

DCGAN 模型改进与 SAR 图像生成研究

徐永士 贲可荣 王天雨 刘斯杰
海军工程大学电子工程学院 武汉 430033
(815849288@qq.com)



摘要 针对 SAR 图像识别软件,通过改进 DCGAN 模型单生成器与单判别器对抗的结构,采用多生成器与单判别器进行对抗,设计了控制各生成器生成图像平均质量的算法,提出了一种基于改进的 DCGAN 生成 SAR 图像的方法。为测试和验证多个同类图像识别软件,并进行择优,需要自行设计不同于训练用的图像来对测软件进行测试。此方法可以为择优测试提供一个公平的基准测试集。实验分别使用原 DCGAN 模型和改进的 DCGAN 模型生成目标图像和场景图像,并使用公开判别器分别对两种模型生成的新图像进行质量验证。实验结果表明,改进的 DCGAN 模型比原 DCGAN 模型生成的图像效果更好,经其训练生成的新 SAR 图像与原 SAR 图像相比,质量相当且多样性更好,可以满足软件择优测试的需要。

关键词: 软件优选;生成对抗网络;图像自动生成;图像识别;图像质量检测

中图法分类号 TP311.5

Study on DCGAN Model Improvement and SAR Images Generation

XU Yong-shi, BEN Ke-rong, WANG Tian-yu and LIU Si-jie

College of Electronic Engineering, Navy University of Engineering, Wuhan 430033, China

Abstract This paper proposes a method of generating SAR images based on the improved DCGAN. This method improves DCGAN, adopts the model structure of multi-generator versus single discriminator, and uses the algorithm to control the average image quality generated by each generator. In order to test and verify multiple similar image recognition software and select the best one, testers need to design the images that are different from those used in training to test the testing software. This method can provide a fair set of benchmarks for selective testing. Respectively in the experiments, based on the original DCGAN model and the improved DCGAN model, target images and the images are generated, and the public discriminator is used to verify the quality of the new images generated by the two models. The experimental results show that the improved DCGAN model generates better images than the original DCGAN model, and the new SAR images have the same quality and better diversity as the original SAR images, and they can meet the needs of software selective testing.

Keywords Software optimization, Generative adversarial network, Automatic image generation, Image recognition, Image quality detection

1 引言

随着人工智能技术的快速发展,目标识别技术已被广泛应用于交通、公共安全、地图与地形配准、环境监测、医学研究、农林生产、工业制造^[1-7]等诸多领域。目标识别软件给我们的工作和生活带来了极大便利,但由于其数量繁多、质量良莠不齐,同时也带来了许多困扰。因此,对同类图像识别软件进行测试和验证并进行择优非常重要。

第三方组织通过软件可靠性、图像识别准确率等指标对数个同类图像识别软件进行优选。软件可靠性测试是在真实的或者接近真实的环境中,基于软件操作剖面(对软件实际使用情况的统计规律的定量描述)对软件进行随机测试,因此得到的测试结果与软件实际使用情况非常相近^[8],可以对软件

的可靠性进行验证、评估及预测,其过程如图 1 所示。




图 1 软件可靠性测试过程

Fig. 1 Process of software reliability test

图像识别准确率是评价图像识别软件质量的另一个重要指标。在 ImageNet 大规模视觉识别挑战赛中,参赛软件需要对来自 Flickr 和搜索引擎的 10 万张照片中的物体和场景进行分类和检测,而识别准确率对参赛软件质量的评价起着决定性作用^[9]。

到稿日期:2020-07-17 返修日期:2020-09-10 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国防十三五预研项目(30201)

This work was supported by the 13th Five-Year National Defense Pre-research Project of China(30201).

通信作者:贲可荣(benkerong08@163.com)

软件失效是由设计缺陷造成的,软件的输入决定了是否会遇到软件内部存在的故障,使用同一组测试用例反复测试是没有意义的,因此在软件择优测试中存在一个常见的问题:由于适用的测试数据太少,生成的测试用例不足,导致测试结果不够准确。

第三方组织在对数个同类图像识别软件进行择优时,为保证公平,不能直接使用各待测软件方提供的图像进行测试和验证,因为基于深度学习的图像识别软件在交付前需要使用大量图像进行训练,而这些图像已被训练使用过了。第三方组织可要求待测软件方提供一定数量的原图像,并采用一定的方法基于这些原图像生成大量与原图像不同但又具有质量一致性的新图像,组成基准测试集,来对待测软件进行择优测试。

合成孔径雷达(Synthetic Aperture Radar, SAR)图像的获取不受天气状况、云层覆盖等条件的影响^[10],具有全天候、强穿透、远距离等特点^[11]。将基于深度学习的 SAR 图像识别技术应用于对地军事目标的识别、侦察、制导和警戒等系统中,可提高观察-判断-决策-攻击的速度,从而提升军事目标的识别效率和系统智能化水平^[12]。

在军事应用领域,由于战场地貌、地物环境复杂度高, SAR 图像的获取难度较大^[13]。美国公开的 MSTAR 数据集是为数不多的对地面军事目标图像进行识别的数据集,其中包含军事目标和地形场景等图像。由于这些 SAR 图像具有不同的目标类型、方位角、俯仰角、外形配置变化和型号变种,因此很多 SAR 图像识别软件都是以 MSTAR 为样本库对分类器模型进行了训练。

在对多个 SAR 图像识别软件进行测试和择优时,需要生成区别于训练用的图像^[14]。为此,本文对深度卷积生成对抗网络(Deep Convolutional Generative Adversarial Networks, DCGAN)进行改进,提出了控制各生成器生成图像平均质量的算法。该算法采用多生成器对抗单判别器的模型结构,以 SAR 图像识别软件使用的 MSTAR 数据集中的目标图像和场景图像作为原始图像输入改进的 DCGAN 模型,经过训练自动生成大量的新 SAR 图像,然后使用公开的判别器对图像质量进行验证。实验结果表明,新生成的 SAR 图像与原 SAR 图像具有同等质量,且多样性较好。这些新 SAR 图像可以作为软件择优考核的测试用例。

2 生成对抗网络模型

图像自动生成技术一直是计算机视觉领域的重要研究课题。2014年,Goodfellow等^[15]提出的生成对抗网络(Generative Adversarial Networks, GAN)以零和博弈与对抗训练思想生成高质量样本,相比传统机器学习算法具有更强的特征学习和表达能力,在机器视觉特别是样本生成领域取得了显著成功,是当前研究的热点方向之一。

GAN 是一种无监督深度学习模型,其核心思想源于博弈论中的“纳什均衡”^[16]。GAN 主要是由生成器(Generator)和判别器(Discriminator)组成。一个常见的类比是将生成器视为造假者,将判别器视为鉴定者。造假者的目的是制作逼真的商品,鉴定者的目的是鉴别收到的商品的真假。两者同时训练,相互竞争,是一个无合作的竞争关系,此消彼长,总和恒为零,故称为“对抗”。GAN 的数学模型如式(1)所示:

$$\min_G \max_D \mathbf{V}(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

其中, x 表示真实样本图像, z 是输入 G 网的噪声系数, $G(z)$ 是 G 网生成的样本图像。 $p_{data}(x)$ 是真实的图像数据分布, $p_z(z)$ 是生成器 G 产生的图像数据分布。 $D(G(z))$ 表示判别器判断图像样本是否真实的概率,其结果越接近 1,表示生成的图像越接近真实图像。该模型的目标是通过训练来调整生成器模型增大 $D(G(z))$ 的参数值,同时调整判别器增大 $D(x)$,使得 $D(G(z))$ 减小,最终使两个模型均达到纳什均衡点。

对抗训练的基本过程如下:

- (1) 初始化判别器 D 和生成器 G 的参数。
- (2) 从真实样本中采样 m 个样本 x 。从先验分布噪声中采样 m 个噪声样本 z ,并通过生成器获取 m 个生成样本。
- (3) 固定生成器 G ,训练判别器 D 以尽可能准确地判别真实样本和生成样本。
- (4) 循环多次更新判别器 D 后,使用较小的学习率来更新一次生成器 G 的参数,训练生成器 G 使其尽可能缩小生成样本与真实样本之间的差距,尽量使得判别器 D 判别错误。

经过不断的对抗训练,判别器 D 最终将无法判别样本是生成器的输出还是真实的输出,判别概率均为 0.5,即达到纳什均衡。但是 GAN 模型的劣势在于其具有不稳定性,噪音扰动大,在特征提取时容易失效,并产生一些无用的图片数据或者降低图片生成的多样性,严重时会造成模型崩溃。为此,许多学者尝试对其进行改进。

Mirza 等^[17]率先提出了条件生成对抗网络(Conditional generative adversarial nets, CGAN),并把标签数据类别信息当作模型输入,与生成图像一起作为判别条件。加入类别信息可以显著地提高生成图像的质量^[18],而更加详细的图像信息能增强模型的生成效果。监督信息虽然可以显著提高模型的精度,但是该方法对网络的生成能力并没有进行相应的扩展,而这种能力恰恰是生成对抗网络的核心^[19]。

Zhang 等^[20]提出了协作式生成网络结构,使多个生成模型能够协作训练、相互学习,以提高模型与真实数据的拟合能力,进而提高图像生成的质量。实验对比发现,模型在人脸图片等二维图像生成方面有显著效果。协作机制加快了模型收敛的速度,提高了训练效率,消除了损失函数的噪声,对三维模型也有积极影响。在该机制中,模式坍塌的问题也可以通过调整参数来遏制。

Radford 等^[21]在 GAN 的基础上添加深度卷积神经网络结构,提出了将 CNN 和 GAN 相结合的 DCGAN。DCGAN 网络结构在 GAN 的基础上采用了全卷积网络,舍弃确定性的 CNN 池化层,但判别器仍保留 CNN 的整体架构,生成器则是将卷积层替换成了反卷积层并取消全连接层,生成器输出层使用 Tanh(Sigmoid) 激活函数,其余层全部使用 ReLU 激活函数。判别器所有层都使用 LeakyReLU 激活函数,以防止梯度稀疏。改进后的 DCGAN 不仅保留了 GAN 优秀的数据生成能力,还融合了 CNN 特征提取的优势,因此其在图像分析和处理方面的性能均得到了很大的提升,不仅提高了图像分类的准确性,而且有效避免了特征提取的噪声数据对生成图像的干扰。

DCGAN 模型作为无监督学习中比较有效的模型,相比

传统的有监督学习的深度学习网络模型,其所需的训练数据集无需进行大量的人工标注,节省时间且高效^[22],为后续实验提供了合适的理论条件基础。

3 DCGAN 模型的改进

利用 DCGAN 模型基于 MSTAR 数据集生成 SAR 图像时,生成的新图像样本过于单一、质量较差,且准确性不高,在训练后期模型会把噪声光斑误认为图片本身的特征,导致后期图像失真严重且光斑较大。

为解决上述问题,保证新生成图像的质量和多样性,我们对 DCGAN 模型加以改进。

DCGAN 的目标损失函数如式(2)所示:

$$\begin{aligned} \text{loss}(D) &= \frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))] \\ \text{loss}(G) &= \frac{1}{m} \sum_{i=1}^m \log(1 - D(G(z^{(i)}))) \end{aligned} \quad (2)$$

其中, $D(x)$ 为真实图像的概率; $G(z)$ 为生成器 G 生成的假图像; $D(G(z))$ 为 G 生成假图像的概率。 G 的目标是生成的假图像能够具有与真图像同等的质量和多样性,从而达到混淆真假的效果,因此,我们希望 $D(G(z))$ 的数值更大。

我们采用多个生成器与判别器进行对抗,改进后的目标损失函数如式(3)所示:

$$\frac{1}{n} \sum_{i=1}^n \min_{G_i} \max_D \text{loss}(D, G_i) = \frac{1}{m} \sum_{i=1}^m [\log D(x^{(i)}) + \log(1 - D(G(z^{(i)})))] \quad (3)$$

将生成器的个数增加为 n ,采用求和平均的方法尽可能地提高每批次图像训练的平均质量,在每次训练的过程中,将生成的假图像与真图像等比例混合后再交给判别器判定真假,以保证假图像尽可能地与真图像质量相当且多样性更好。

DCGAN 模型使用单个生成器与单个判别器对抗的结构,其工作原理如图 2 所示。




图 2 DCGAN 工作原理图

Fig. 2 Working principle of DCGAN

改进后的 DCGAN 模型采用多个生成器与判别器进行对抗,其工作原理如图 3 所示。

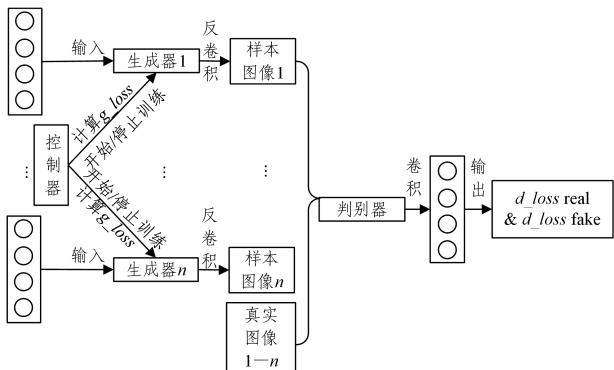


图 3 改进后的 DCGAN 工作原理图

Fig. 3 Working principle of improved DCGAN

在训练过程中需要控制各个生成器在每次训练时生成图像的平均质量,但是由于生成器的可解释性不足,在梯度下降的过程中存在随机性,训练过程并非完全可控,因此不同生成器的训练过程并不相同,导致同一批次训练中各生成器生成的图像质量相差较大,有的生成器过早结束训练,而有的生成器并不收敛。

为此,本文提出了一种控制各个生成器生成图像的平均质量的算法,如算法 1 所示。

算法 1 生成器速度控制算法

```

Begin
While(不满足停止训练条件)
计算上次训练生成器平均损失函数  $\bar{g\_loss}$ 
计算本次训练生成器损失函数  $g\_loss$ 
If( $\frac{|\bar{g\_loss} - g\_loss|}{g\_loss} \leq 0.1$ )
符合条件的生成器参加下次训练
While( $g\_loss > \bar{g\_loss}$ )
单独训练直至损失函数值接近平均值;
Break;
While( $g\_loss < \bar{g\_loss}$ )
停止本生成器训练;
Break;
End;
End

```

不同生成器训练的收敛速度并不相同,可能造成每个训练批次各个生成器生成的图像质量不一致,最终导致模型崩溃。针对这一问题,本文采用各个生成器的 $loss$ 值与上一次训练的平均 $loss$ 值的差值这一指标来控制生成器停止或者开始训练动作。如果单个生成器的 $loss$ 值远大于上一次训练的平均 $loss$ 值,则说明这个生成器训练得过于缓慢,将会严重影响生成图像的平均质量,此时将暂停其他生成器的训练动作,生成器将进行单独训练直至其 $loss$ 值与上一次训练的平均 $loss$ 值的差值较小;如果单个生成器的 $loss$ 值远小于上一次训练的平均 $loss$ 值,则说明这个生成器训练得过于迅速,需要停止训练以等待其他生成器训练。使用这一算法能有效控制每个训练批次的平均质量。

经实验验证,DCGAN 的初始学习率在 0.000 2~0.001 的区间内效果较好。在初始化生成器的过程中,本文将学习率随机设置为 0.000 2~0.001 区间内的值并分配给各生成器,并且由于训练中噪声函数 $f(z)$ 是一个完全随机的高维函数,而在学习过程中各个神经元层的特征值不同,因而改进后的 DCGAN 模型从理论上可以保证各个生成器最后收敛时的图像特征具有多样性。

4 实验步骤与结果分析

本文实验主要包括 3 部分内容:使用原始 DCGAN 和改进的 DCGAN 两种模型生成目标图像;使用两种模型生成场景图像;将两种模型生成的新图像与原图像对比以对新生成图像进行质量验证。

4.1 实验数据集与预处理

实验所用的硬件配置为 CORE i7-9700 的 CPU,3.00 GHz,6 GB 大小的 RTX2060 显卡和 16 GB 的内存。操作系统为

Win10 家庭版, 软件为 Aconda 3.0, TensorFlow1.14.0, Python 3.7. DCGAN 模型训练目标图像的时间为 22 h 37 min, 训练场景图像的时间为 12 h 27 min, 训练时间共计约 35 h. 改进后的 DCGAN 模型使用 3 个生成器训练目标图像的时间为 26 h 7 min, 训练场景图像的时间为 14 h 37 min, 训练时间共计约 40 h.

MSTAR 数据集中包含多目标集 (PUBLIC_MIXED_TARGETS)、混合多环境场景集 (PUBLIC_Clutter), 以及单一目标的多型号分类数据集 (PUBLIC T72Variants). 由于 MSTAR 的数据格式为 jpeg, 而 DCGAN 模型要求输入单通道灰度图片, 因此需要先将 jpeg 格式转换为 jpg 格式. 运用 cmd 命令格式转换语句, 共转换 13 685 张图片. 通过人工筛选剔除一些噪声光斑较大、特征不够明显的图像后, 剩余 13 002 个训练样本, 经过预处理后各数据集可用图数量如表 1 所列.

表 1 预处理后各数据集可用图数量汇总

Table 1 Summary of number of graphs available for each preprocessed dataset

MSTAR	Number
PUBLIC_MIXED_TARGETS	4231
PUBLIC_Clutter	4594
PUBLIC T72 Variants	2176
PUBLIC Target Chips	2001

本文采用 MSTAR 数据集中的目标图像和场景图像进行实验和验证. 在进行目标图像生成实验时, 选用 MSTAR 数据集中 T72 主战坦克、BMP2 装甲车、BTR-70 装甲运输车 3 种不同型号的军事目标 SAR 图像作为输入图像, 这 3 种目标图像的数量如表 2 所列.

表 2 各型号的目标图像数量汇总

Table 2 Summary of number of target images of each model

Target Type	Model	Pitching Angle			
		15°	17°	30°	45°
T72	SN_132	320	340	0	480
	SN_812	341	493	271	0
	SN_S7	472	450	0	338
BTR70	SN_C71	294	0	542	0
	SN_C21	282	254	0	492
BMP2	SN_9563	0	483	487	444
	SN_9566	584	609	0	532

在进行场景图像生成实验时, 使用 MSTAR 数据集中的混合多环境场景集 (PUBLIC_Clutter), 挑选 15° 和 17° 的平原、山地、森林场景图像, 并通过人工甄别去掉一些图像辨识度低、噪声干扰过大、图片全黑等不符合实验要求的图像, 将筛选后的图像作为输入图像, 则 3 种场景可用图像的数量如表 3 所列.

表 3 各场景图像数量汇总

Table 3 Summary of number of images in each scene

PUBLIC_Clutter	Number
Plain	2339
Mountain	1224
Forest	1031

4.2 目标图像生成实验结果与分析

在目标图像生成实验中, 分别以 DCGAN 模型和改进的

DCGAN 模型进行训练. 实验将目标图像进行有效混合, 各进行了 1 000 epoch 的训练, 并将结果进行对比. 由于 DCGAN 模型提取特征时, 训练图像的特征结构较为简单, 生成器的学习速度与判别器的学习速度可能不一致, 从而影响了其生成图片的质量, 严重时甚至可能出现不收敛的情况, 因此将初始学习率设置为 0.002, 这样每训练 1 次判别器, 就会训练 3 次生成器. 改进后的 DCGAN 模型的生成器根据初始学习率的不同, 每训练 1 次判别器, 就会训练 3~4 次生成器, 使得判别器 D 和生成器 G 的损失率得到有效收敛并相互产生震荡, 在相互学习的过程中不断提升产生图片的质量和判定图像的准确性. 两种模型的生成器均使用 Relu 激活函数, 相比 Tanh 其更符合低精度图像的训练, 能更好地掌握图像的特征, 提高图像质量, 其采用 4 核卷积链接, 卷积核大小为 4 * 4, 步长为 2. 图 4 展示了在 100 epoch, 500 epoch, 1 000 epoch 时, DCGAN 模型和改进的 DCGAN 模型生成的新目标图像与原目标图像的对比结果.

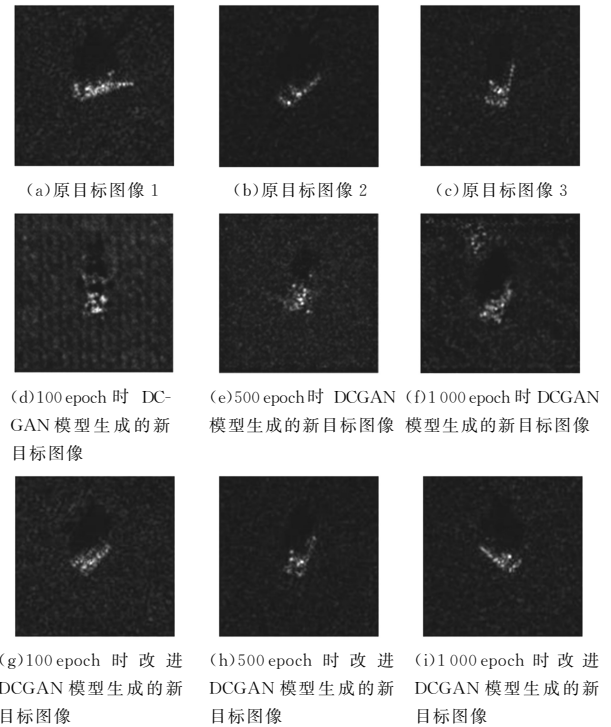


图 4 生成目标图像与原目标图像的对比

Fig. 4 Comparison between generated target images and the original target images

从图 4 可以看出, 两种模型的生成器都能确定图像的基本特征, 包括方位角特征、目标外形轮廓等, 已经能产生较为完整的图像. 但是改进后的 DCGAN 模型生成的图像与原始 DCGAN 模型相比, 光斑数量更少且范围更小, 并且俯仰角各不相同, 因此改进的 DCGAN 模型的图像质量有较大提升且多样性较好.

下文将使用判别器损失率、生成器损失率等指标进一步进行判断. 图 5 为 DCGAN 模型和改进的 DCGAN 模型的判别器损失率和生成器损失率, 其中改进的 DCGAN 模型的生成器损失率为各个生成器的平均损失率. 在训练开始阶段, 由于生成器训练次数较少, 不能完全识别图像特征, 此时生成的新图像与原目标图像相差较大, 判别器并不需要较多

训练就能较为准确地将其分辨出来。随着训练的不断进行,生成器提取到的图像特征越来越充分,新图像与原目标图像的差距逐渐缩小,判别器开始进行学习,具体表现为判别器的损失率曲线不断震荡。此外,随着训练的进行,生成器和判别器均不断互相学习,生成的新图像与原目标图像越来越接近,损失率曲线也不断震荡直至训练结束。从损失率曲线上看,与 DCGAN 模型相比,改进的 DCGAN 模型的 d_loss (判别器损失率)和 g_loss (生成器损失率)震荡频率较高且最终收敛,表示生成的新目标图像质量较高、多样性较好。

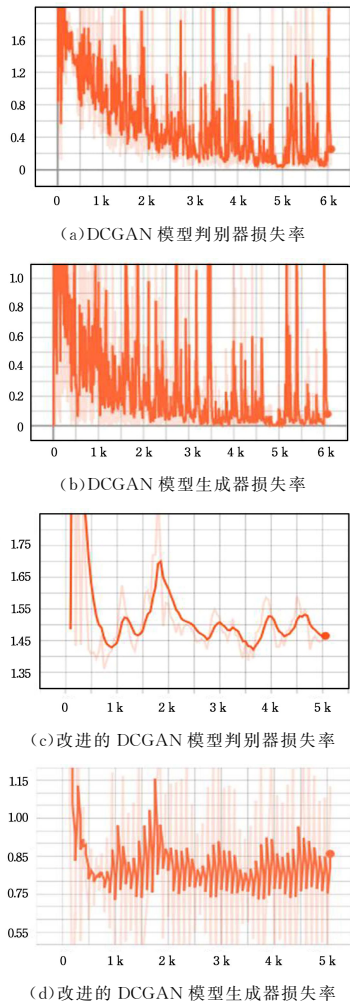


图5 判别器和生成器损失率曲线

Fig. 5 Discriminator and generator loss rate

4.3 场景图像生成实验结果与分析

在场景图像生成实验中,分别以 DCGAN 模型和改进的 DCGAN 模型进行训练。场景图像生成实验与目标图像生成实验有所不同,混合训练并不符合实际,且会出现场景混乱,不具有实际应用效果,因此实验按照森林、平原、山地 3 个场景分别进行训练。由于 MSTAR 数据集中少部分图像为全黑或者全灰,导致辨识度不高,存在噪声斑点大等特征,因此对其进行人工剔除,最终剩余 4594 张图像,学习率调整为 0.01。图 6 展示了 DCGAN 模型和改进的 DCGAN 模型以平原场景图像为输入图像,分别对 100 次、500 次、1000 次迭代训练时生成的新场景图像进行对比。可以看出,改进后的 DCGAN

模型生成的场景图像与原始 DCGAN 模型相比,光斑数量减少了,范围也缩小了,基本特征更为清晰,质量有较大提升。图 7 为 tensorboard 对图像训练日志的图像展示。




图6 两种模型生成的新场景图像对比

Fig. 6 Comparison of new scene images generated by two models




图7 判别器和生成器的损失率曲线

Fig. 7 Discriminator and generator loss rate

¹⁾ <https://github.com/kozistr/Awesome-GANs/tree/master/dcgan/model>

可以看出,两种模型的 d_loss (判别器损失率)和 g_loss (生成器损失率)震荡均较为频繁,但与 DCGAN 模型相比,改进的 DCGAN 模型损失率曲线更加平缓,没有出现大量的不能作为最后实验数据的干扰样本图像,各个生成器都能够模仿训练集中的图像特征,说明改进的 DCGAN 模型生成图像的效果更好。

4.4 生成图像质量验证

为了保证生成图像质量验证结果的客观公正,实验以公开的 DCGAN 判别器^[1]模拟待测的图像识别软件对生成图像的质量和多样性进行验证。验证标准为:如果分别以生成的新图像和原图像作为输入,二者在相同的公开判别器上的数据保持一致或相似,则表明生成的新图像与原图像质量一致。

由于采用公开发表的 DCGAN 预训练模型(pre-trained model)进行实验,因此预训练模型中的参数已经固定,分别将 500 张原 SAR 图像、DCGAN 模型生成图像、改进的 DCGAN 模型生成图像作为输入,验证两种模型生成的新图像与原图像相比的质量水平。图 8 为分别输入 3 种图像时判别器的判别概率曲线。从图中可以看出,与原 DCGAN 模型相比,当输入改进的 DCGAN 生成的图像时,判别器的判别概率曲线随着训练的不断进行,与输入原 SAR 图像时判别器的判别概率曲线已经非常接近。

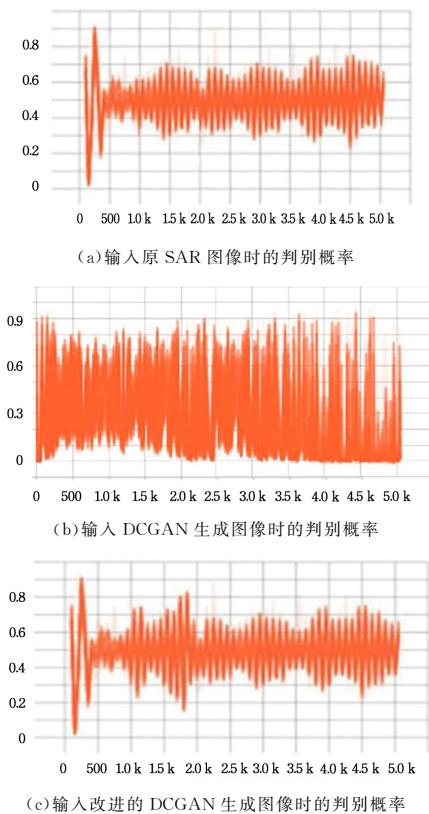


图 8 判别器的判别概率

Fig. 8 Discriminant probability of discriminator

表 4 列出了程序输出的判别器判别概率值。输入改进后的 DCGAN 模型生成的 500 张新图像时,判别器的判别概率是 0.5195,与以 MSTAR 数据集中 500 张原 SAR 图像作为输入时判别器的判别概率 0.5136 相差仅 0.59%,而以原 DCGAN 模型生成的 500 张新图像作为数据集进行测试时,

判别器的判别概率相差达 5.61%。可以看出,使用改进的 DCGAN 模型生成的新图像与原 SAR 图像的质量相差不大,新图像的生成效果与原 DCGAN 模型相比却有很大的提升。

表 4 实验结果对比

Table 4 Comparison of experimental results

Input Image	Probability of Discriminant
Images Generated by Improved DCGAN	0.5195
Original SAR Image	0.5136
Images Generated by DCGAN	0.5427

在本实验中,改进的 DCGAN 模型生成的新图像在相同的公开判别器上的判别概率曲线和原 SAR 图像的判别概率曲线极为相似,表明生成的新图像与原图像具有同等质量。

结束语 本文提出了基于改进的 DCGAN 自动生成测试用 SAR 图像的方法,以 MSTAR 数据集中的 SAR 图像作为输入,通过训练自动生成大量新的 SAR 图像,并使用公开的 DCGAN 预训练模型判别器对这些新图像进行质量验证。从图像表征和实验结果来看,改进的 DCGAN 模型生成器能够确定图像的基本特征,包括方位角特征、目标外形轮廓等,生成的新图像具有和原图像同等的质量和更好的多样性。本方法可以生成区别于训练用的图像,以满足多个 SAR 图像识别软件进行测试和择优的需要。

参考文献

- [1] SPENCER JR B F, HOSKERE V, NARAZAKI Y. Advances in computer vision-based civil infrastructure inspection and monitoring[J]. Engineering, 2019, 5(2): 199-222.
- [2] LIN J, LI X, PAN H. Aircraft recognition in remote sensing images based on deep learning[C]// Proceedings of 33rd Youth Academic Annual Conference of Chinese Association of Automation(YAC). Nanjing: IEEE, 2018: 895-899.
- [3] YAGHOUBI H, MANSOURI H, FARSANGI M A E, et al. Determining the fragmented rock size distribution using textural feature extraction of images[J]. Powder Technology, 2019, 34(2): 630-641.
- [4] RAUL O P. Using TensorFlow-based neural network to estimate GNSS single frequency ionospheric delay[J]. Advances in Space Research, 2019, 63(5): 1607-1618.
- [5] LOU M Y, LIU Y Q, YANG F, et al. Image enhancement of palm veins based on adaptive fusion and Gabor filter[C]// Proceedings of the 5th Fuzzy Systems and Data Mining. Kitakyushu City, Japan. IOS Press. 2019: 296-304.
- [6] MOHAMED A A, BERG W A, PENG H, et al. A deep learning method for classifying mammographic breast density categories[J]. Medical Physics, 2018, 45(1): 314-321.
- [7] YAN Q, GONG D, ZHANG Y. Two-Stream Convolutional Networks for Blind Image Quality Assessment[J]. IEEE Transactions on Image Processing, 2019, 28(5): 2200-2211.
- [8] WANG Y C, GAO J H. Test Case Assignment and Selection Method Based on Run Profile[J]. Computer Engineering, 2020, 46(6): 216-220.

- [9] OLGA R, JIA D, HAO S, et al. ImageNet Large Scale Visual Recognition Challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [10] FEI G, TENG H, JIN S, et al. A New Algorithm of SAR Image Target Recognition Based on Improved Deep Convolutional Neural Network[J]. Cognitive Computation, 2019, 11 (6): 809-824.
- [11] DING B Y, WEN G J, YU L S, et al. Matching of attributed scattering center and its application to synthetic aperture radar Automatic Target Recognition [J]. Journal of Radar, 2017, 6(2): 157-166.
- [12] LI G L, MA Y F. Air Combat Situation Feature Extraction Based on Deep Network [J]. Journal of System Simulation, 2017, 29(S1): 98-105, 112.
- [13] MIAO S, LIU X. Joint sparse representation of complementary components in SAR images for robust target recognition [J]. Journal of Electromagnetic Waves and Applications, 2019, 33(7): 882-896.
- [14] CASTELLAZZI P, DOODY T, PEETERS L. Towards monitoring groundwater-dependent ecosystems using synthetic aperture radar imagery[J]. Hydrological Processes, 2019, 33 (25): 3239-3250.
- [15] IAN G, JEAN P, MEHDI M, et al. Generative Adversarial Nets [C]// ACM. The 27th International Conference on Neural Information Processing Systems. Canada. New York: ACM, 2014: 2672-2680.
- [16] LILLIAN J R, SAMUEL A B, SHANKAR S. Characterization and computation of local Nash equilibria in continuous games [C]// Proceedings of the 51st Annual Allerton Conference on Communication, Control, and Computing (Allerton). Monticello, IL, USA; IEEE, 2013; 917-924.
- [17] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. Computer Science, 2014, 27(8): 2672-2680.
- [18] VAN O A, KALCHBRENNER N, ESPEHOLT L. Conditional image generation with Pixel CNN decoders[C]// Proceedings of Advances in Neural Information Processing Systems. Barcelona, Spain; Curran Associates, Inc. , 2016: 4790-4798.
- [19] SCOTT R, ZEYNEP A, SANTOSH M, et al. Learning what and where to draw[C]// Proceedings of Advances in Neural Information Processing Systems. Barcelona, Spain; Curran Associates, Inc. , 2016: 217-225.
- [20] ZHANG L, ZHAO J Y, YE X L, et al. Collaborative Generation of Confrontation Networks[J]. Acta Automatica Sinica, 2018, 44(5): 804-810.
- [21] RADFORD A, METZ L, CHINTALA S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks[J]. arXiv:1511.06434.
- [22] ZHU L, CHEN Y, GHAMISI P, et al. Generative adversarial networks for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(9): 5046-5063.



XU Yong-shi, born in 1989, postgraduate, engineer. His main research interests include software quality assurance and software testing.



BEN Ke-rong, born in 1963, Ph.D, professor, Ph.D supervisor, is an outstanding member of China Computer Federation. His main research interests include software quality assurance and artificial intelligence.