

DOI:10.19651/j.cnki.emt.2212068

基于改进循环生成对抗网络实现红外图像生成^{*}

易星^{1,2,3,4} 潘昊¹ 赵怀慈^{2,3,4} 刘鹏飞^{2,3,4} 杨斌¹(1. 沈阳化工大学信息工程学院 沈阳 110142; 2. 中国科学院光电信息处理重点实验室 沈阳 110016;
3. 中国科学院沈阳自动化研究所 沈阳 110016; 4. 中国科学院机器人与智能制造创新研究院 沈阳 110169)

摘要: 针对目前已有的可见光图像生成红外图像的算法不能感知图像的弱纹理区域而导致生成的图像细节信息不突出、图像质量低的问题,本文提出了一种适用于图像生成任务的改进循环生成对抗网络(CycleGAN)结构。首先,利用特征提取能力更强的残差网络构建CycleGAN的生成器网络结构,使图像特征可以充分被提取,解决图像因特征提取不充分导致图像质量低下的问题;其次,在生成器的网络结构中引入了通道注意力机制和空间注意力机制,利用注意力机制对图像感知能力较差的区域进行权重处理,解决图像纹理细节丢失的问题。在OSU数据集上,本文所提出的方法相较于CycleGAN方法在峰值信噪比(PSNR)以及结构相似性(SSIM)指标上分别提高了7.1%和10.9%,在Flir数据集上的PSNR和SSIM分别提高了4.0%和6.7%。经过多个数据集上的实验结果证明,本文改进的方法能够突出图像生成任务中的细节特征信息,并且能有效地提升图像生成的质量。

关键词: 循环生成对抗网络;红外图像生成;通道注意力;空间注意力;残差网络

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.2

Based on improved cycle generative adversarial network for infrared image generation

Yi Xing^{1,2,3,4} Pan Hao¹ Zhao Huaici^{2,3,4} Liu Pengfei^{2,3,4} Yang Bin¹(1. School of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110142, China;
2. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;
3. Key Laboratory of Optical-Electronics Information Technology Processing, Shenyang Institute of Automation,
Chinese Academy of Sciences, Shenyang 110016, China; 4. Institutes for Robotics and Intelligent Manufacturing,
Chinese Academy of Sciences, Shenyang 110169, China)

Abstract: To address the problem that the existing algorithms for generating infrared images from visible images cannot perceive the weak texture regions of the images, which leads to the low quality of the generated image details, this paper proposes an improved Cycle Generation Adversarial Network (CycleGAN) for the image generation task. Firstly, the generator network structure of the cycle generation adversarial network is constructed by using the residual network with stronger feature extraction ability, so that the image features can be fully extracted and the problem of low image quality caused by insufficient feature extraction can be solved; secondly, the channel attention mechanism and spatial attention mechanism are introduced in the generator network structure, and the regions with poor image perception are weighted by the attention mechanism to solve the problem of loss of image texture details. processing to solve the problem of image texture detail loss. On the OSU dataset, the proposed method improves the Peak Signal to Noise Ratio (PSNR) and Structural Similarity (SSIM) metrics by 7.1% and 10.9%, respectively, compared with the cyclic generative adversarial network method on the Flir dataset. PSNR and SSIM improved by 4.0% and 6.7%, respectively, on the Flir dataset. The experimental results on several datasets demonstrate that the improved method in this paper can highlight the detailed feature information in the image generation task and can effectively improve the quality of image generation.

Keywords: CycleGAN; infrared image generation; channel attention; spatial attention; residual network

0 引言

红外图像无论是在民用检测还是在军事侦察领域中都

起着非常重要的作用。通常情况下,红外成像设备通过光学镜头捕获红外线,然后经过电信号转换和图像处理技术,最后形成可供人眼观察的热图像。这种成像技术虽然能够

收稿日期:2022-11-14

*基金项目:中国国家装备发展部重点预研基金(41401040105)项目资助

生成红外图像,但是在恶劣的环境中,得到的红外图像的质量普遍不高,细节信息缺失较为严重。随着深度学习技术的迅速发展,通过图像处理技术,利用算法实现生成红外图像,可以弥补在恶劣环境中通过红外设备获取的红外图像细节不够突出,红外图像^[1-2]模糊以及质量低下等问题。通过利用深度学习的方法生成红外图像在军事侦察和民用监控等领域都具有重要的应用价值。

随着深度学习在各个领域广泛被应用,2014 年 Goodfellow 等^[3]基于博弈思想提出了生成式对抗网络,并在各个领域得到了广泛应用。生成对抗网络(generative adversarial networks, GAN)主要由生成器和鉴别器 2 个部分组成,生成器是利用输入数据来生成出一个假数据,而鉴别器是将生成器产生的假数据和真实数据进行鉴别。在训练网络的过程中,通过生成器与鉴别器的相互博弈,使得生成假数据的分布逐渐逼近真实数据,直至达到纳什均衡为止。

为了更好地实现从原域图像到目标域图像的映射,学者们基于生成对抗网络提出了很多算法。2015 年 Radford 等^[4]提出了深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN),在生成对抗网络上采用反卷积层进行上采样,使用 Leaky ReLU 作为激活函数,以此来稳定生成对抗网络的训练。2017 年 Isola 等^[5]提出了基于监督学习的图像生成 pix2pix 算法,该方法通过使用成对的数据集来实现源域图像到目标域图像的转化。虽然 pix2pix 实现了图像生成,但是从源域到目标域生成的图像较为模糊、质量较为低下。针对 pix2pix 算法所出现的问题,Wang 等^[6]又提出了 pix2pixHD 算法,该算法不再依照生成对抗网络中输入随机噪声,而是将随机噪声改为输入用户所给的图片,通过这样的方式可以生成清晰度较高的目标域图像。2017 年 Arjovsky 等^[7]提出了 Wasserstein 距离生成对抗网络(wasserstein generative adversarial Networks, WGAN)实现源域图像到目标域图像的生成方法,该方法是对判别器进行权重裁剪,通过限制判别器中的参数,从而降低了判别器的判别能力。2019 年 Zhang 等^[8]、2017 年 Liu 等^[9]提出了自注意力生成对抗网络(self-attention generative adversarial networks, SAGAN)方法用于解决卷积局部感受野的限制,通过在判别器和生成器中都引入了自注意机制来获取图像的全局特征信息,进而得到较好的目标域生成图像。2016 年 Liu 等^[10]提出无监督图像翻译生成对抗网络(couple generative adversarial networks, Couple GAN)的方法,此方法实现了非成对数据集在源域与目标域之间的图像生成,它可以通过成功的学习在没有任何配对数据下的域之间的联合分布,在域适应(domain adaption, DA)和图像转换(image conversion, IC)方面得到了很好的效果。2017 年 Zhu 等^[11]提出了循环生成对抗网络(cycle generation adversarial network, CycleGAN)实现了源域到目标域图像的双向转

化,CycleGAN 方法的创新点在于能够在源域和目标域之间无须建立成对映射的训练数据,同时提出了循环生成对抗损失,更好的生成目标域图像。

虽然 CycleGAN 在图像翻译和生成中得到了非常好的效果,但是训练过程中可以发现:生成器网络训练很不稳定、生成图像的细节容易丢失、图像模糊等。针对以上问题,本文提出了一种结合了通道注意力和空间注意力机制的残差网络作为生成器。首先引入了残差网络作为生成器主体网络,提升网络的特征提取能力,而后在残差网络中引入了通道注意力模块和空间注意力模块,解决了生成图像模糊的问题,同时对图像生成的纹理细节信息有很大提升。

1 相关工作

1.1 CycleGAN

自从 2014 年 Goodfellow 等^[3]提出利用卷积神经网络搭建生成器和鉴别器,通过生成器与鉴别器之间的不断博弈来实现图像生成和翻译,当前这种博弈思想被广泛应用在图像生成以及迁移学习的领域中。本文改进的循环生成对抗方法也是基于博弈思想,从而实现了可见光图像到红外图像的生成与转化。CycleGAN 是由双生成器和双辨别器组成,生成器采用的是 UNet 网络结构,判别器则由 PatchGAN 网络结构组成。CycleGAN 的总体框架图如图 1 所示:生成器 Generator_A 负责将可见光图像转换生成为红外图像,Generator_B 负责将红外图像生成为可见光图像,不管是生成红外图像还是可见光图像,都会将生成的图像输入各自的辨别器中进行真假的判别。但是基于 UNet 网络结构组成的生成器特征提取能力有限,进而导致图像生成过程中小细节部分的特征信息无法被完全提取并展现出来。

1.2 残差网络

残差网络(residual network, ResNet)^[12]是在 2016 年视觉识别竞赛中获得图像分类的优胜网络,本文提出采用 ResNet 作为生成器基本网络,增强特征的提取能力。为了使图像信息提取更充分,本文在 ResNet 中引入了通道注意力模块和空间注意力模块,采用该模块是为了更好地增强特征提取时的权重信息,使生成的图像细节得到更好的体现。具体流程如图 2 所示,将特征图输入到权重层(Weight layer),权重层主要利用通道注意力和空间注意力模块更好的突出特征图中显著性区域,再将进行权重层操作后的特征与原始特征图进行加权后进行 ReLU 激活输出。

1.3 通道注意力和空间注意力机制

注意力模块是 Woo 等^[13]和 Hu 等^[14]在 2018 年提出来用于加强显著性区域的特征信息,这个模块在神经网络中有很大的促进作用。Woo 等提出在给定中间特征图时通过空间和通道两个维度上对特征做出注意力权重加权操作,再与原图像进行特征匹配来达到图像特征的自适应调整,使得重点区域的特征得到显著性关注。注意力机制结

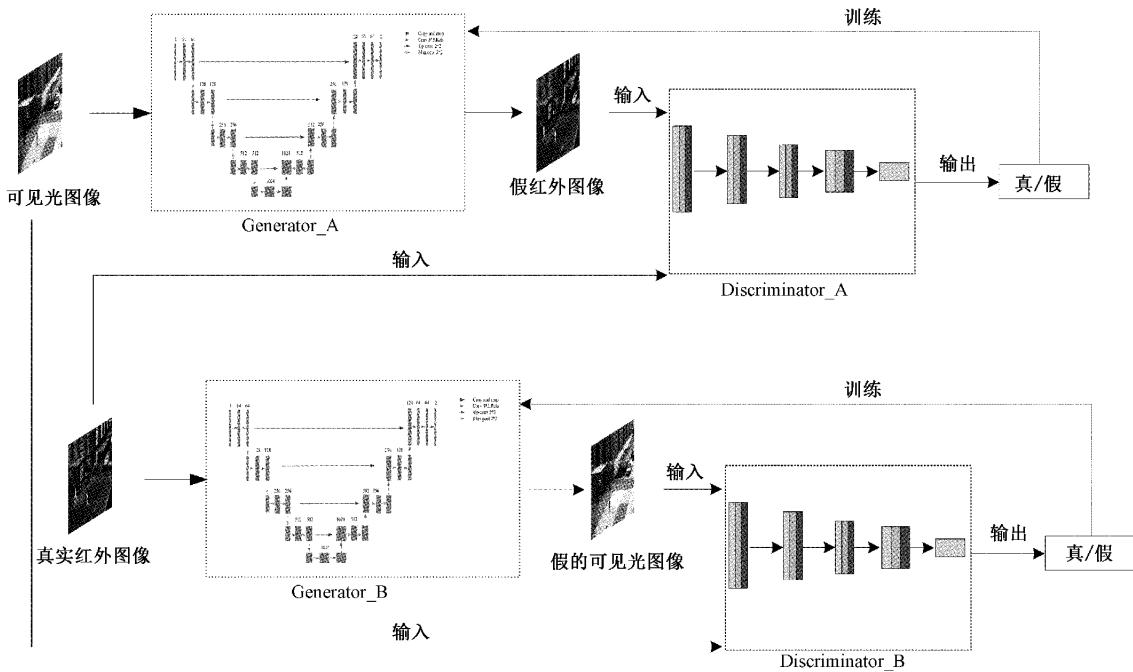


图 1 CycleGAN 整体结构图

■ 输入 ■ 输出	■ 卷积层 ■ 归一化层	■ 通道注意力模块 ■ 空间注意力模块
		■ ReLU 层

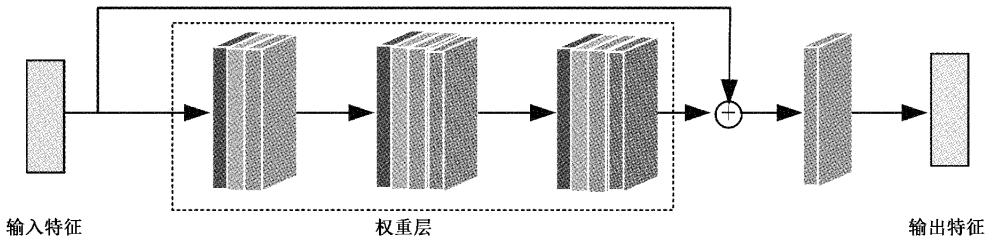


图 2 残差网络结构图

构如图 3 所示。具体流程是将输入 $H \times W \times C$ 的特征图分别送入平均池化层和最大池化层得到 2 个 $1 \times 1 \times C$ 的特征图;再将特征图经过 MLP 神经网络进行特征,提取后加权和 sigmoid 激活操作得到最终的通道注意力特征图。空间注意力则是以通道注意力为前提,将得到的通道注意力特征图与原特征图做相乘后的特征图作为空间注意力模块的输入,首先对输入的特征图分别进行最大池化和平均池化,得到两个 $H \times W \times 1$ 的特征图,再通过 7×7 的卷积操作以及通道降维后得到 2 个 $H \times W \times 1$ 的特征图,之后将该特征图进行 sigmoid 激活后得到空间注意力特征图。通过该特征图与输入的特征图进行相乘操作最终形成新的融合了空间注意力与通道注意力的特征图。

2 本文方法

2.1 网络整体框架结构图

本文所使用的网络架构是 CycleGAN,采用的是双生

成器与双鉴别器,生成器使用的是 ResNet,在 ResNet 中加入了通道注意力机制和空间注意力机制。引入 ResNet 主要是利用 ResNet 对图像特征提取能力较强,引入注意力机制是为了提高生成图像质量解决生成的图像纹理信息缺乏严重。通过引入 ResNet 和注意力机制能够生成质量较高、纹理细节信息丰富的红外图像。鉴别器采用 patchGAN 鉴别器结构。通过生成器与鉴别器两者之间的不断博弈将可见光图像生成红外图像,解决图像的转换问题,整体的网络框架结构如图 4 所示。整体网络框架流程为:将可见光图像输入到 G_A 生成器中生成 1 张假的红外图像,再将假的红外图像与真实的红外图像一起输入到 D_A 鉴别器中进行真假判断,得出的真假信息值将反馈给 G_A 生成器;同样的,将真实的红外图像输入到 G_B 生成 1 张假的可见光图像,将真实的可见光图像与生成的可见光图像一起输入到 D_B 鉴别器中进行鉴别得到真假值反馈给 G_B。通过生成器与鉴别器不断对抗学习和更新便

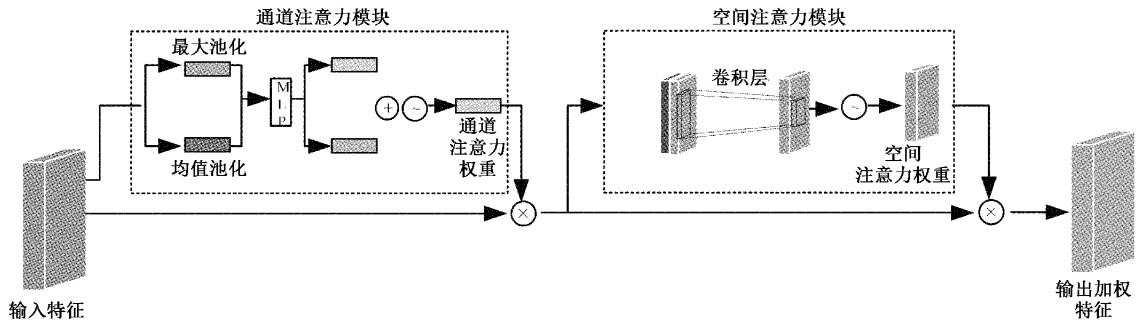


图3 通道注意力与空间注意力机制结构图

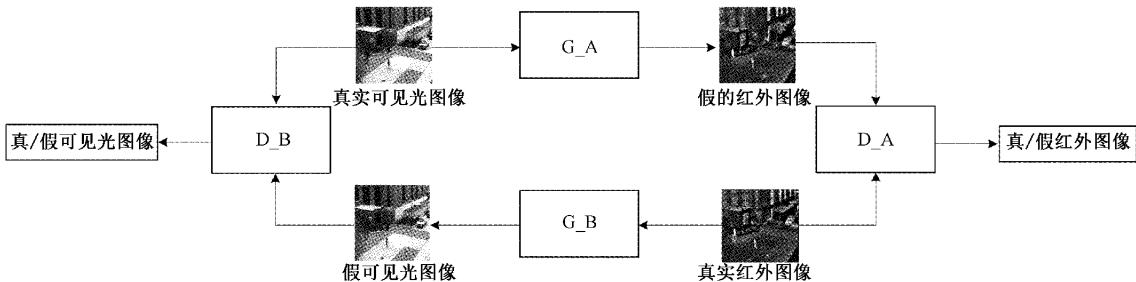


图4 改进 CycleGAN 方法整体框架图

可以得到训练完成的生成器模型,实现可见光图像到红外图像的双向生成。

本文采用伪代码形式表示网络模型的具体训练过程,如表1所示。为了保证红外图像能够输出的前提在于判别器是否有准确区分真假红外图像的能力,因此采用先训练双判别器K次,再训练双生成器的分批循环训练形式,并持续迭代到最大训练次数M。

表1 网络模型的训练过程

输入:红外图像 I_i , 可见光图像 I_v
输出:由可见光图像 I_v 生成的假红外图像 I_f
步骤1 For M epochs do
步骤2 For k steps do
步骤3 从红外图像分布采取 n 个样本 $\{I_i^1, I_i^2, I_i^3, \dots, I_i^n\}$;
步骤4 从可见光图像分布采取 n 个样本 $\{I_v^1, I_v^2, I_v^3, \dots, I_v^n\}$;
步骤5 训练判别器 Discriminator_A, 并更新参数模型;
步骤6 训练判别器 Discriminator_B, 并更新参数模型;
步骤7 End for
步骤8 训练生成器 Generator_A, 并更新模型参数;
步骤9 训练生成器 Generator_B, 并更新模型参数;
步骤10 End for

2.2 生成器结构图

相较于传统的CycleGAN方法,本文改进了生成器网络架构,采用了特征提取能力更强的ResNet,可以使得图像的特征被充分提取;其次,为了防止图像生成过程中细节信息的丢失,我们在ResNet中引入了通道注意力机制

与空间注意力机制,以此加强网络对弱感知区域的关注,增强纹理细节信息的生成。通过双生成器能将原域与目标域的图像双向生成的图像可以进行对比监督,在这样的学习情况下能具有良好的特征重构,生成的图像质量也会越好。生成器的网络结构(以可见光图像生成红外图像为例)如图5所示。

生成器第1层采用了 7×7 的卷积层、归一化层以及采用ReLU激活函数,通过提取图像特征进行下采样操作。与特征提取层不同的是:下采样采用了 3×3 的卷积层,对图像特征提取更为充分。下采样提取完成后的特征进入残差网络,采用9个ResNet_block块,ResNet_Block块是由 3×3 卷积块和ReLU激活函数构成,通过对特征提取以及激活后输入到通道注意力机制和像素注意力机制中,最后输出的特征与原始特征进行加权处理,得到最后融合了注意力机制的特征层。通过这样的方法对图像中的细节信息以及边缘信息着重提取,再通过特征的上采样操作进行图像的生成。上采样中采用 3×3 的反卷积层,上采样操作完成后通过 7×7 卷积层和Tanh激活函数完成整个生成器的图像生成流程。Tanh激活函数公式如下:

$$\text{Tanh}(x) = 2\text{sigmoid}(2x) - 1 \quad (1)$$

其中,sigmoid($2x$)为平滑阶梯激活函数。

2.3 判别器网络结构

在图像生成任务中,判别器采用的是PatchGAN的基础判别器框架,该判别器只针对于生成器生成的假图像和数据集中真实的图像进行真假判别。判别器结构如图6所示。判别器由 4×4 的卷积层和激活函数组成,其中判别器中采用的是LeakyReLU激活函数。通过不断卷积后

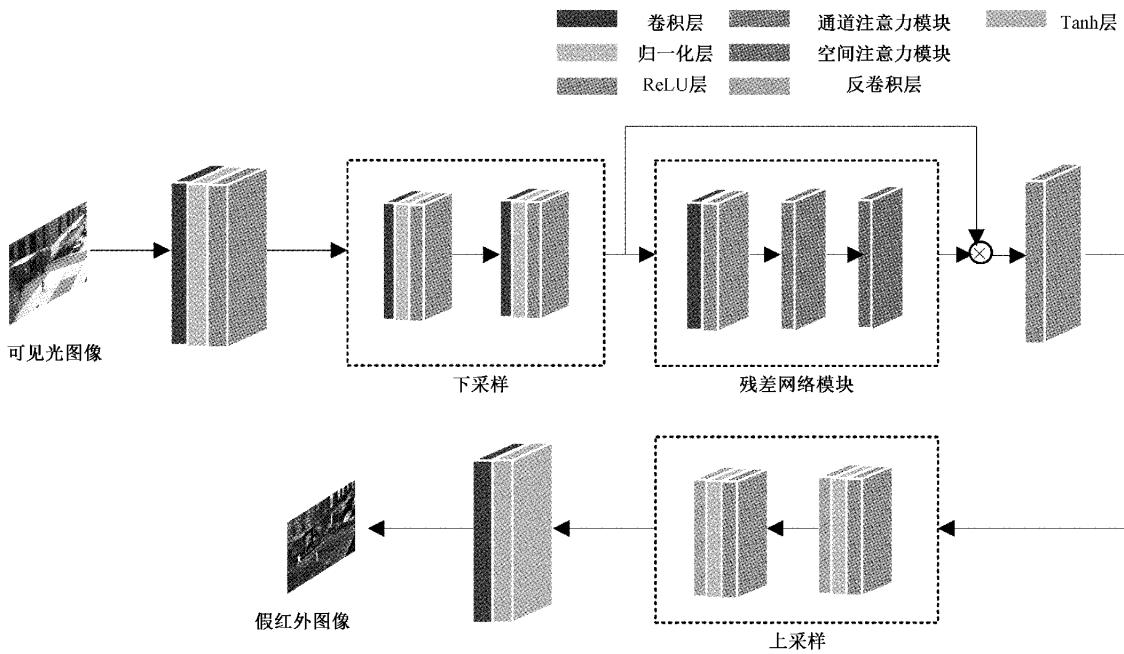


图 5 生成器网络结构图

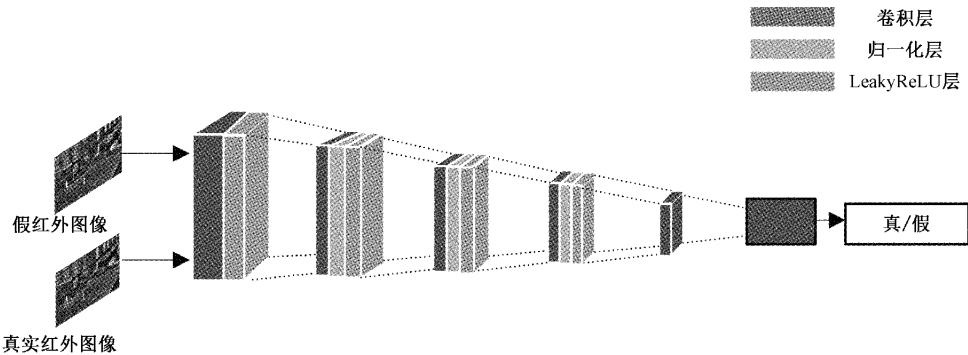


图 6 判别器网络结构图

输出一个 $n \times n$ 的矩阵, 最后取出矩阵的均值作为真假输出。利用 patchGAN 的辨别器是因为它具有更好的辨识性, 对生成的图像与真实图像具有更好的辨别能力, 从而保证图像生成的纹理性特征和更多的细节。

2.4 损失函数

CycleGAN 的损失函数包含生成对抗损失、循环一致性损失以及总体损失。生成对抗损失是生成器将源域图像转换为目标域图像。构造的生成对抗损失函数由源域(可见光图像)生成目标域图像(红外图像)的损失函数为:

$$\text{Loss}_{\text{GAN}}(\text{GA}_B, D_Y, X, Y) = E_{y \sim P_{\text{data}}(y)} [\log_{10} D_Y(y)] + E_{x \sim P_{\text{data}}(x)} [\log_{10} (1 - D_Y(\text{GA}_B(x)))] \quad (2)$$

其中, 生成器 GA_B 中的 $E_{y \sim P_{\text{data}}(y)}$ 为在目标域中取出的样本图像期望, $E_{x \sim P_{\text{data}}(x)}$ 表示为在源域中取得的样本图像期望, 函数中的 y 是构成 Y 样本空间(红外图像)中的样本, x 构成 X 样本空间(可见光图像)中的样本。 $\text{GA}_B(x)$

为生成器 GA_B 生成的图像。 $D_Y(y)$ 则表示判别器 D 判断 y 是否是来自 Y 样本空间中的样本的概率, $(1 - D_Y(\text{GA}_B(x)))$ 则表示为判别器 D 对生成器 GA_B 生成的图像进行判别, 判断该图片是否是取自 Y 样本空间中的样本的概率。

目标域(红外图像)生成源域(可见光图像)的生成对抗损失函数为:

$$\text{Loss}_{\text{GAN}}(\text{GB}_A, D_X, X, Y) = E_{x \sim P_{\text{data}}(x)} [\log_{10} D_X(x)] + E_{y \sim P_{\text{data}}(y)} [\log_{10} (1 - D_X(\text{GB}_A(y)))] \quad (3)$$

该损失函数与源域生成目标域图像的损失函数类似。

循环一致性损失函数是同时学习 GA_B 和 GB_A 两个映射, 并且期望 $\text{GA}_B(\text{GB}_A(y))$ 尽可能生成的图像与 y 接近, 期望 $\text{GB}_A(\text{GA}_B(x))$ 生成的图像与 x 接近。采用循环一致性损失函数的目的是为了防止生成器 G 过分学习 Y 样本空间中的样本, 进而过度改变 X 样本空间中的样本; 循环一致性损失函数为:

$$\begin{aligned} Loss_{cycle}(GA_B, GB_A) = \\ E_{x \sim p_{data}(x)} [\|GB_A(GA_B(x)) - x\|] + \\ E_{y \sim p_{data}(y)} [\|GA_B(GB_A(y)) - y\|] \end{aligned} \quad (4)$$

因此最终的损失函数为：

$$\begin{aligned} Loss(GA_B, GB_A, D_x, D_y) = Loss_{GAN}(GA_B, D_y, X, Y) + \\ Loss_{GAN}(GB_A, D_x, X, Y) + \lambda Loss_{cycle}(GA_B, GB_A) \end{aligned} \quad (5)$$

其中， λ 为循环一致性损失函数的权重系数。

3 实验验证与结果分析

3.1 数据集与实验过程

本文进行深度学习模型训练所采用的平台配置如下：显卡为 GeForce RTX 2080Ti，内存为 32 GB。所采用的框架是 Pytorch，在 Linux 系统上使用 python3.7 搭建本模型。测试后的结果和消融实验及指标均在 Windows 10 操作系统上使用 Matlab R2019a 运行并得出结果。

在训练期间，所采用的数据集是 OSU 色热数据^[15]库中的序列 3 和 Flir 数据集中的可见光图像与红外图像 2 组数据集。从 2 个数据集中各筛选了 500 对红外图像与可见光图像序列对组成数据集，另外取 20 对作为测试集来进行本实验。训练的 epoch 设置为 200，batch_size 设置为 1，学习率在 1~100 个 epoch 为 0.000 2，在 100~200 个 epoch 设置为线性梯度下降，采用 Adam 优化策略。

3.2 实验结果

为了验证本文图像生成方法的有效性，客观评价采用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity, SSIM)^[16]来评价图像清晰度和纹理细节丰富程度。统计结果如表 2 所示，在 2 个数据集上进行了实验，表中数据指标 PSNR 和 SSIM 下分别采用 2 对数据作为指标数据，更能保证数据的准确性，体现出模

型方法的有效性。采用了 CycleGAN + UNet_256、CycleGAN (ResNet)、CUT 方法作为对照实验，CycleGAN+UNet_128 为原始方法，CycleGAN+ResNet+attention 为本文提出的方法，图 7 和 8 为生成红外图像的可视化结果。与 CycleGAN 方法相比，本文算法在 OSU 数据集中，PSNR 和 SSIM 分别提升了 7.10% 和 10.90%；在 Flir 数据集中^[17]，PSNR 和 SSIM 分别提升了 4.00% 和 6.70%。客观评价指标表明本文算法生成的红外图像的质量得到了显著提升，客观上验证了本文算法的有效性和先进性。

表 2 对比实验客观评价结果

方法	数据集	OSU 序列 3		Flir	
		评价指标	PSNR/dB	SSIM	PSNR/dB
CycleGAN+Unet_128	OSU 序列 3	13.62	0.24	15.00	0.41
CycleGAN+Unet_256	OSU 序列 3	13.74	0.26	14.83	0.44
CycleGAN(ResNet)	OSU 序列 3	17.29	0.69	14.42	0.43
CUT ^[18]	OSU 序列 3	13.35	0.32	13.79	0.28
本文	OSU 序列 3	18.39	0.75	20.45	0.46

从图 7 和 8 可以看出：CycleGAN 生成的红外图像提取的特征不够充分，主要存在于生成器网络提取特征能力有限，从而造成图像生成模糊，生成质量低下。同时在针对细节信息，生成器没有对图像中较为显著区域的特征进行权重处理操作，造成生成的红外图像细节不够突出。CUT 生成方法造成了纹理细节严重丢失的情况。而本文方法通过在提取特征进行权重处理和优化生成器网络等方面做出的改进，获得的图像生成清晰度较高、区域纹理细节丰富。OSU 色热数据库实验对比结果如图 7 所示，Flir 数据集对比结果如图 8 所示。

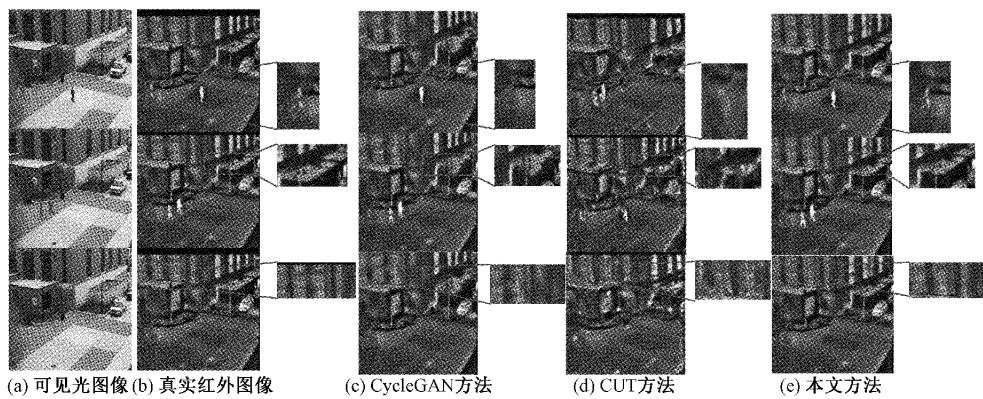


图 7 CycleGAN 与本文方法在 OSU 色热数据集上生成效果对比

3.3 消融实验

本文使用 OSU 色热数据库进行消融实验，分析改进网络结构的作用。实验包含 3 个部分：1) CycleGAN + Spatial；在生成器中引入空间注意力机制；2) CycleGAN +

Channel；在生成器中引入通道注意力机制；3) CycleGAN + Channel + Spatial(ours)；同时对网络做出以上 2 改进。统计结果如表 3 所示，表中数据指标 PSNR 和 SSIM 下分别采用 2 对数据作为指标数据，更能保证数据的准确性，体

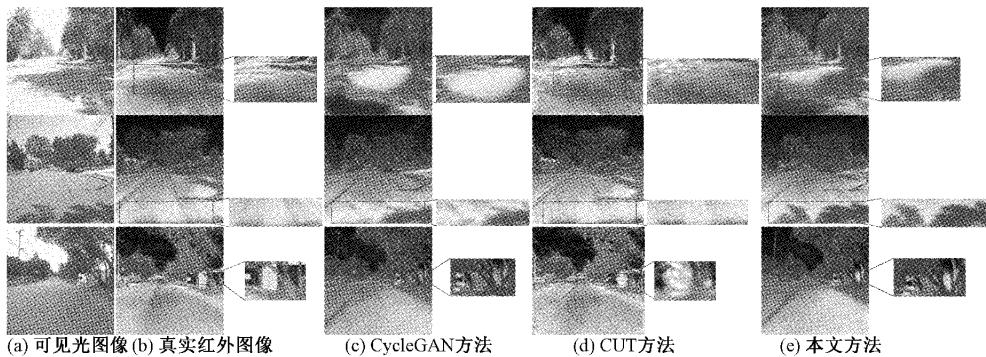


图 8 CycleGAN 与本文方法在 Flir 数据集上生成效果对比

现出模型方法的有效性。从表中可以看出分别引入通道注意力机制和空间注意力机制在 PSNR 和 SSIM 指标上有较少的提升。在结合通道注意力机制和像素注意力机制得到的效果相较实验(1)和实验(2),在 PSNR 和 SSIM 指标上有较大的提升。

消融实验效果如图 9 所示。从图中可以看出,在 CycleGAN+Spatial 中生成的图像细节信息有较好的体现,但是纹理信息突出不够明显。在 CycleGAN+Channel 实验中,生成图像的纹理信息非常好,细节信息有些丢失。二者相互结合,能生成较好的红外图像纹理信息,突出细节。

表 3 消融实验客观评价指标结果

方法	数据集	OSU 序列 3			
		PSNR/dB		SSIM	
CycleGAN		17.03	17.28	0.68	0.69
CycleGAN+Spatial		17.30	17.49	0.69	0.70
CycleGAN+Channel		17.44	17.73	0.69	0.69
本文		18.24	18.39	0.75	0.75

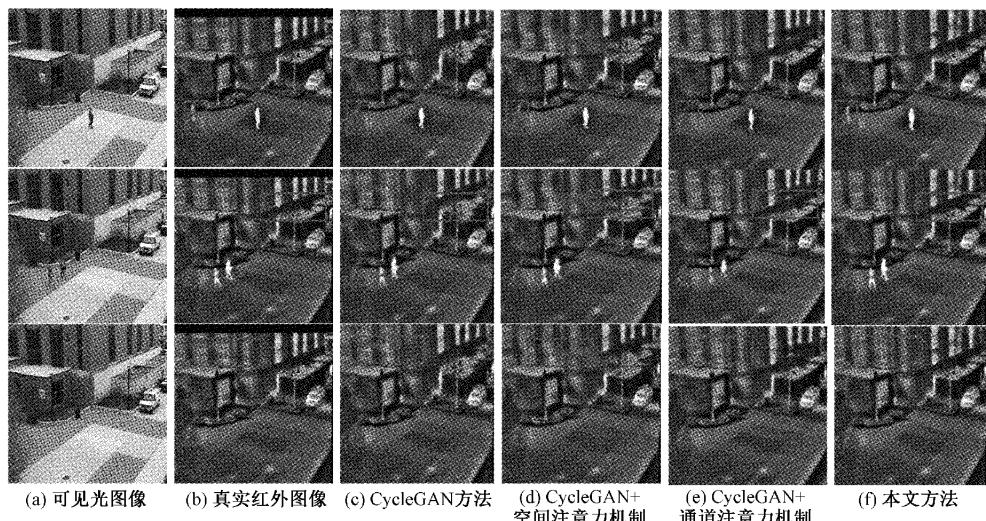


图 9 在 OSU 色热数据集上的消融实验结果

可以看出,采用 ResNet 可以使图像特征提取更充分。与通道注意力机制和空间注意力机制相结合,最终使图像生成的效果得到了显著性的提升。以上消融实验结果表明本文所提出的方法在红外图像纹理细节信息丢失严重的情况下是有效的。

4 结 论

针对可见光图像生成的红外图像的细节信息不突出、图像质量低的问题,本文提出了基于改进的 CycleGAN 的

方法实现红外图像生成。在生成器中采用采用了特征提取能力更好的 ResNet,可以对红外图像特征充分提取;同时本文在 ResNet 中引入通道注意力机制和空间注意力机制,提升模型训练时对弱感知区域的特征和纹理信息的关注,丰富图像生成细节。通过大量的实验以及数据表明本文提出的方法具有更好的细节生成能力,在一定程度上提升了生成的红外图像的质量,保证生成的红外图像有丰富的细节信息。但是该方法不易收敛,训练时间长。未来将通过改进算法,在保证图像生成质量的情况下,加快算法

的收敛速度。

参考文献

- [1] 陈震,杨小平,张聪炫,等.基于补偿机制的NSCT域红外与可见光图像融合[J].仪器仪表学报,2016,37(4):860-870.
- [2] 姜骞,刘亚东,方健,等.基于轮廓特征的电力设备红外和可见光图像配准方法[J].仪器仪表学报,2020,41(11):252-260.
- [3] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. Advances in Neural Information Processing Systems, 2014, 27: 1-9.
- [4] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [J]. ArXiv Preprint, 2015, ArXiv:1511.06434.
- [5] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1125-1134.
- [6] WANG T C, LIU M Y, ZHU J Y, et al. High-resolution image synthesis and semantic manipulation with conditional gans[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8798-8807.
- [7] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C]. International Conference on Machine Learning, PMLR, 2017: 214-223.
- [8] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks [C]. International Conference on Machine Learning, PMLR, 2019: 7354-7363.
- [9] LIN Z, FENG M, SANTOS C N, et al. A structured self-attentive sentence embedding[J]. ArXiv Preprint, 2017, ArXiv:1703.03130.
- [10] LIU M Y, TUZEL O. Coupled generative adversarial networks [J]. Advances in Neural Information Processing Systems, 2016, 29, DOI:10.48550/arXiv.1606.07536.
- [11] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 2223-2232.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [13] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [15] QIAN X, ZHANG M, ZHANG F. Sparse gans for thermal infrared image generation from optical image[J]. IEEE Access, 2020, 8: 180124-180132.
- [16] AI-NAJJAR Y A Y, SOONG D C. Comparison of image quality assessment: PSNR, HVS, SSIM, UIQI [J]. International Journal of Scientific and Engineering Research, 2012, 3(8):1-5.
- [17] LI S, HAN B, YU Z, et al. I2V-GAN: Unpaired infrared-to-visible video translation[C]. Proceedings of the 29th ACM International Conference on Multimedia, 2021: 3061-3069.
- [18] PARK T, EFROS A A, ZHANG R, et al. Contrastive learning for unpaired image-to-image translation [C]. In Proceedings of the European Conference on Computer Vision, 2020: 319-345.

作者简介

易星,硕士研究生,主要研究方向为深度学习与图像生成。

E-mail:yixing@sia.cn

赵怀慈,博士,研究员,博士生导师,主要研究方向为图像处理、复杂系统建模与仿真技术,指挥、控制、通信与信息处理技术方面的研究等。

E-mail:hczhao@sia.cn

潘昊(通信作者),博士,讲师,硕士生导师,主要研究方向为边缘计算、大数据分析与数据挖掘、人工智能方面的研究等。

E-mail:panhao@syuct.edu.cn