究方向为雷达信号处理.



**刘有军** 男, 1975 年生, 现为国防科技大学电子对抗学院副教授, 研究方向为电子对抗信息处理和装备计量技术研究.