

DOI: 10.3969/j.issn.1009-9492.2021.06.008

张德浩, 王佳松, 陈禹平, 等. 基于VAE-MSGAN网络的复杂细节图像生成方法 [J]. 机电工程技术, 2021, 50 (06): 29-33.

基于VAE-MSGAN网络的复杂细节图像生成方法

张德浩^{1,2}, 王佳松¹, 陈禹平¹, 王 帅¹

(1.中国科学院长春光学精密机械与物理研究所, 长春 130033; 2.中国科学院大学, 北京 100049)

摘要: 生成式对抗网络被广泛应用于图像生成领域, 但其在图像生成时模型不易收敛, 导致生成图像的局部细节易出现背景模糊问题。将变分自动编码器与生成式对抗网络相结合, 在两者图像生成方面优势相结合的基础上, 引入多尺度判别器, 提出了VAE-MSGAN网络模型。通过不同尺度的卷积核可以提取到更加丰富的特征信息, 并通过加入批标准化(BN)层与特征融合处理, 从而加快网络的收敛速度, 有利于特征信息的有效利用, 再将两者提取到的特征信息进行融合, 最后将改进的正则化方法应用到目标函数中, 减小网络复杂度和过拟合, 提升了GAN模型的训练稳定性和图像的局部细节生成质量。对设计的图像生成算法基于Ubuntu16.04环境下利用Tensorflow深度学习框架进行了实现和仿真。对比在不同军事图像类别上的图像生成质量, 通过交叉验证证明生成图像与真实图像在深度学习分类器下分类准确率基本一致, 验证了所设计网络模型的有效性。

关键词: 图像样本生成; 卷积神经网络; 生成式对抗网络; 变分自动编码器

中图分类号: TP391.4

文献标志码: A

文章编号: 1009-9492(2021)06-0029-05

Method of Complex Detail Image Generation Based on VAE-MSGAN Network

Zhang Dehao^{1,2}, Wang Jiasong¹, Chen Yuping¹, Wang Shuai¹

(1. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;

2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Generative adversarial networks is widely used in the field of image generation, but it is not easy to converge in the process of image generation, which leads to the problem of fuzzy background in the local details of the generated image. Combined variational auto-encoder with generative adversarial networks, multi-scale discriminator was introduced based on their advantages in image generation, and VAE-MSGAN network model was proposed. More abundant feature information could be extracted by convolution kernel of different scales, and by adding Batch Standardization(BN) layer and feature fusion processing, the convergence speed of the network could be accelerated, which was conducive to the reuse of feature information. Then the feature information extracted from the two was fused. Finally, the improved regularization method was applied to the objective function to reduce the network complexity and over fitting, it improved the training stability of GAN model and the quality of local detail generation. The image generation algorithm was implemented and simulated by using Tensorflow deep learning framework in the environment of Ubuntu 16.04. By comparing the image generation quality of different military image categories, through cross validation, the classification accuracy of the generated image and the real image is basically consistent under the deep learning classifier, which verifies the effectiveness of the designed network model.

Key words: image samples generation; convolutional neural network; generative adversarial networks; variational auto-encoder

0 引言

现阶段深度神经网络在特定行业应用时图像训练样本较少, 采用生成式对抗技术实现图像训练样本的生成可以增加图像集中图像的多样性, 并对图像数据集中图像数量进行增广, 减轻在搜集和标记图像中使用的工作量。生成式对抗网络模型(Generative Adversarial Networks, GANs)相较于自回归模型和自动编码器模型需要大量先验知识和大量参数, 可以实现无监督学习, 同时能够反映数据内在的概率分布规律并生成全新数据, 因而在图像生成、图像修补^[1]、图像超分辨^[2-3]、草稿图复原^[4]、图像上色^[5-6]、图像风格变换^[7-9]、视频生成^[10]和文字生成图像领域有着广泛应用。

近年来, GAN的发展日新月异, 国内外对于GAN进行了深入研究。Mirza M等^[11]提出了CGAN, 在GAN中添加额外的条件信息 c , 在GAN中添加有监督的学习方式, 引导GAN生成固定方向的图像, 稳定GAN的训练。Chen X等^[12]提出了InfoGAN, 通过引入互信息量, 将条件变量 c 拆解为有隐含意义的条件 c 和无意义的噪声, 使得GAN的行为在某种程度上可以解释。Odena等^[13]提出ACGAN(Auxiliary Classifier GAN), 以条件重构的形式使GAN能够生成指定图像。Alec Radford等^[14]提出了DCGAN, 将卷积神经网络与GAN相结合, 从网络模型和训练GAN技巧方面改进网络, 提升训练的稳定性, 一定程度上解决了模型易崩溃的问题。Arjovsky等^[15]提出了

Wasserstein GAN (W-GAN), 改变了原始GAN的优化代价函数, 直接用其他分布度量来提供优化目标, 将代价函数由交叉熵变为推土机距离, 解决GAN易崩溃的原理性问题。Denton E等^[16]提出了一种LAP-GAN模型, 通过叠加不同的生成器网络, 由一张低分辨率图像最终生成高分辨率图像。Zhao J B等^[17]提出EBGAN, 将GAN中的判别器使用自动编码器作为代替, 通过将自动编码器的重构误差视为图像样本的能量, 有效地改善了生成样本的多样性。上述文献虽然提出了一定稳定GAN训练的方法, 但对于图像生成时纹理细节部分模糊的情况未作具体的分析和改进, 同时加入先验信息一定程度上使GAN这一无监督学习深度学习模型变为有监督学习, 在提升了训练稳定性的条件下, 失去了无监督学习的意义。文章通过对生成式对抗网络进行模型研究, 在GAN的基础上将生成式对抗网络与变分自编码器相结合, 应用深度卷积模型作为判别器, 增强模型兼容性, 提升训练的稳定性, 同时采用多尺度判别器, 解决生成图像局部模糊的问题, 最终设计了一种多尺度判别变分编码-生成式对抗网络 (Variational Auto-Encoder and Multiscale Generative Adversarial Networks, VAE-MSGAN) 模型结构, 通过该网络模型稳定了GAN训练, 同时在多个尺度下判别图像局部信息的真实性, 使其具有复杂背景图像的生成更加清晰的特点。最后, 针对特定领域图像数据集, 将文章中所提算法生成图像与真实图像的分类结果相似性对比, 实验结果表明了所提算法的有效性。

1 GAN网络模型

在生成式对抗网络中, 包括生成模型和判别模型。生成器的作用是通过使生成样本数据分布逼近真实样本数据分布, 进而生成一个真实图像, 判别器的作用是作为一个分类器, 用以判断所生成的图像和真实图像是否一致。为实现图像生成, 将随机噪声输入到生成器中, 输出生成图像; 然后将真实图像样本和生成图像输入到判别器中, 进行判别图像真伪。模型的优化过程是训练生成器和判别器, 在对生成式对抗网络进行训练时, 固定判别器或者生成器其中一方, 更新另一方的参数, 然后交替执行此步骤, 每一次更新目的都是使另一方的错误最大化。最终, 网络训练处于纳什均衡状态, 此时生成器生成的图像基本与真实图像一致, 达到生成图像目的。

GAN的生成图像原理和模型如图1所示。




图1 GAN的模型结构

1.1 GAN模型优化目标函数

在通过GAN对图像进行生成时, GAN模型算法的总体目标优化函数如下所示:

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

式中: $P_{\text{data}}(x)$ 和 $P_z(z)$ 分别是真实数据和生成数据的分布, 即真实图像的像素值矩阵和生成的图像像素矩阵。

整个生成式对抗网络的训练过程, 就是对上式进行最大化最小化交替训练的过程。

在GAN网络训练过程中, 当生成器固定时, 优化判别器得到目标函数的极小值, 而当判别器固定时, 求取生成器目标函数的极小值, 但是生成器和判别器的极小值并不一定是处在同一个位置上, 所以就会有一个全局的次优或者说折中的均衡点, 这个点就是纳什均衡点。

当固定生成器的网络参数, 训练判别器的网络时, 式(1)可化作:

$$V = \int_x P_{\text{data}}(x) \log(D(x)) dx + \int_x P_c \log(1 - D(x)) dx = \int_x [P_{\text{data}}(x) \log(D(x)) + P_c(x) \log(1 - D(x))] dx \quad (2)$$

此时如果要通过优化 D 使目标函数 V 最大, 就可以转化为求积分项最大, 即优化 D 使下式最大:

$$f(x) = P_{\text{data}}(x) \log(D(x)) + P_c(x) \log(1 - D(x)) \quad (3)$$

因为真实样本分布一致, 生成器固定, 所以此时 P_{data} 与 P_c 已经固定为常值, 将上式求导, 即可以得到判别器网络的当前全局最优值如下所示:

$$D^*(x) = \frac{P_{\text{data}}(x)}{P_{\text{data}}(x) + P_c(x)} \quad (4)$$

将上式代入总体优化目标函数式(2)中, 可得下式:

$$\begin{aligned} V(G, D^*) &= -2 \log 2 + \int_x P_{\text{data}}(x) \log \frac{P_{\text{data}}(x)}{(P_{\text{data}}(x) + P_c(x))/2} dx + \\ &\int_x P_c(x) \log \frac{P_c(x)}{(P_{\text{data}}(x) + P_c(x))/2} dx = \\ &-2 \log 2 + KL(P_{\text{data}}(x) \parallel \frac{P_{\text{data}}(x) + P_c(x)}{2}) + \\ &KL(P_c(x) \parallel \frac{P_{\text{data}}(x) + P_c(x)}{2}) = \\ &-2 \log 2 + 2JS(P_{\text{data}}(x) \parallel P_c(x)) \end{aligned} \quad (5)$$

其中, JS 为 JS 散度 (Jensen-Shannon divergence), 其定义为下式:

$$JS(P \parallel Q) = \frac{1}{2} KL(P \parallel M) + \frac{1}{2} KL(Q \parallel M) \quad (6)$$

式中: $M = \frac{1}{2}(P + Q)$; $KL(P \parallel M)$ 为 P 和 M 的 KL 散度。

优化目标函数要使 V 最小, 需要使上式中 JS 散度最小, 而 JS 散度最小时为0, 此时, 需满足条件如下式所示:

$$P_c(x) = P_{\text{data}}(x) \quad (7)$$

此时生成分布与真实分布相等, 优化函数最终目标达成, 可视为GAN生成了真实样本分布, 即GAN的训练成功的充分必要条件是真实样本分布与生成样本分布一致。

1.2 GAN模型训练优化过程

通过生成式对抗网络对图像进行生成时, 在训练判别器时, 需尽可能判断出真实图像为真, 即真实数据通

过判别器的判别值应为1, 同时需尽可能判断出生成图像为假, 即生成数据通过判别器的判别值应为0。在训练生成器时, 尽可能使生成器的输出图像为真, 也就是使生成图像通过判别器时为真, 判别值应为1。

生成器与判别器通过不断地进行博弈学习, 最后判别器无法判别输入数据是否为生成器生成, 此时不论输入的是生成图像还是真实图像, 分类器判断输入的概率都是真实的概率都近似为0.5, 此时可视为生成器生成了真实图像样本。

图2所示为GAN的简化训练过程, 可以看出在优化过程中, 采用交替训练判别器和生成器的方式, 每进行 k 次对判别器的优化, 相应的再进行1次生成器的优化。这样只要生成器的变化足够慢, 判别器的值就基本稳定在其最优解的附近。




图2 GAN优化过程

2 VAE-MSGAN网络模型

VAE-MSGAN将变分自编码器与生成式对抗网络结合, 在本课题中, 真实图像首先通过变分自编码器的编码器进行编码, 得到隐性变量, 将隐性变量通过解码器得到VAE所生成的图像, 随机噪声通过生成器得到生成图像, 随机噪声的维数保持与隐性变量一致。真实图像、GAN的生成图像、VAE的生成图像同时通过判别器进行判别, 通过对抗训练使随机噪声生成真实图像。通过变分自编码器与GAN的结合, 可以得到其训练过程, 可以看出解码器与生成器的作用以及输入输出大小相同, 所以可以在网络模型中将二者合为一个上采样层, 这样通过将两种模型的融合可以推理出其训练过程。

VAE-MSGAN的基本结构如图3所示。




图3 VAE-MSGAN的基本结构

由变分自编码器可以得出编码器与解码器的优化函数, 编码器的作用是由真实数据得到隐性表达 z , 过程可以描述为:

$$z = Enc(x) \sim q(z|x) \quad \tilde{x} = Dec(z) \sim p(x|z) \quad (8)$$

变分自编码器的损失函数是期望的对数似然和先验正则化项做减法运算, 得到损失函数如下:

$$L_{VAE} = -E_{q(z|x)}(\log(\frac{p(x|z)p(Z)}{q(Z|x)})) = L_{LL} + L_p \quad (9)$$

其中:

$$L_{LL} = -E_{q(z|x)}(\log(p(x|z))), L_p = E_{q(z|x)}(\log(q(z|x))) = D_{KL}(q(z|x)||p(z)) \quad (10)$$

同时, 在生成对抗网络中, 也是由两个不同网络组成, 一个是生成器 G , 作用是将噪声或者是隐性表达 z 映射到与真实样本分布一致的空间, 其输出为 $G(z)$, 一个是判别器网络 D , D 的作用是将输入的 x 降采样分类, 输出表达为 $D(x)$, $y = D(x) \in [0, 1]$, y 是用来表明 x 是真实数据样本的概率, $1 - D(x)$ 则表示生成数据样本通过判别器判别为假样本的概率, 其中 z 的分布可以设为 $p(z)$ 。这样其目标函数如下式所示:

$$L_{GAN} = \log(Dis(x)) + \log(1 - Dis(Gen(z))) \quad (11)$$

将两种模型结合后的整体优化函数总结为:

$$L = L_{GAN} + L_{KL} + L_{LL}^D \quad (12)$$

在训练的过程中, 首先用损失函数公式(12)来同时对VAE和GAN进行训练。在对生成式对抗网络和编码器进行训练时, 首先是自动编码器更新编码器, 同时更新解码器使得输入的重建误差最小化。然后生成式对抗网络先更新判别器来判断输入样本数据是真实样本还是生成样本, 真实样本来自于真实的样本数据, 生成样本通过解码器和生成器对隐藏编码进行计算得到。

3 实验结果分析

3.1 网络模型选用及生成结果分析

在不同网络层分别使用 3×3 , 5×5 , 7×7 的卷积核进行训练, 通过不同卷积核生成图像的评价结果来确定卷积核的大小组合, 每一层网络层最优的卷积核大小。同时通过对判别器中池化操作的不同方式和进行池化操作的具体网络层数位置进行不同测试考量, 确定卷积核大小与池化操作的最优组合。

首先, 将生成器中反卷积核的大小与判别器中卷积核的大小组合成不同模式, 表1所示为所设定几种不同情况。

表1 不同模式表

卷积核	模式						
	1	2	3	4	5	6	7
反卷积	3×3	5×5	3×3	5×5	3×3	5×5	7×7
卷积	3×3	3×3	5×5	5×5	7×7	7×7	7×7

在上表所有模型中, 通过所设计网络实现图像生成时, 模式1、2、3所生成图像基本为噪声, 其他几种模式下通过主观观察, 模式4、6的生成图像质量良好, 其他几种模式能正常生成图像, 但生成图像质量较前几种模式差。通过实验结果分析, 在较高分辨率的图像中,

使用3*3的卷积核提取图像的特征时表现较差,使GAN生成图像质量较差。

在客观评价指标中,将未能正确生成对应类别图像的模式排除在外,其余几种模式下生成图像的客观评价指标如图4所示。由图可知,在模式4生成图像的Laplace梯度值与真实图像最为接近,说明生成图像的细节特点最优,其他指标与其他模式较为接近,以生成图像客观质量评价指标看,5*5的卷积核与5*5的反卷积核是本题网络模型中最优的卷积核大小。




图4 客观质量评价1

综合主观质量评价和客观质量评价,本课题所设计的深度卷积生成对抗网络模型的生成器中,反卷积层的反卷积核大小为5*5;在判别器中,卷积层的卷积核大小为5*5。

在本课题对网络模型进行设计时,在卷积核固定为5*5时,将判别器中对于池化操作的选择设为3种模式,即不采用池化、平均池化、最大池化。通过对网络的训练,可得到生成图像,在这3种模式下,平均池化时生成图像质量较差,基本不能识别图像所属类别,而最大池化与全卷机(即无池化)所生成图像以主观判断生成所属类别正确。而在客观质量评价上,具有有效生成图像的两种模式评价如图5所示。




图5 客观质量评价2

在生成图像的客观质量评价中,在均值上,不同池化操作所生成的图像平均均值近似相等,与真实图像的平均均值也近似;在方差上,不同池化操作所生成的图像同样与真实图像方差近似;在图像的熵上,不同池化操作所生成的图像同样与真实图像的熵同样近似相等,可见不用池化操作和最大池化两种模式下评价指标大小几乎一致,而最大池化模式略接近真实图像实际评价,故本文选用最大池化作为判别器中卷积操作的下采样层。

3.2 VAE-WGAN 多尺度判别网络图像生成结果分析

为验证VAE-WGAN多尺度判别网络在图像生成问题上的有效性和稳定性,同样采用主观质量生成评价,客观质量生成评价和分类器准确率3种方式对生成图片进行质量评价,并与真实图像进行对比,确定生成图像有效性,3种类别军事生成图像如图6所示。



图6 生成图像

(1) 主观质量生成评价

通过主观判断,新设计的网络模型的图像生成质量优于基于WGAN的条件DCGAN网络模型,生成的3种类别的图像都能判断生成的图像所属类别,局部图像也未失真严重。

(2) 客观质量生成评价

将每个类别100张生成图像输入到所编写程序中,计算图像的平均均值、标准差、熵和Laplacian梯度值,对比真实图像的平均图像质量和生成图像的平均图像生成质量,结果如表2所示。

表2 不同类别图像客观评价指标

模式	均值	标准差	熵	梯度值
生成 (1)	111.31	48.30	15.79	446.24
真实 (1)	106.51	48.58	14.25	426.77
生成 (2)	161.79	44.86	18.13	496.33
真实 (2)	126.13	42.41	17.97	567.45
生成 (3)	155.96	66.30	19.07	989.29
真实 (3)	137.89	62.56	18.87	1 067.07

整体客观评价如图7所示。从图中可以看出本文提出的方法所生成图像的客观评价指标参数都接近真实图像,考虑到在计算客观质量评价时图像平均的问题,可视为生成图像质量良好。




图7 整体客观质量评价

(3) 分类器准确率评价

将1 000张真实图像与其他类别的图像一同输入到VGG分类网络中,训练好模型后,将100张真实测试图像和100张生成测试图像输入到分类网络中,得到真实图像测试集的分类准确率为96%,生成图像的分类准确率为90%;将1 000张生成图像与其他类别的图像一同输入到VGG分类网络中,训练好模型后,将100张真实测试图像和100张生成测试图像输入到分类网络中,得到真实图像测试集的分类准确率为91%,生成图像的分类准确率为93%;将500张生成图像与500张坦克真实图像作为同一类别训练上述VGG分类器,再通过100张真实图像测试集和100张生成图像分别计算分类准确率,得到的真实图像分类准确率为93%,生成图像分类准确率为92%,而其他类别图像的测试集测试分类准确率基本保持不变;可以看出,通过本章中的网络模型进行生成图像,与真实图像有着较高的相似性,分类为真实图像的概率较大,同样可以用于图像样本增广,制作图像样本数据集。

从3种图像生成质量评价中,通过综合分析可知,本章所设计的基于VAE-WGAN的多尺度判别网络模型具有良好的图像生成质量,对于特定行业领域,例如军事领域的图像样本生成有着良好的作用。

4 结束语

图像生成技术一直是计算机视觉领域中的重点内容之一,并且随着近年来人工智能的发展,得到了广泛发展,而通过GAN来进行图像生成则在图像生成领域有着卓越地位,在通过GAN对图像进行生成时仍存在很多具有挑战性的问题亟待解决。本文针对特定行业领域图像训练样本缺乏这一问题,设计了复杂背景下的特定图像训练样本生成算法流程。通过分析生成式对抗网络的模型结构,设计实现了基于深度卷积生成式对抗网络的图像生成算法,并通过对比实验,确定了网络的模型结构和参数;为了解决生成图像局部失真模糊的问题,通过分析变分自编码器这一生成式模型,将之与生成式对抗网络结合,基于多尺度分类的思想,设计了一个生成式模型,将这一生成式模型的生成结果进行生成质量评价,与真实图像进行比较。因此,本文提出的方法在图像生成领域具有一定的参考意义和工程应用价值。

参考文献:

- [1] Pathak D, Krahenbuhl P, Donahue J, et al. Context encoders: Feature Learning by Inpainting[C]//The IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 2536–2544.
- [2] Dosovitskiy A, Tobias Springenberg J, Brox T. Learning to generate chairs with convolutional neural networks[C]//The IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA, 2015: 1538–1546.
- [3] Yang C, Lu X, Lin Z, et al. High-resolution image inpainting us-

- ing multi-scale neural patch synthesis[C]//The IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017: 4076–4084.
- [4] Isola P, Zhu J Y, Zhou T, et al. Image-to-Image Translation with Conditional Adversarial Networks[C]//The IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA, 2017: 5967–5976.
- [5] Larsson G, Maire M, Shakhnarovich G. Learning representations for automatic colorization[C]//European Conference on Computer Vision. Amsterdam, Netherlands: Springer International Publishing, 2016: 577–593.
- [6] WANG C, WANG C, XU C, et al. Tag disentangled generative adversarial network for object image re-rendering[C]//The Twenty-Sixth International Joint Conference on Artificial Intelligence. Beijing, China, 2017: 2901–2907.
- [7] ZHU J Y, ZHANG R, PATHAK D, et al. Toward multimodal image-to-image translation[C]//Advances in Neural Information Processing Systems. 2017: 465–476.
- [8] Liu M Y, Tuzel O. Coupled Generative Adversarial Networks[C]//Advances in Neural Information Processing Systems, 2016: 469–477.
- [9] Ho J, Ermon S. Generative adversarial imitation learning[C]//Advances in Neural Information Processing Systems. Montreal, Canada: Curran Associates, Inc, 2016: 4565–4573.
- [10] Vondrick C, Pirsaviash H, Torralba A. Generating videos with scene dynamics[C]//Advances in Neural Information Processing Systems. Montreal, Canada: Curran Associates, Inc, 2016: 613–621.
- [11] Mirza M, Osindero S. Conditional Generative Adversarial Nets [C]//Neural Information Processing Systems, Montreal, Canada. 2014: 2672–2680.
- [12] Chen X, Duan Y, Houthoof R, et al. InfoGAN: interpretable representation learning by information maximizing generative adversarial nets[C]//Proceedings of the 2016 Neural Information Processing Systems. Barcelona, Spain: Department of Information Technology, 2016: 2172–2180.
- [13] Odena A, Olah C, Shlens J. Conditional Image Synthesis With Auxiliary Classifier GANs[C]//International Conference on Machine Learning, Sydney, Australia: Springer, 2017: 745–757.
- [14] Radford A, Metz L, Chintala S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks[J]. arXiv: arXiv1511.06434, 2015.
- [15] Wang Kunfeng, Gou Chao, Wang Feiyue. Parallel vision: an ACP-based approach to intelligent vision computing[J]. Acta Automatica Sinica, 2016, 42(10): 1490–1500.
- [16] Denton E L, Chintala S, Fergus R. Deep Generative Image Models using a Laplacian Pyramid of Adversarial Networks[C]//Advances in Neural Information Processing Systems. 2015: 1486–1494.
- [17] Zhao J, Mathieu M, LeCun Y. Energy-based generative adversarial network[C]//International Conference on Learning Representations. San Juan, Puerto Rico, 2016: 1526–1534.

第一作者简介:张德浩(1993–),男,博士,研究实习员,研究领域为图像处理、深度学习。(编辑:王智圣)