

fire-GAN: 基于生成对抗网络的火焰图像生成算法

秦魁, 侯新国*, 周锋, 闫正军, 卜乐平

海军工程大学电气工程学院, 湖北 武汉 430033

摘要 针对生成对抗网络生成火焰图像质量不高、颜色难以控制的问题, 基于 HistoGAN 算法, 提出一种新的火焰生成算法 (fire-GAN)。首先, 在图像预处理环节添加火焰图像分割, 使网络不受背景的干扰, 能有效减少生成火焰发生形状变形、颜色失真的情况; 其次, 提出圆弧度损失函数, 使网络在训练过程中更加关注火焰轮廓的复杂度; 最后, 在生成器和判别器中均采用数据增强, 使网络在训练过程中保持稳定, 避免发生梯度爆炸。经实验测试, fire-GAN 生成的火焰与目标火焰的 RGB 平均误差为 2.6%, Fréchet inception distance (FID) 为 59.23, inception score (IS) 为 2.81。实验结果表明, fire-GAN 能生成与目标火焰图像颜色相近、清晰度好、真实性高的火焰图像。

关键词 生成对抗网络; 生成火焰图像; 火焰图像分割; 圆弧度损失函数; 数据增强

中图分类号 TP391.9

文献标志码 A

DOI: 10.3788/LOP220989

fire-GAN: Flame Image Generation Algorithm Based on Generative Adversarial Network

Qin Kui, Hou Xinguo*, Zhou Feng, Yan Zhengjun, Bu Leping

School of Electrical Engineering, Naval University of Engineering, Wuhan 430033, Hubei, China

Abstract We propose a novel flame generation algorithm, called fire-GAN, based on the HistoGAN algorithm to solve the issues of low quality and complex color control of flame images produced by a generative adversarial network. First, flame image segmentation is introduced in the image preprocessing link to remove background interference from the network, reduce the flame shape distortion and color distortion. Second, the roundness loss function is suggested to increase the focus of the network during training on the intricacy of the flame contour. Finally, data enhancement is implemented in the generator and discriminator to maintain the network stability during training and prevent gradient explosion. The experimental results demonstrate that the average RGB error between the flame generated by fire-GAN and the target flame is 2.6%, the Fréchet inception distance (FID) is 59.23, and the inception score (IS) is 2.81. The outcomes demonstrate the feasibility of the fire-GAN to produce a flame image with color, definition, and authenticity levels quite comparable to the target flame image.

Key words generative adversarial network; flame image generation; flame image segmentation; roundness loss function; data enhancement

1 引言

生成具有不同纹理特征、形状的火焰在诸如虚拟现实、数据生成、神经网络训练增强^[1-3]等领域有着广泛的应用。对于内容创作来说, 通常希望完全控制生成图像的语义属性^[4]。解决这个问题的方法之一是通过计算机图形学精准控制图像渲染。然而, 这种方法过程繁琐, 且需要具有动画、渲染等方面的专业知识。

近年来, 生成对抗网络 (GAN)^[5-8] 在生成逼真的图像方面取得了重大进展。这类网络仅需要学习一个易

于采样的潜在空间到真实图像的映射关系, 而不需要进行复杂的计算机图形学建模和光传输模拟。但相比于计算机图形学, GAN 不容易控制生成图像的语义属性。最近, Li 等^[9] 提出了 MixNMatch, 通过创建一个编码器和一个生成器, 在生成鸟的同时可以控制鸟的形状、姿势、颜色等特征。Karras 等^[6, 10-11] 提出了 styleGAN, 通过将不同的潜在风格向量逐渐输入到 GAN 中, 控制输出图像的风格和外观。Lin 等^[12] 提出了 Laplacian Pyramid 网络, 该网络首先通过 Drafting 网络以低分辨率传递整体风格, 然后通过 Revision 网络对局

收稿日期: 2022-03-14; 修回日期: 2022-05-13; 录用日期: 2022-06-13; 网络首发日期: 2022-06-23

基金项目: 国家自然科学基金 (41971416, 41771487)

通信作者: hxinguo2008@126.com

部细节进行高分辨率修正。王越等^[13]提出基于金字塔注意力机制的生成对抗网络,该网络通过特征金字塔注意力模块使生成图像与参考图像的结构、内容和色彩保持一致。然而将这些方法推广到火焰图像生成时面临两个困难:一是不同火焰图像的颜色特征相近,运用上述方法会使生成火焰图像与目标火焰图像的颜色特征差距过大,且这些方法生成的火焰图像的清晰度和真实性不高;二是上述方法仅能完成目标图像与生成图像一对一的映射,无法完成一对多的映射。

目前针对火焰生成问题的研究较少。Yang 等^[14]提出了 FIS-GAN,该网络能够通过编码来控制生成火焰的纹理,但仍存在两点问题:一是该网络主要针对 128×128 大小的图像生成,分辨率低;二是必须要对火焰进行编码,操作过程较为麻烦。

针对以上问题,本文提出了一种新的火焰图像生成模型,即 fire-GAN。该方法基于 HistoGAN 框架^[15],通过颜色直方图共享目标图像与生成图像的颜色信息,实现在生成火焰图像的同时控制火焰的颜色。

2 HistoGAN

fire-GAN 是在 HistoGAN 算法基础上改进而来的,主要借鉴了 HistoGAN 的两个主要方法:一是颜色直方图;二是颜色控制方法。

2.1 直方图特征

通过将目标火焰图像的颜色直方图添加到 fire-GAN 中,控制生成火焰图像的颜色。该方法借鉴了颜色恒常性文献^[16-17],采用 RGB-uv 颜色直方图特征 (uv 为色度坐标),该直方图将原图中 RGB 信息投影到色度空间中。相较于典型的三维 RGB 直方图,该直方图能减少计算机内存的使用,且能准确地传递颜色信息。

该直方图首先将原始图像的 R (红色)、G (绿色)、B (蓝色) 分量转换到 log-chroma 空间中。一个 log-chroma 空间以一个分量的强度定义,由另外两个分量归一化。以 R 分量为例,R 分量转换到 log-chroma 空间的公式为

$$\begin{cases} I_{uR}(x) = \log[I_R(x) + \epsilon] - \log[I_G(x) + \epsilon] \\ I_{vR}(x) = \log[I_R(x) + \epsilon] - \log[I_B(x) + \epsilon] \end{cases}, \quad (1)$$

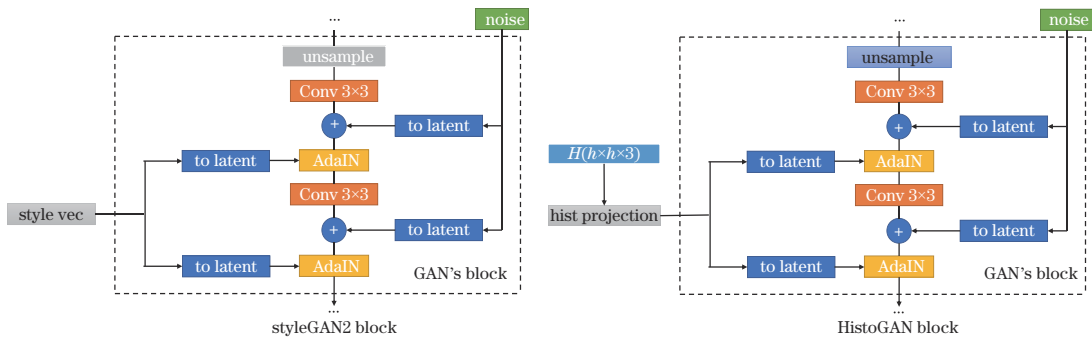


图 2 HistoGAN 与 styleGAN2 的区别

Fig. 2 Difference between HistoGAN and styleGAN2

式中: I_R, I_G, I_B 表示原图像 I 的 R、G、B 分量图; ϵ 为常量; x 为像素索引; (uR, vR) 为以 R 分量为主要通道的色度空间中的坐标。 I_{uG} 和 I_{vG} 为将 G 分量作为主要通道,按照式(1)将其转换到 log-chroma 空间; I_{uB} 和 I_{vB} 为将 B 分量作为主要通道,按照式(1)将其转换到 log-chroma 空间。

将三个分量的 log-chroma 空间组合生成直方图 $H(u, v, c)$, 计算公式为

$$H(u, v, c) = \left[s_c \sum_x I_y(x) \exp(-|I_{uc}(x) - u| / \sigma_c^2) \times \exp(-|I_{vc}(x) - v| / \sigma_c^2) \right]^{1/2}, \quad (2)$$

式中: $c \in \{R, G, B\}$; s_c 表示比例因子,控制每一个分量的比例; σ_c 表示衰减因子,控制直方图的平滑度。 I_y 表示颜色强度,计算公式为

$$I_y(x) = \sqrt{I_R^2(x) + I_G^2(x) + I_B^2(x)}. \quad (3)$$

火焰图像的 RGB-uv 直方图示例如图 1 所示。从图 1 易观察出,RGB-uv 直方图能准确地传递出三个分量各颜色值的概率。将 RGB-uv 直方图输入到 fire-GAN 中,能有效控制生成火焰的颜色。




图 1 RGB-uv 直方图示例

Fig. 1 Example of RGB-uv histogram

2.2 颜色控制方法

HistoGAN 将颜色直方图整合到 styleGAN2^[11], 以控制图像颜色。HistoGAN 主要对 styleGAN2 进行两点修改:第一,在 styleGAN2 最后两层,用直方图特征替换样式向量作为输入,网络结构修改内容如图 2 所示;第二,引入颜色匹配损失函数 $C(H_g, H_t)$, 使生成图像与目标图像的颜色直方图更加相似。

$$C(\mathbf{H}_g, \mathbf{H}_t) = \frac{1}{\sqrt{2}} \|\mathbf{H}_g^{1/2} - \mathbf{H}_t^{1/2}\|_2, \quad (4)$$

式中： \mathbf{H}_g 为生成图像的颜色直方图； \mathbf{H}_t 为目标图像的颜色直方图。

3 fire-GAN

若仅使用HistoGAN算法,生成火焰会出现颜色失真、形状模糊、不真实等情况,因此从图像预处理、圆形度损失函数、数据增强三方面对HistoGAN算法进行改进。

3.1 图像预处理

在生成对抗网络的输入中,图像背景是无效信息,且图像背景会干扰火焰的生成,因此在图像预处理时进行火焰图像分割(去除图像背景)是非常有意义的。

参考文献[18-19],火焰图像相较于其他物体图像具有以下独特的颜色特性:火焰R分量值比其他分量值高;火焰的B分量值及B分量离散度与干扰物(与火焰颜色、纹理特征相似的其他物体)有较大区别;火焰的S分量随R分量的增大而减小。利用这些火焰图像

的颜色特性,设计的火焰图像分割判据为

$$\begin{cases} R \geq G \geq B \\ B \geq B_T \\ S > (1-R)S_T/R_T \\ B_{std} \geq B_{std,T} \end{cases}, \quad (5)$$

式中: R 、 G 、 B 、 S 为图像红色分量、绿色分量、蓝色分量、饱和度分量; B_T 、 R_T 、 S_T 表示设定的蓝色分量阈值、红色分量阈值、饱和度分量阈值; B_{std} 为图像某一区域的蓝色分量离散度^[19]; $B_{std,T}$ 为设定的蓝色分量离散度阈值。相较于文献[18-19],式(5)的主要区别是将 $R \geq R_T$ 替换成 $B \geq B_T$,这是因为火焰反光区域B分量值衰减程度最大,G分量衰减程度次之,R分量衰减程度最小,B分量判据相较于R分量判据能有效抑制火焰反光。对一些不同场景的火焰图像采用式(5)进行分割,效果如图3所示。从图3可以观察到,针对不同背景、不同颜色、不同形状的火焰图像,式(5)能够在保留火焰信息的同时,抑制火焰反光、阳光等干扰物,具有良好的分割效果。

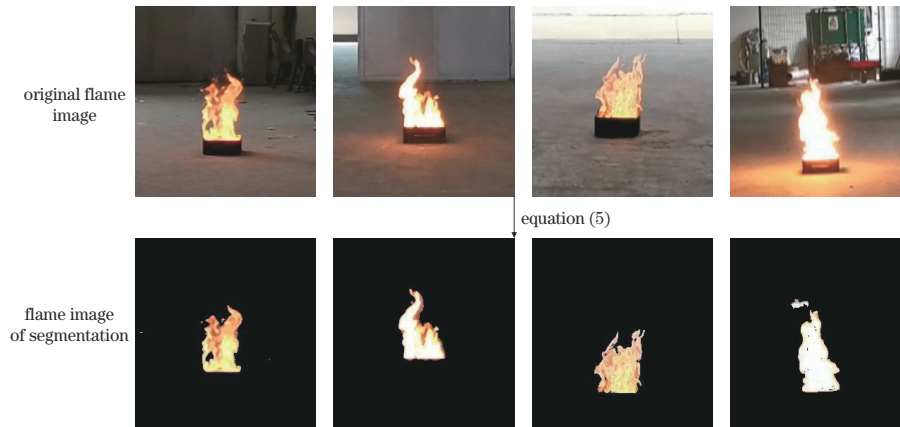


图3 采用式(5)的火焰图像分割示例

Fig. 3 Example of flame image segmentation using Equ. (5)

3.2 圆形度损失函数

圆形度是衡量物体形状复杂度的重要指标,计算公式为

$$C = \frac{4\pi s}{l^2}, \quad (6)$$

式中: s 表示面积; l 表示周长。当物体的形状越复杂时,单位面积的周长越长,圆形度就越小。

火焰形状随机性很大,轮廓较为复杂,因此火焰单位面积的周长较长,较一般物体,圆形度较低。通过实

验拍摄1000张不同场景的火焰与常见的干扰物的图片,分割出前景,并按照式(6)统计圆形度,对比结果如表1所示。易知:手电筒、车灯圆形度最高,这主要是因为它们为似圆物,形状较简单;从窗门透射的阳光的圆形度要比手电筒、车灯低,这是因为窗门大多数为矩形结构,由式(6)易得矩形结构要比似圆物的圆形度低;而火焰圆形度最低,这主要是因为火焰的轮廓较为复杂,呈不规则状。

表1 火焰与部分干扰物的圆形度

Table 1 Roundness of flames and disturbances

Parameter	Flame	Flashlight	Car lights	Sunlight through windows
C	0.279	0.714	0.666	0.585

HistoGAN对火焰的形状、轮廓拟合效果较差,导致生成火焰的圆形度较真实火焰高。为使生成火焰与

真实火焰在形状、轮廓上更加相似,降低生成火焰的圆形度,引入圆形度损失函数来训练生成器和判别器。

定义生成火焰与真实火焰圆形度的相似度为网络的圆形度损失函数,公式为

$$R_{\text{loss}} = |R_{\text{real}} - R_{\text{generate}}|, \quad (7)$$

式中: R_{real} 表示真实火焰圆形度; R_{generate} 表示生成火焰圆形度。当图像中出现多个目标(火焰)时 R_{real} 和 R_{generate} 为多个目标圆形度的平均。

fire-GAN中生成器的损失函数为

$$L_g = D(\mathbf{I}_g) + \alpha C(\mathbf{H}_g, \mathbf{H}_t) + \beta R_{\text{loss}}, \quad (8)$$

式中: \mathbf{I}_g 为生成图像; $D(\mathbf{I}_g)$ 表示判别器,在给定生成图像时,输出该图像为真的概率; α 、 β 为调节3个损失函数的比例因子。

fire-GAN中判别器的损失函数为

$$L_d = D(\mathbf{I}_g) + D(\mathbf{I}_r) + \lambda R_{\text{loss}}, \quad (9)$$

式中: $D(\mathbf{I}_g)$ 为给定生成图像时,判别器为假的概率; \mathbf{I}_r 为真实图像; $D(\mathbf{I}_r)$ 为在给定真实图像时,判别器输出

该图像为真的概率; λ 表示调节圆形度损失函数的比例因子。

3.3 数据增强

HistoGAN的性能受数据集大小的影响较大,当数据集较大时,网络易生成多样化和高质量的图像。然而,火焰图像数据集因安全性因素较难采集,数据集较小,导致网络容易过拟合,进而发生模型崩溃。使用HistoGAN的生成火焰图像随训练次数变化而变化的情况如图4所示,从图4可以看出,较训练5000次(本文中训练1次为更新一次判别器和生成器),网络训练10000次生成图像中火焰在真实性、多样性等方面均较差。这主要是因为随着训练次数的增加,生成器和判别器发生了不平衡,即判别器太“强”,易分辨出生成图像和真实图像,导致生成器没有目标,网络发生梯度爆炸,从而发生模型崩溃。因此进行数据增强是非常必要的。




图4 HistoGAN生成火焰图像示例

Fig. 4 Example of generating flame image using HistoGAN

为解决HistoGAN训练火焰图像数据集时易发生的模型崩溃问题,引入differentiable augmentation方法^[20]。传统的生成对抗网络的目标函数为

$$\min_G \max_D V(D, G) = E_{\mathbf{I}_r \sim p_{\text{data}}(\mathbf{I}_r)} [\log D(\mathbf{I}_r)] + E_{z \sim p_z(z)} \left\{ \log \left\{ 1 - D[G(z)] \right\} \right\}, \quad (10)$$

式中: G 表示生成器; D 表示判别器; z 表示噪声; p 表示概率分布; E 表示期望。differentiable augmentation方法为平衡生成器和判别器,对生成图像和真实图像均采用了相同的图像变换函数,然后输入到判别器中,增强后的目标函数为

$$\min_G \max_D V(D, G) = E_{\mathbf{I}_r \sim p_{\text{data}}(\mathbf{I}_r)} \left\{ \log D[T(\mathbf{I}_r)] \right\} + E_{z \sim p_z(z)} \left\{ \log \left\{ 1 - D\{T[G(z)]\} \right\} \right\}, \quad (11)$$

式中: T 表示对真实图像 \mathbf{I}_r 和生成图像 $G(z)$ 采用的相同的图像变换函数,使用cutout(用一半真实图像大小的随机正方形遮罩图像)、translation(在图像 $[-1/8, 1/8]$ 范围内用0覆盖)两个图像变换函数。

4 实验

这一部分主要进行图像预处理实验、火焰上色实验、数据增强实验、圆形度实验、火焰图像生成效果实

验共5部分内容,通过定性和定量评估来讨论fire-GAN生成火焰图像的效果。

为制作火焰图像生成数据集,通过实验拍摄了24个不同场景的火焰视频,并将其转换为10000张图像,并按8:1:1分为训练集、验证集、测试集。采用RTX3090作为硬件平台。定量评估主要选用inception score (IS)^[21]和Fréchet inception distance (FID)^[22]两个指标。IS能评估生成图像的清晰度和多样性,值越高越好,表达式为

$$S_{\text{IS}}(\mathbf{P}_g) = e^{E_{a \sim \mathbf{P}_g} [\text{KL}(\rho(\mathbf{b}|a)) | \rho(\mathbf{b})]}, \quad (12)$$

式中: $a \sim \mathbf{P}_g$ 表示生成器生成图像;KL表示散度; $\rho(\mathbf{b}|a)$ 表示生成图像属于某类的概率; $\rho(\mathbf{b})$ 表示所有类别概率的平均。FID评估生成图像与真实图像的相似性,值越低越好,表达式为

$$D_{\text{FID}} = \|\boldsymbol{\mu}_r - \boldsymbol{\mu}_g\|^2 + \text{Tr} \left[\boldsymbol{\Sigma}_r + \boldsymbol{\Sigma}_g - 2(\boldsymbol{\Sigma}_r \boldsymbol{\Sigma}_g)^{1/2} \right], \quad (13)$$

式中:Tr表示矩阵的迹; $\boldsymbol{\mu}$ 表示均值; $\boldsymbol{\Sigma}$ 表示协方差。

4.1 图像预处理实验

将进行火焰图像分割的数据集和未进行火焰图像分割的数据集分别作为fire-GAN的训练集,训练10000次,两部分数据集生成火焰图像的效果对比如图5所示。从图5可以观察到:使用未进行火焰图像

分割的数据集时,生成图像中火焰发生了形状变形、孤立、颜色失真,且生成的背景也较为模糊;使用进行火焰图像分割后的数据集时,生成图像中火焰在真实性、清晰度方面均较好,且不会发生形状变形、颜色失真的情况。使用 IS 和 FID 对两部分生成图像进行定量评

估,评估结果如表 2 所示。从表 2 可以观察到:相比使用未进行火焰图像分割的数据集,使用进行火焰图像分割的数据集后生成图像的 FID 提高了 26.05%,IS 提高了 17.57%,证明使用火焰图像分割进行图像预处理能提高 fire-GAN 生成图像的质量。




图 5 两部分数据集生成火焰图像效果对比

Fig. 5 Comparison of flame effect generated by two parts of datasets

表 2 两部分数据集生成火焰图像定量评估

Table 2 Quantitative evaluation of flame image generated by two parts of datasets

Dataset	FID	IS
Without flame segmentation	80.09	2.39
With flame segmentation	59.23	2.81

4.2 圆形成度实验

探究圆形成度损失函数对网络的影响。在不使用圆形成度损失函数(Without loss)、仅在判别器使用圆形成度损失函数(R_{d_loss})、仅在生成器使用圆形成度损失函数(R_{g_loss})、在判别器和生成器中都使用圆形成度损失函数($R_{d_loss} + R_{g_loss}$)。4 种情况下,网络训练 10000 次。

4 种情况下的生成图像示例如图 6 所示。从图 6 可以观察到:对于在生成器和判别器中添加圆形成度损失函数的情况,生成图像中火焰的轮廓清晰度、复杂度相较于不添加函数情况均有提高;相较仅在判别器使用圆形成度损失函数的情况,在生成器中添加圆形成度损失函数情况下生成图像中火焰的清晰度、复杂度更高;相较于仅在判别器使用圆形成度损失函数和仅在生成器使用圆形成度损失函数的情况,在两者中都加入圆形成度损失函数情况下生成图像中火焰的清晰度、复杂度更高。

不同情况下随机生成 1000 张火焰图像,生成图像中火焰圆形成度平均值如表 3 所示。从表 3 易观察到,在生成器和判别器中添加圆形成度损失函数均能有效降低




图 6 圆形成度损失函数不同情况下生成火焰图像效果对比

Fig. 6 Comparison of flame generation effects under different conditions of roundness loss function

表 3 圆形成度损失函数不同情况下生成图像中火焰圆形成度平均值对比

Table 3 Comparison of average values of flame roundness in images generated under different conditions of roundness loss function

Parameter	Without loss	R_{d_loss}	R_{g_loss}	$R_{d_loss} + R_{g_loss}$	Real image
C	0.434	0.379	0.330	0.319	0.279

生成图像中火焰圆形度,且

$$R_{d,loss} > R_{g,loss} > R_{d,loss} + R_{g,loss}, \quad (14)$$

这说明在网络中添加圆形度损失函数能提高生成图像中火焰的轮廓复杂度,进而提高生成火焰图像的质量。

4.3 火焰上色实验

对 fire-GAN(直方图控制火焰颜色)与先进的编码控制对象颜色网络 MixNMatch^[9]进行对比实验。两个网络生成火焰图像对比如图 7 所示,从图 7 易观察出 fire-GAN 相较于 MixNMatch,生成图像更加清晰,与目标图像颜色也更为接近。分别利用 MixNMatch 和 fire-GAN 生成 250 张图像,其火焰 R 、 G 、 B 均值如表 4 所示。MixNMatch 生成图像中 R 、 G 、 B 均值误差分别为 12.6%、6.6%、15.0%, RGB 三个分量平均误差为 11.4%;fire-GAN 生成图像中 R 、 G 、 B 均值误差分别为




图 7 fire-GAN 与 MixNMatch 生成火焰图像效果对比
Fig. 7 Comparison of flame image generated by fire-GAN and MixNMatch

表 4 fire-GAN 与 MixNMatch 生成图像 R 、 G 、 B 均值对比
Table 4 Comparison of R , G , and B mean values of images generated by fire-GAN and MixNMatch

Network	R	G	B
Target image	233.6397	217.8905	201.2066
fire-GAN	228.3991	213.4572	194.0862
MixNMatch	204.1542	203.5226	171.0034

2.2%、2.0%、3.5%, RGB 平均误差为 2.6%。因此证明 fire-GAN 相较于 MixNMatch,生成图像与目标图像的颜色更为接近,将颜色直方图输入到网络中,能有效控制生成火焰图像的颜色。

4.4 数据增强实验

对 fire-GAN 的数据增强方案与解决模型崩溃的代表性方法梯度正则化(GN)^[23]、自适应伪增强(APA)^[24]进行对比实验。三种方法训练 10000 次,生成图像如图 8 所示。从图 8 可以观察出:GN、APA 在训练 10000 次后,生成图像不清晰,真实性、多样性较差;而 fire-GAN 在训练 10000 次后,生成图像清晰度较高,真实性、多样性较好。三种方法生成图像的 FID 随训练次数变化而变化的情况如图 9 所示。从图 9 观察出:APA 在训练 5000 次后,FID 开始增大,模型开始崩溃;GN 在训练 6000 次后 FID 增大,模型开始崩溃;而 fire-GAN 随着训练次数的增加,FID 在减小,说明模型依旧保持稳定。结果表明 fire-GAN 在解决模型崩溃问题上是非常有效的。

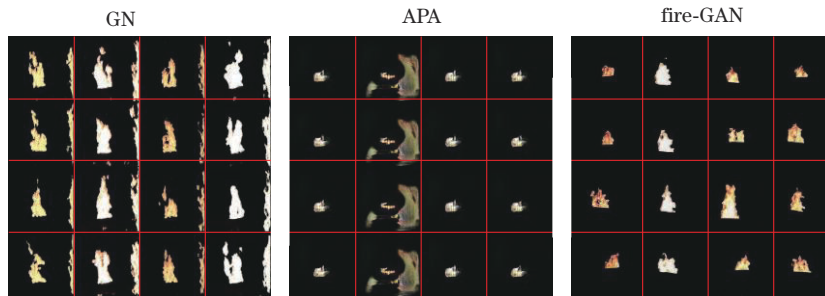


图 8 GN、APA、fire-GAN 生成图像效果对比
Fig. 8 Comparison of image effects generated by GN, APA, and fire-GAN

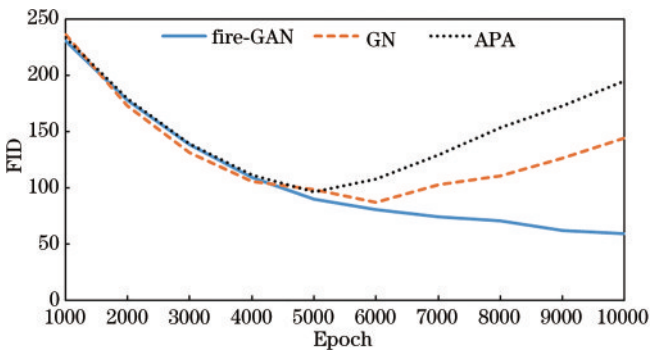


图 9 GN、APA、fire-GAN 生成图像 FID 与训练次数的关系
Fig. 9 Relationship between FID of image generated by GN, APA, and fire-GAN and training times

4.5 火焰图像生成效果实验

对 fire-GAN 与现阶段生成图像效果较好的生成对抗网络系列 GAN^[5]、SAGAN^[25]、MixNMatch^[9]、content-aware-GAN^[26]、styleGAN2^[11]进行生成火焰图像效果的对比实验,不同 GAN 生成图像示例对比如图 10 所示。易观察出:GAN、SAGAN 生成图像中火焰出现了失真的情况;MixNMatch 生成图像中火焰轮廓较为模糊;content-aware-GAN、styleGAN2 及 fire-GAN 生成图像中火焰轮廓清晰,色彩与真实火焰也较为接近,图像整体的视觉感知效果更好。使用 IS 和 FID 对上述网络进行定量评估,定量评估如表 5 所示。fire-GAN 的 FID 和 IS 指标均优于其他生成对抗网络




图 10 不同网络生成火焰图像效果对比

Fig. 10 Comparison of flame images generated by different networks

表 5 不同网络的定量评估

Table 5 Quantitative evaluation of different networks

Parameter	GAN	SAGAN	MixNMatch	content-aware-GAN	styleGAN2	fire-GAN
FID	129.02	125.35	140.34	68.85	60.52	59.23
IS	2.06	2.00	1.91	2.76	2.79	2.81

系列,表明 fire-GAN 生成图像在清晰度、多样性、真实性等方面表现更好。

5 结 论

介绍了一种改进的生成火焰图像算法,即 fire-GAN。该算法主要提高了生成火焰质量(清晰度、多样性、复杂度),解决了生成火焰颜色控制和模型崩溃等问题。通过进行一系列实验,对不同网络生成的火焰图像进行定性和定量评估,验证了 fire-GAN 的有效性。然而,fire-GAN 生成火焰图像是无背景的,这限制了生成图像的使用。未来,会探索如何对生成火焰与任意背景进行融合的内容,使得生成火焰在火焰数据增广、火焰目标检测、火焰图像超分、消防与安全领域等发挥更好的作用。

参 考 文 献

- [1] 刘中法, 杨艺哲, 方宇, 等. 基于深度学习的虚拟相衬成像方法[J]. 光学学报, 2021, 41(22): 2217001.
Liu Z F, Yang Y Z, Fang Y, et al. Deep learning-based virtual phase contrast imaging method[J]. Acta Optica Sinica, 2021, 41(22): 2217001.
- [2] 王梦瑶, 孟祥超, 邵枫, 等. 基于深度学习的 SAR 辅助下光学遥感图像去云方法[J]. 光学学报, 2021, 41(12): 1228002.
Wang M Y, Meng X C, Shao F, et al. SAR-assisted optical remote sensing image cloud removal method based on deep learning[J]. Acta Optica Sinica, 2021, 41(12): 1228002.
- [3] 王一同, 周宏强, 闫景道, 等. 基于深度学习算法的计算光学研究进展[J]. 中国激光, 2021, 48(19): 1918004.
Wang Y T, Zhou H Q, Yan J X, et al. Advances in computational optics based on deep learning[J]. Chinese Journal of Lasers, 2021, 48(19): 1918004.
- [4] Sarkar K, Liu L J, Golyanik V, et al. HumanGAN: a generative model of human images[C]//2021 International Conference on 3D Vision (3DV), December 1-3, 2021, London, United Kingdom. New York: IEEE Press, 2021: 258-267.
- [5] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[EB/OL]. (2014-06-10) [2021-02-04]. <https://arxiv.org/abs/1406.2661>.
- [6] Karras T, Aittala M, Laine S, et al. Alias-free generative adversarial networks[EB/OL]. (2021-06-23) [2022-02-01]. <https://arxiv.org/abs/2106.12423>.
- [7] Lin J, Zhang R, Ganz F, et al. Anycost GANs for interactive image synthesis and editing[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 14981-14991.
- [8] 韩子硕, 王春平, 付强, 等. 基于空间分离表征 GAN 的遥感图像模式互转[J]. 光学学报, 2021, 41(7): 0728003.
Han Z S, Wang C P, Fu Q, et al. Remote sensing image mode translation by spatial disentangled representation based GAN[J]. Acta Optica Sinica, 2021, 41(7): 0728003.
- [9] Li Y H, Singh K K, Ojha U, et al. MixNMatch: multifactor disentanglement and encoding for conditional image generation[C]//2020 IEEE/CVF Conference on

- Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 8036-8045.
- [10] Karras T, Laine S, Aila T M. A style-based generator architecture for generative adversarial networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 4396-4405.
- [11] Karras T, Aittala M, Hellsten J, et al. Training generative adversarial networks with limited data[EB/OL]. (2020-06-11)[2021-02-04]. <https://arxiv.org/abs/2006.06676>.
- [12] Lin T W, Ma Z Q, Li F, et al. Drafting and revision: Laplacian pyramid network for fast high-quality artistic style transfer[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 5137-5146.
- [13] 王越, 王德兴, 袁红春, 等. 基于金字塔注意力机制和生成对抗网络的水下图像增强[J]. 激光与光电子学进展, 2021, 58(16): 1610006.
Wang Y, Wang D X, Yuan H C, et al. Underwater image enhancement based on pyramid attention mechanism and generative adversarial network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610006.
- [14] Yang Z K, Wang T, Bu L P, et al. Training with augmented data: GAN-based flame-burning image synthesis for fire segmentation in warehouse[J]. Fire Technology, 2022, 58(1): 183-215.
- [15] Afifi M, Brubaker M A, Brown M S. HistoGAN: controlling colors of GAN-generated and real images via color histograms[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 7937-7946.
- [16] Afifi M, Brown M S. Sensor-independent illumination estimation for DNN models[EB/OL]. (2019-12-14)[2022-02-27]. <https://arxiv.org/abs/1912.06888>.
- [17] Afifi M, Price B, Cohen S, et al. When color constancy goes wrong: correcting improperly white-balanced images [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 1535-1544.
- [18] Chen T H, Wu P H, Chiou Y C. An early fire-detection method based on image processing[C]//2004 International Conference on Image Processing, October 24-27, 2004, Singapore. New York: IEEE Press, 2004: 1707-1710.
- [19] Wang T, Bu L P, Yang Z K, et al. A new fire detection method using a multi-expert system based on color dispersion, similarity and centroid motion in indoor environment[J]. IEEE/CAA Journal of Automatica Sinica, 2020, 7(1): 263-275.
- [20] Zhao S Y, Liu Z J, Lin J, et al. Differentiable augmentation for data-efficient GAN training[EB/OL]. (2020-06-18)[2022-02-24]. <https://arxiv.org/abs/2006.10738>.
- [21] Barratt S, Sharma R. A note on the inception score[EB/OL]. (2018-01-06)[2022-02-24]. <https://arxiv.org/abs/1801.01973>.
- [22] Dowson D C, Landau B V. The Fréchet distance between multivariate normal distributions[J]. Journal of Multivariate Analysis, 1982, 12(3): 450-455.
- [23] Wu Y L, Shuai H H, Tam Z R, et al. Gradient normalization for generative adversarial networks[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2021: 6353-6362.
- [24] Jiang L M, Dai B, Wu W, et al. Deceive D: adaptive pseudo augmentation for GAN training with limited data [EB/OL]. (2021-11-12)[2022-02-24]. <https://arxiv.org/abs/2111.06849>.
- [25] Zhang H, Goodfellow I, Metaxas D, et al. Self-attention generative adversarial networks[EB/OL]. (2018-05-21)[2022-02-04]. <https://arxiv.org/abs/1805.08318>.
- [26] Liu Y C, Shu Z X, Li Y J, et al. Content-aware GAN compression[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 12151-12161.