

9-17-2021

## An Improved SRGAN Infrared Image Super-Resolution Reconstruction Algorithm

Hu Lei

*1. School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China; ;*

Zugen Wang

*1. School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China; ;*

Chen Tian

*2. Electric Power Research Institute, State Grid Jiangxi Electric Power Co., Ltd, Nanchang 330096, China; ;*

Yongmei Zhang

*3. School of Information, North China University of Technology, Beijing 100144, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research, Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# An Improved SRGAN Infrared Image Super-Resolution Reconstruction Algorithm

## Abstract

**Abstract:** Aiming at the low resolution of infrared images, an improved SRGAN super-resolution reconstruction algorithm is designed. In the generative network, the method of *applying the residual dense network to obtain the image features extracted from each network layer so as to retain more high-frequency information of the image, and adopting a progressive upsampling method to improve the super-resolution reconstruction effect under a large scaling factor. In terms of the loss function, the perceptual loss that is more in line with human senses is adopted* to make the generated image being closer to the real high-resolution image of senses and content. Experimental results show that the quality of reconstructed infrared image is better than that of the current representative methods in the subjective and objective evaluation.

## Keywords

infrared image, super-resolution reconstruction, generative adversarial network, residual dense network

## Recommended Citation

Hu Lei, Wang Zugen, Chen Tian, Zhang Yongmei. An Improved SRGAN Infrared Image Super-Resolution Reconstruction Algorithm[J]. Journal of System Simulation, 2021, 33(9): 2109-2118.

## 一种改进的 SRGAN 红外图像超分辨率重建算法

胡蕾<sup>1</sup>, 王足根<sup>1</sup>, 陈田<sup>2</sup>, 张永梅<sup>3</sup>(1. 江西师范大学 计算机信息工程学院, 江西 南昌 330022; 2. 国网江西省电力有限公司 电力科学研究院, 江西 南昌 330096;  
3. 北方工业大学 信息学院, 北京 100144)

**摘要:** 针对红外图像分辨率偏低的问题, 设计了一种改进的超分辨率生成对抗网络(Super-Resolution Using a Generative Adversarial Network, SRGAN)算法。在生成网络中, 提出应用残差密集网络获取各网络层提取的图像特征以保留图像更多的高频信息, 并采用渐进式上采样方式以提升大缩放因子下超分辨率重建效果。在损失函数方面采用更符合人类感官的感知损失, 使生成图像在感官和内容上与真实高分辨率图像更加接近。实验结果表明: 所提方法重建的超分辨率红外图像质量在主观及客观评价中均要优于当前具有代表性的方法。

**关键词:** 红外图像; 超分辨率重建; 生成式对抗网络; 残差密集网络

中图分类号: TP391.4 文献标志码: A 文章编号: 1004-731X (2021) 09-2109-10

DOI: 10.16182/j.issn1004731x.joss.20-0450

## An Improved SRGAN Infrared Image Super-Resolution Reconstruction Algorithm

Hu Lei<sup>1</sup>, Wang Zugen<sup>1</sup>, Chen Tian<sup>2</sup>, Zhang Yongmei<sup>3</sup>(1. School of Computer Information Engineering, Jiangxi Normal University, Nanchang 330022, China;  
2. Electric Power Research Institute, State Grid Jiangxi Electric Power Co., Ltd, Nanchang 330096, China;  
3. School of Information, North China University of Technology, Beijing 100144, China)

**Abstract:** Aiming at the low resolution of infrared images, an improved SRGAN super-resolution reconstruction algorithm is designed. In the generative network, the method of *applying the residual dense network to obtain the image features extracted from each network layer so as to retain more high-frequency information of the image, and adopting a progressive upsampling method to improve the super-resolution reconstruction effect under a large scaling factor.* In terms of the loss function, the *perceptual loss that is more in line with human senses is adopted* to make the generated image being closer to the real high-resolution image of senses and content. Experimental results show that the quality of reconstructed infrared image is better than that of the current representative methods in the subjective and objective evaluation.

**Keywords:** infrared image; super-resolution reconstruction; generative adversarial network; residual dense network

## 引言

红外图像的获取不受外部光线的影响, 且温度灵敏度高、探测距离远, 被广泛应用于对象温度监测, 特别是设备运行状态监测、夜间野外动物监测、视频行人监控及车辆监测等场合。红外成像系统的

探测器阵列数目有限, 探测单元尺寸受限导致红外图像分辨率低, 当前市场上典型的红外视频监控探头的分辨率为 320×240, 难以满足实际应用需求。利用单帧或者多帧低分辨图像通过信号处理、图像处理的方式重建高分辨率图像, 即图像超分辨率重建技术, 具有成本低、相对容易实现优点, 被广泛

收稿日期: 2020-07-07 修回日期: 2020-09-23

基金项目: 国家自然科学基金(61662033, 61262036)

第一作者: 胡蕾(1980-), 女, 博士, 副教授, 研究方向为图像处理与分析、数据智能分析等。E-mail: hulei@jxnu.edu.cn

应用在医学图像处理、显微镜成像、视频监控以及遥感成像等领域。本文研究单帧低分辨率红外图像的超分辨率重建。

图像超分辨率重建技术主要可分为基于插值的方法<sup>[1]</sup>和基于学习的方法<sup>[2]</sup>。基于学习的方法因效果较好是目前主流的方法,该方法通过大量数据学习到低分辨率图像和高分辨率图像之间的对应关系来重建超分辨率图像,其中深度学习框架下所重建的图像在主观和客观评价方面较之前的方法都有巨大的提升。Dong 等<sup>[3]</sup>利用多层卷积神经网络实现了可见光图像的超分辨率重建,所提出的超分辨率卷积神经网络(Super-Resolution Convolutional Neural Network, SRCNN)方法分别获取低分辨率和高分辨率图像的特征,通过大量学习获得两者的映射关系,重建出的高分辨率图像质量比传统双三次线性插值(Bi-cubic Interpolation, Bic)<sup>[4]</sup>方式有显著的提高。而 Shi 等<sup>[5]</sup>在 SRCNN 的基础上提出高效亚像素卷积神经网络(Efficient Sub-Pixel Convolutional Neural Network, ESPCNN)方法,在上采样操作中引入子像素卷积,获得比 SRCNN 更好的效果。Lim 等<sup>[6]</sup>基于残差网络提出单幅图像超分辨率的增强型深度残差网络(Enhanced Deep Residual Networks for Single Image Super-Resolution, EDSR)方法,改进了残差结构,将残差结构中的归一化层去除,在空间上能节省大概 40%,同时引入多尺度模型解决多倍数问题,并且在 NTIRE2017 超分辨率挑战赛中获得冠军。Zhang 等<sup>[7]</sup>在超分辨率重建中引入残差密集网络,将残差网络和密集网络结合形成了一种连续记忆机制,通过密集方式强化残差网络中局部与全局特征级联,重建后的超分辨率图像模糊效应抑制得比较好。生成对抗网络(Generative Adversarial Network, GAN)也被应用于超分辨率重建,以超分辨率生成对抗网络(Super-Resolution Using a Generative Adversarial Network, SRGAN)<sup>[8]</sup>方法为代表,该类方法采用子像素卷积<sup>[9]</sup>对经过卷积的低分辨率图像上采样生成高分辨率图像,经过判别网络分析生成的高分辨率图像和原始高分辨率图像的相似性,并且利用感

知损失取代最小均方差,使得生成图像卷积得到的高层信息与原始图像卷积得到的高层信息接近。李方彪等<sup>[10]</sup>提出的 M-GAN 超分辨率重建方法针对多帧红外图像,放大因子  $r=3$  时效果较好。

针对单帧红外图像分辨率低、对比度差、视觉效果模糊等问题,本文在 SRGAN<sup>[8]</sup>的基础上提出一种基于残差密集块网络的超分辨率重建算法(Super-resolution Reconstruction Based on Residual Dense Block Network, SRRDB),引入残差密集网络保留更多的高频细节信息,同时为了使得大缩放因子的学习过程更加容易,引入渐进式上采样<sup>[11]</sup>方法,从客观与主观对所提方法进行评价。

## 1 相关工作

GAN 是一种极大极小的博弈过程,它由 2 个相互对抗的网络组成:生成网络  $G$  捕获数据分布,判别网络  $D$  估计样本来自训练数据而不是来自生成网络  $G$  的概率<sup>[3]</sup>。为了更好地训练生成网络和判别网络,GAN 构建式(1)所示的目标函数:

$$\min_G (\max_D V(D, G)) = E_{y \sim p_{\text{data}}(y)} [\log D(y)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中:  $y$  为真实数据;  $p_{\text{data}}$  为真实数据的分布;  $z$  为噪声;  $p_z$  为原始噪声的分布;  $E$  为期望。式(1)分 2 步理解,第一步是判别网络的优化  $\max_D V(D, G)$ ,  $E_{y \sim p_{\text{data}}(y)} [\log D(y)]$  为对真实数据  $y$  分布  $p_{\text{data}}$  中采用的样本,其被判别网络判定为真实样本概率的期望。对于真实数据分布中的样本,判别网络预测为正样本的概率越接近 1 越好。因此希望最大化这一项。  $E_{z \sim p_z(z)} [\log(1 - D(G(z)))]$  为对于从噪声变量  $z$  分布  $p_z(z)$  中得到的样本,经过生成网络之后得到的生成图片,送入判别网络,预测噪声样本概率的负对数的期望,这个值越大越接近 0,代表判别网络越好。第二步是生成网络的优化通过  $\min_G (\max_D V(D, G))$  实现,即最小化判别网络目标函数的最大值,其中判别网络目标函数的最大值是真实数据分布与生成数据分布的 JS(Jensen-Shannon)

散度, 越小表示 2 个分布越接近。

从图像超分辨率重建角度出发, 生成网络的输入为低分辨率图像  $I^{LR}$ , 输出为生成的高分辨率图像  $I^{SR}$ ; 判别网络输入为  $I^{SR}$  和原始高分辨率图像  $I^{HR}$ , 输出则为对输入图像来源的判断, 则式(1)可转换成式(2)。式(2)是期望训练出生成尽可能接近原始高分辨率图像的高分辨率图像。

$$\min_G \max_D E_{I^{HR} \sim P_{data}, I^{LR}} [\log D(I^{HR})] + E_{I^{LR} \sim P_G(I^{LR})} [\log(1 - D(G(I^{LR})))]$$
 (2)

生成对抗网络图像超分辨率重建流程如图 1 所示, 为了得到更好的生成网络和判别网络, 训练和测试中, 原始红外图像视为真实高分辨率图像  $I^{HR}$ , 低分辨率图像  $I^{LR}$  由  $I^{HR}$  应用高斯滤波器下采样获得。将  $I^{LR}$  输入到生成网络中得到生成的高分辨率图像  $I^{SR}$ , 将伪造图像和真实图像输入到判别网络中, 判别  $I^{SR}$  与  $I^{HR}$  是否相似, 计算对抗损失, 通过  $I^{SR}$  和  $I^{HR}$  计算内容损失, 将内容损失和对抗损失加权计算出感知损失, 优化感知损失, 督促生成网络和判别网络学习, 当迭代轮数达到 epoch 结束训练。

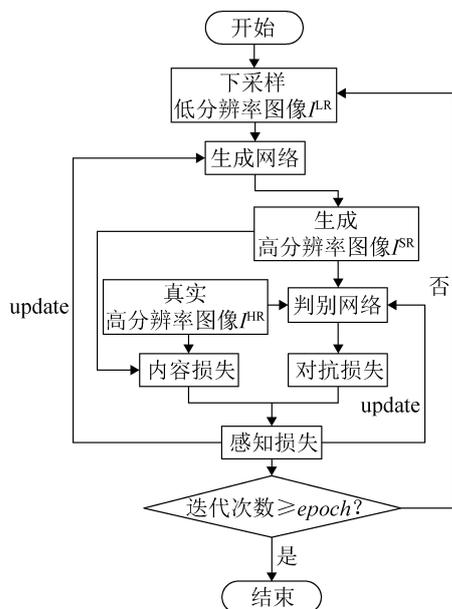


图 1 生成对抗网络图像超分辨率重建流程图  
Fig. 1 GAN framework for image super-resolution reconstruction flowchart

## 2 本文方法

### 2.1 算法原理

将 GAN 网络运用到超分辨率领域中就是需要训练生成网络  $G$ , 通过生成网络的前向传播  $G_{\theta_G}$  生成图像, 其中  $\theta_G = \{W_l; L; b_l; L\}$  是生成网络的参数, 表示生成网络的第  $L$  层神经网络的权重  $W_l$  和偏差  $b_l$ , 在损失函数  $I^{SR}$  的指导下,  $\theta_G$  可以通过学习  $I_n^{HR}$  和  $I_n^{LR}$  ( $n=1, 2, \dots, N$ ) 之间的映射关系进行调整以获得最优参数:

$$\hat{\theta}_G = \arg \min_{\theta_G} \frac{1}{N} \sum_{n=1}^N I^{SR}(G_{\theta_G}(I_n^{LR}), I_n^{HR})$$
 (3)

在 SRGAN 中, 特征提取部分采用残差网络, 该网络提取特征时会丢失部分分层特征, 并且红外图像分辨率差、对比度低、信息量少以及信噪比低, 残差网络提取红外图像特征时, 特征丢失更为严重。残差密集网络充分利用低分辨率图像的所有分层特征, 有些分层特征是有利于生成高分辨率图像的。在 SRGAN 的基础上, SRRDB 算法的生成网络中引入残差密集网络和渐进式上采样, 并针对红外图像调整感知损失函数参数。

### 2.2 网络结构

本文生成网络和判别网络如图 2 所示。其中红色块表示残差密集网络, 蓝色块表示渐进式上采样,  $k$  为卷积核尺寸,  $n$  为卷积核数量,  $s$  为步长。在生成网络提取特征信息时采用残差密集网络, 重建图像时利用渐进式上采样的方法; 而判别网络是利用卷积、激活函数、全连接神经网络组合设计而成。

生成网络输入输出图像尺寸均为  $128 \times 128 \times 3$ 。前半部分残差密集网络包含 1 个 Conv-Relu 的组合、14 个 Conv-BN(Batch Normalization)-Relu 的组合和 1 个 Conv-BN 的组合, 每个组合中的 Conv 卷积核大小均为  $7 \times 7$ , 步长为 1, 16 个组合中卷积核数量均为 64。后半部分是渐进式上采样、多重卷积和 tanh 激活函数的组合, 其中一共经历 7 个 Conv 卷积, 卷积核大小均为  $7 \times 7$ , 步长为 1, 卷积核数量分别 256, 64, 64, 256, 64, 32, 3。最后经过 tanh 函数, 生成高分辨率图像。

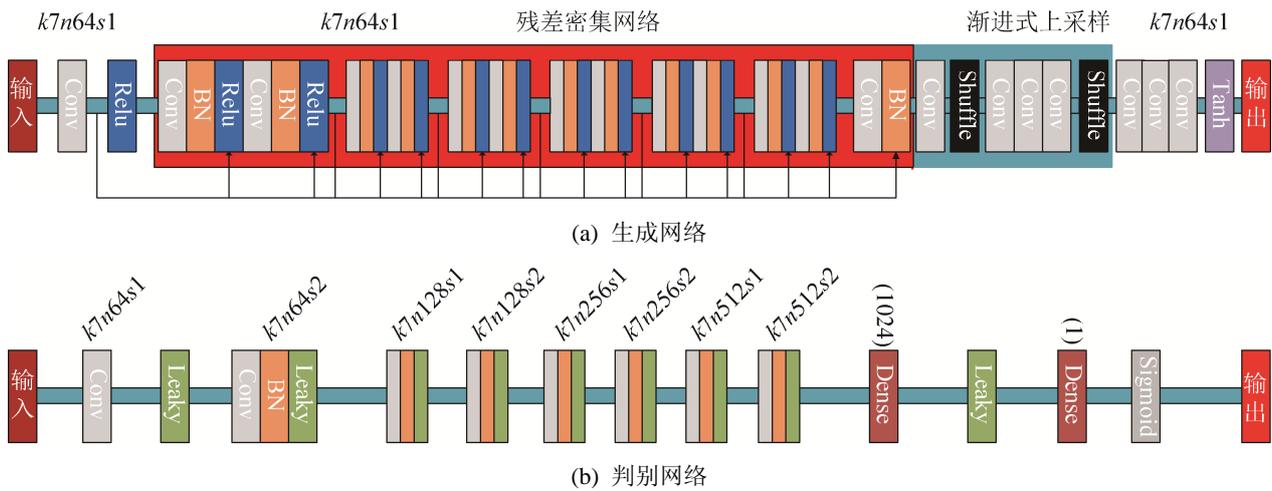


图2 生成网络和判别网络结构图  
Fig. 2 Structure diagram of generator network and discriminator network

判别网络输入图像尺寸  $128 \times 128 \times 3$ ，输出为经过全连接神经网络(Dense)神经元的值和经过Sigmoid激活函数的概率值。前半部分卷积模块经过1个Conv-Leaky\_relu的组合和7个Conv-BN-Leaky\_relu的网络组合，其中Conv卷积核大小均为  $7 \times 7$ ，Conv卷积的步长分别为：1, 2, 1, 2, 1, 2, 1, 2, Conv卷积核数量为：64, 64, 128, 128, 256, 256, 512, 512。后半部分是由Dense-Leaky\_relu激活函数和Dense-Sigmoid函数组合而成，其中2个Dense神经元个数分别为：1024, 1。最后输出判断生成图像与真实图像相似的概率值。

### 2.3 残差密集网络

残差密集网络是由残差网络和密集网络组成，其中残差网络提取全局特征，而密集卷积层提取局部特征。残差密集网络结合了残差网络和密集网络的特性，将全局特征和局部特征融合形成连续的记忆机制，通过前一个残差密集网络提取到的特征链接到当前残差密集网络的所有层。其中每个残差密集块是由Conv-BN-ReLU组合而成，该残差密集网络结构如图3所示，其中Conv为卷积，BN为归一化，ReLU为激活函数， $k$ 为卷积核尺寸， $n$ 为卷积核数量， $s$ 为步长。

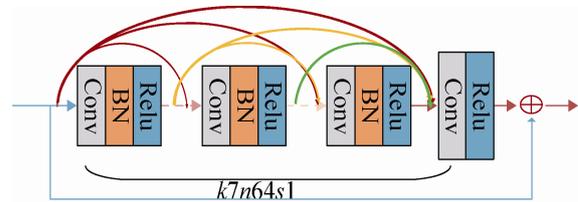


图3 残差密集网络  
Fig. 3 Residual dense network

### 2.4 渐进式上采样

渐进式上采样采用子像素卷积实现，单通道下子像素卷积过程如图4所示，在子像素卷积中，首先使用普通卷积来产生具有 $r \cdot r$ 倍通道的输出，生成大小为 $h \cdot r \cdot w \cdot r$ 的亚像素图像，即图4中的卷积操作，其中蓝色框表示输入，其他颜色框表示不同卷积操作的输出， $r$ 为上采样因子， $h$ ， $w$ 为亚像素图像的高、宽，然后执行重建操作，将亚像素图像按照顺序重组，得到高分辨率图像。与反卷积相比，子像素卷积的最大优点是较大的感受野，能提供更多的上下文信息生成更准确的细节。

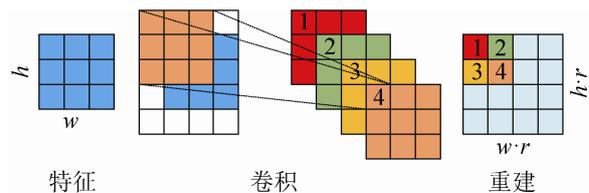


图4 子像素卷积  
Fig. 4 Sub-pixel convolution

如果仅在一个步骤中执行上采样操作, 将极大地增加大比例因子的学习难度, 并且每个比例因子都需要一个单独的超分辨率重建模型, 无法满足多比例因子超分辨率重建的需求。为了解决此问题, 本文采用渐进式上采样方式, 如图 5 所示, 其中 Conv 表示卷积, Sub-Pixel Conv 表示子像素卷积。低分辨率图像特征作为输入, 经过 Conv 后, 进入第一个 Sub-Pixel Conv 阶段, 完成第一次放大; 将放大后的图像经过 3 层 Conv, 进入第二个 Sub-Pixel Conv 阶段, 将第二次上采样后的超分辨率图像特征作为输出。引入渐进式上采样的方式不仅可极大地降低学习难度<sup>[12]</sup>, 而且在较大比例因子情况下, 还能获得更好的多尺度超分辨率效果, 并且不会引入过多的空间和时间成本。

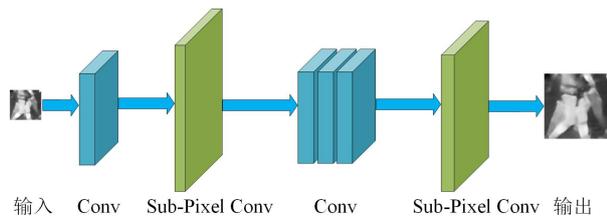


图 5 渐进式上采样  
Fig. 5 Progressive upsampling

### 2.5 损失函数

本文所提 SRRDB 算法是基于 GAN 网络生成图像, 而 GAN 网络的损失函数就是使生成网络和判别网络更加准确。为了使生成网络生成的图像更加逼真, 结合内容损失  $l_{MSE}^{SR}$  使生成的图像和原始高清图的欧氏距离更小, 同时结合对抗损失  $l_{Gen}^{SR}$  使判别网络能力更强。因此, 为了使得生成的图像更符合人类感知, 本文采用 SRGAN 中的感知损失  $l^{SR}$ , 该损失由内容损失  $l_{MSE}^{SR}$  和对抗性损失  $l_{Gen}^{SR}$  2 部分组成:

$$l^{SR} = l_{MSE}^{SR} + \lambda l_{Gen}^{SR} \quad (4)$$

$$l_{MSE}^{SR} = \frac{1}{r^2 WH} \sum_{x=1}^{rW} \sum_{y=1}^{rH} (I_{x,y}^{HR} - G_{\theta_G}(I_{x,y}^{LR}))^2 \quad (5)$$

$$l_{Gen}^{SR} = \sum -\ln D_{\theta_D}(G_{\theta_G}(I^{LR})) \quad (6)$$

式中:  $\lambda$  为权重系数;  $r$  为放大因子;  $W$  为图像宽;

$H$  为图像高;  $I^{HR}$  为高分辨率图像;  $G$  为生成网络;  $\theta_G$  为生成网络参数;  $I^{LR}$  为低分辨率图像;  $D$  为判别网络;  $\theta_D$  为判别网络参数。

## 3 实验结果及分析

### 3.1 数据集和质量评价指标

目前针对超分辨率重建的公开的红外图像数据集较少, 本文采用 FIR 公司提供的 CVC-09/CVC-14 数据集, 该数据集包括白昼图和夜视图, 图像均为单通道。由于该数据集是用于自动驾驶, 因此数据集以街景为主, 图像内容主要包括街道、行人、汽车、交通指示以及房屋建筑等。本文在 CVC-09 和 CVC-14 数据集中随机选取 3 000 多张图片, 每张图片随机裁剪成  $128 \times 128$  大小的图像作为模型训练的真实高分辨率图像数据集, 对裁剪后的图像下采样作为模型训练的低分辨率图像数据集, 下采样因子  $r=4$ , 低分辨率图像大小为  $32 \times 32$ 。测试时, 在 CVC-09 和 CVC-14 中选取未被选入训练数据集的图像, 相同处理后得到的低分辨率图像作为测试数据集, 输入到模型中生成高分辨率图像。

在超分辨率重建算法中, 质量评价方法有主观评价和客观评价。主观评价指通过实验人员观看图像的主观感受来评价图像质量; 而客观评价则是设计量化指标, 通过一定指标来衡量图像质量的好坏。本文选取 2 种常用的客观评价指标: 峰值信噪比(Peak Signal to Noise Ratio, PSNR)和结构相似度 (Structural Similarity Index, SSIM)。与此同时, 本文与 Bic<sup>[4]</sup>, SRCNN<sup>[3]</sup>, ESPCNN<sup>[5]</sup>, EDSR<sup>[6]</sup>, SRGAN<sup>[8]</sup>等经典和主流方法作了实验对比, 实验对比过程中, 若其他方法是针对 RGB 等多通道图, 则其各通道图均为红外单通道图。

### 3.2 训练细节和参数

本文的 SRRDB 算法在单张英伟达 1 080 ti 显卡上实现, 训练生成网络时, 对输入图像做归一化处理, 将输入图像的像素值取值范围线性映射到  $[-1, 1]$ 。对于每一批次, 本文随机选取 32 张高分

分辨率图像作为输入,通过生成网络生成的高分辨率图像与原始高分辨率图像计算像素损失。优化过程采用 Adam 优化器,其中衰减率  $\beta_1=0.9$ ,  $\beta_2=0.99$ , 学习率  $learning-rate=0.0001$ , 迭代轮数  $epoch=150$ , 权重初始化采用正态分布的方式生成符合标准差为 0.02 的值,以此参数对生成网络训练。训练过程中,损失函数变化情况如图 6 所示,包含了生成网络的内容损失变化曲线  $content\_loss$ , 判别网络的损失函数变化曲线  $d\_loss$ , 生成网络的感知损失函数变化曲线  $perception\_loss$ 。

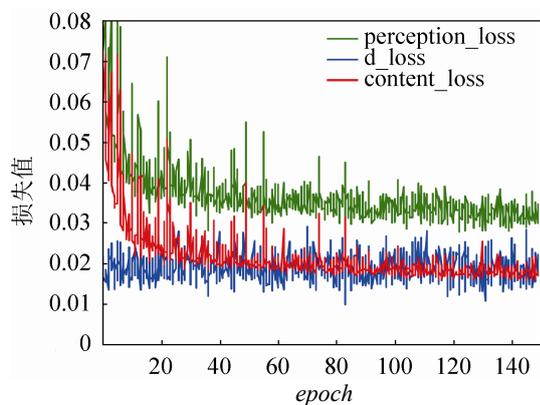


图 6 生成对抗网络损失函数变化曲线  
Fig. 6 Change curve of GAN loss function

### 3.3 损失函数中参数 $\lambda$ 的选择

损失函数中参数  $\lambda$  主要是对内容损失权重和对抗性损失权重的考量, SRGAN 方法中设置  $\lambda=0.001$ , 本文参考 SRGAN 方法在 0.0001~0.1 之间选择部分典型值进行了实验分析。本文在保证生成网络生成图像的质量以及保证判别网络能很好地判别出生成网络生成图像的好坏之间平衡, 分析的  $\lambda$  值主要有: 0.0001, 0.0005, 0.001, 0.005, 0.1 等, 实验结果如表 1 所示。根据 PSNR 和 SSIM 评价指标, 当  $\lambda=0.0005$  时, 效果最好, 后续实验过程中  $\lambda$  取值为 0.0005。

### 3.4 卷积核大小的选择

在网络结构中卷积核的大小是可以选择的, 而卷积核的大小是感受野大小的决定性因素, SRGAN 卷积核大小  $k$  为 3, 但是一般在深度学习的任务中,

卷积核大小  $k$  多为 3, 5 和 7, 因此本文选择  $k=3, 5, 7$  进行实验以选择合适大小。本文通过对比实验得出, 随着卷积核  $k$  的增大, 重建图像在主观评价和客观评价中均有所提高, 实验结果中  $k$  与 SSIM 和 PSNR 指标的关系如图 7 所示。但是随着  $k$  值的增大, 算法的参数增多, 需要的计算力也要求更高, 因此本文选取的卷积核大小  $k=7$ 。

表 1  $\lambda$  参数对 PSNR 和 SSIM 的影响分析  
Tab. 1 Analysis of influence of  $\lambda$  on PSNR and SSIM

$\lambda$	PSNR	SSIM
0.0001	31.18	0.90
0.0005	31.54	0.91
0.0010	30.87	0.89
0.0050	30.67	0.90
0.0100	30.52	0.89
0.0500	30.44	0.89
0.1000	24.37	0.75

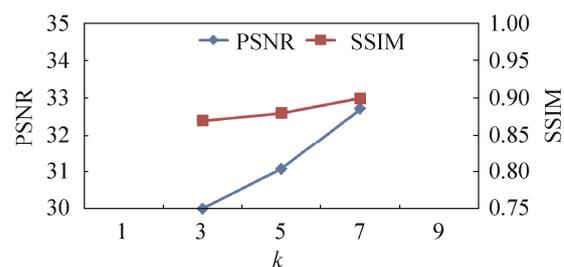


图 7  $k$  值对 PSNR 和 SSIM 的影响分析  
Fig. 7 Analysis of influence of  $k$  on PSNR and SSIM

### 3.5 结果分析

本文的测试图像集是在 CVC-09 和 CVC-14 中随机选取的 16 张图片, 有 6 张白昼图和 10 张夜视图, 内容包括人、车、马路等。本文方法及其他方法对测试图像集的评价情况如表 2 所示, 从表 2 中可以得出, 本文所提出的 SRRDB 模型在 CVC-09 和 CVC-14 数据集测试所得的客观评价指标 PSNR 和 SSIM 值都要高于其他几种算法。

本文从测试图像集中选取包含道路、行人、车辆的典型图像进一步说明本文所提方法的有效性, 实验结果如图 8~12 和表 3 所示。从实验结果目视分析, 传统的 Bic 方法所重建的图像整体比较模糊, ESPCNN 方法所重建的图像存在噪声点多、视觉效

果不佳等问题, 而 SRCNN 重建后的图像在明亮程度方面与原始高分辨率图像相差较大, 且图像稍显平滑。EDSR 方法在红外图像重建时出现很多矩阵块, 原因可能是本文所使用的红外图像是单通道的, 输入网络的图像 3 通道的值一样, 此时的 EDSR 方法并不适用在单通道红外图像超分辨率重建任务上。SRGAN 在重建质量上优于以上方法, 但是在细节纹理重建上还是略显不佳。本文 SRRDB 方法实验结果优于其他方法主要原因有: ①采用的红

外图像数据集是 CVC-09 和 CVC-14, 所选数据集为单通道、背景不复杂、图像内容均为街景; ②在生成对抗网络的基础上引入残差密集网络, 残差密集网络可以充分利用原始低分辨率图像的所有分层特征, 保证低层信息传到高层, 相对其他方法而言, 对低分辨率图像信息利用更为充分, 提高了信息的利用率。在 RGB 图像上的实验结果表明, 本文方法在红外图像上的性能优于 RGB 图像, 在 RGB 图像超分辨率重建上存在一定的局限性。

表 2 测试图像集超分辨率重建结果比较

Tab. 2 Comparison of super-resolution reconstruction results of test image set

数据集	评价指标	Bic	ESPCNN	SRCNN	EDSR	SRGAN	SRRDB
CVC-09	PSNR	23.01	26.45	26.75	19.55	27.07	30.23
	SSIM	0.75	0.80	0.78	0.62	0.83	0.87
CVC-14	PSNR	22.54	26.53	26.81	19.27	27.01	29.97
	SSIM	0.83	0.81	0.79	0.59	0.85	0.90

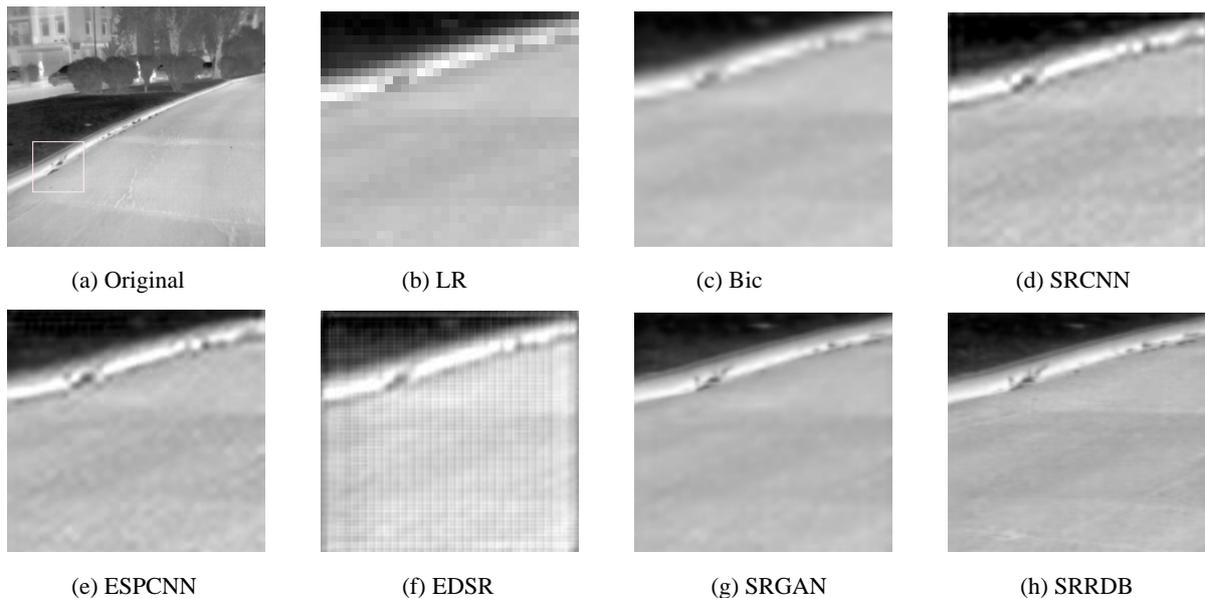
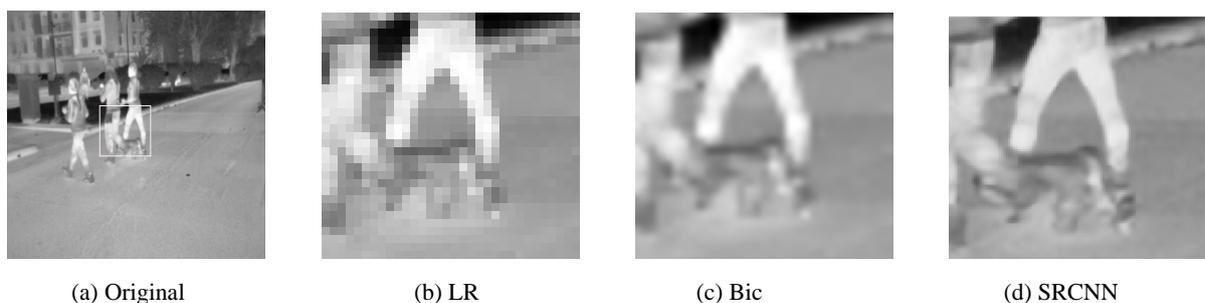


图 8 白昼道路图像实验结果

Fig. 8 Experimental results of road image during the day



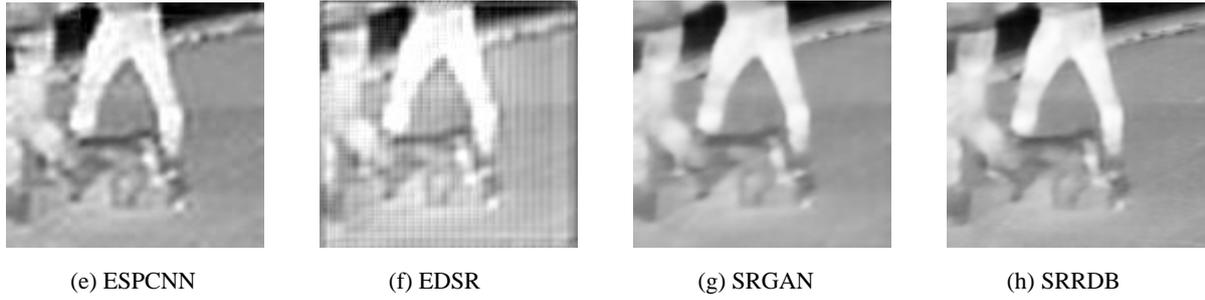


图9 白昼行人图像实验结果  
Fig. 9 Experimental results of pedestrian images during the day

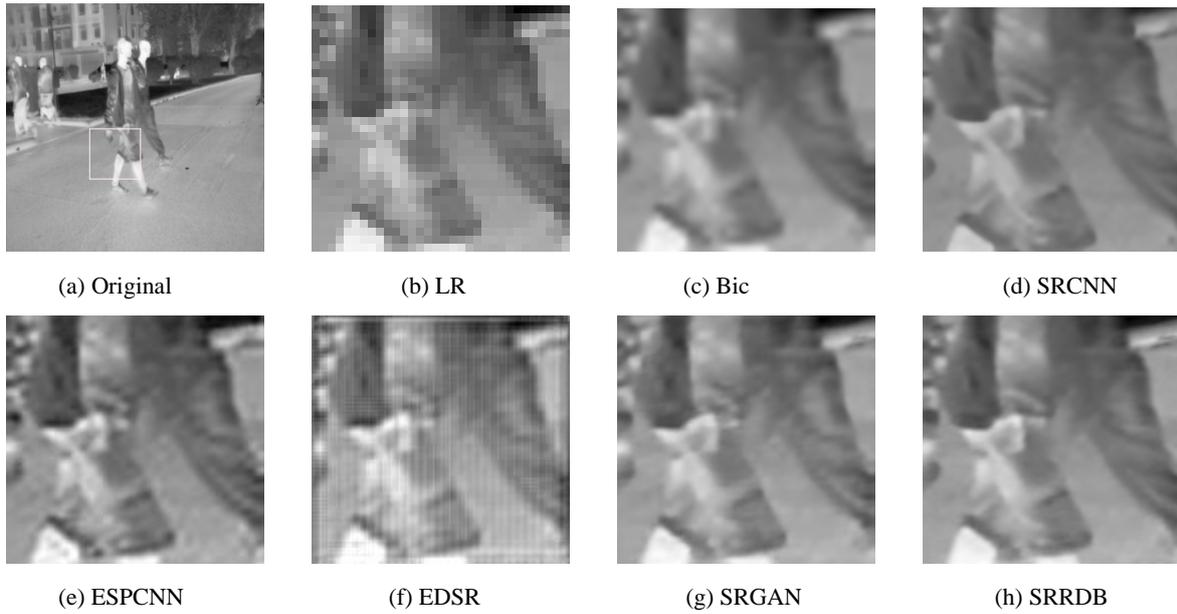


图10 夜视行人图像实验结果  
Fig. 10 Experimental results of pedestrian images at night

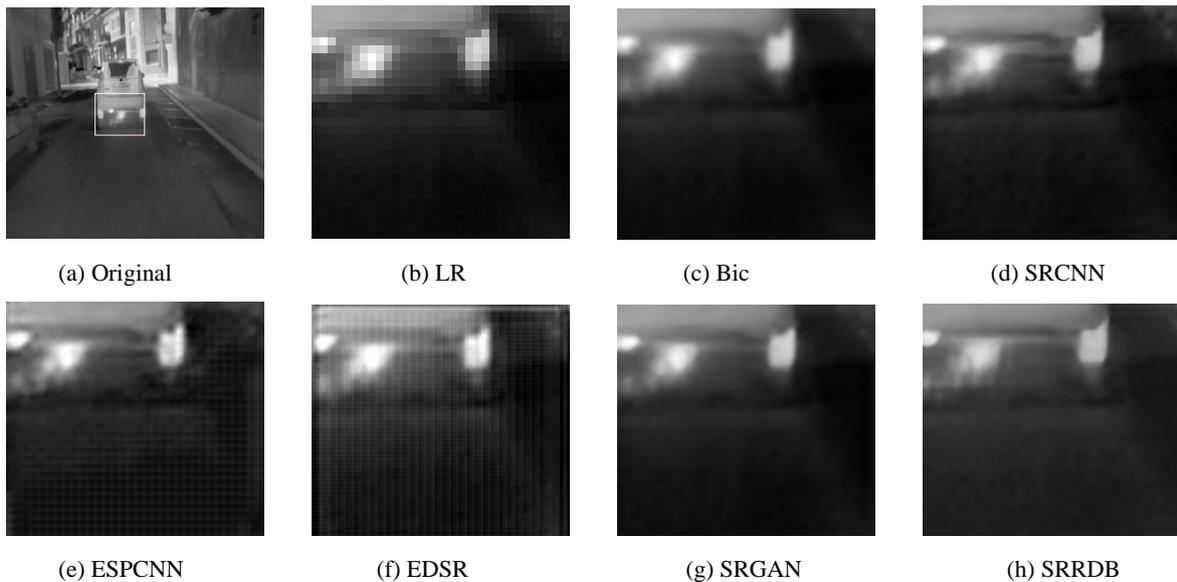


图11 夜视车辆轮胎图像实验结果  
Fig. 11 Experimental results of tire image at night

<http://www.china-simulation.com>

• 2116 •

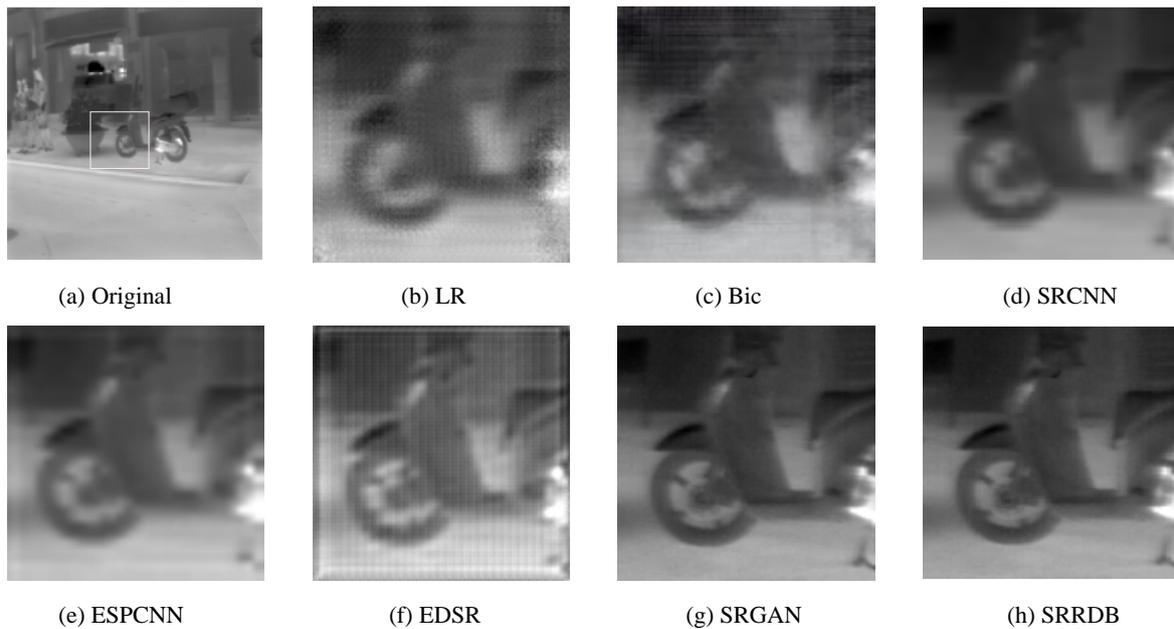


图 12 夜视摩托车图像实验结果

Fig. 12 Experimental results of motorcycle image at night

表 3 典型图像实验结果对比

Tab. 3 Comparison of typical image experiment results

图	Bic		SRCNN		ESPCNN		EDSR		SRGAN		SRRDB	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
8	23.77	0.79	26.63	0.81	27.80	0.82	18.38	0.64	31.91	0.87	39.66	0.96
9	23.72	0.75	28.06	0.82	28.06	0.82	19.85	0.67	30.92	0.87	33.44	0.91
10	26.53	0.84	29.16	0.85	28.73	0.87	20.83	0.73	27.09	0.88	32.62	0.93
11	28.25	0.85	28.02	0.71	27.75	0.85	21.83	0.56	31.55	0.87	34.37	0.91
12	20.57	0.79	23.58	0.75	21.16	0.69	16.47	0.63	30.55	0.89	33.47	0.90

## 4 结论

本文在 SRGAN 网络的基础上引入残差密集网络以及渐进式上采样方式, 在单帧红外图像超分辨率重建上取得了显著效果。相对于非 GAN 网络, 本文所提出的方法在低分辨率重建到高分辨率图像过程中获得了更多的高频信息, 使得放大因子为 4 的图像清晰且边缘尖锐。由于公开的高清红外图像数据集相对较少, 可供训练的数据也不够丰富, 且为单通道图像, 制约了红外图像超分辨率质量的进一步提高, 导致在方法中无法有效引入通道注意等机制, 无法从多个通道关联中获取更多的信息。网络结构、上采样的方式、注意力机制以及传统的图像处理等方法作为先验知识都会影响超分辨率重建的能力, 未来红外图像超分辨率重建仍然有很大的提高空间。

## 参考文献:

- [1] 王杰, 李洪兴, 王加银, 等. 一种图像快速线性插值的实现方案与分析[J]. 电子学报, 2009, 37(7): 1481-1486.  
Wang Jie, Li Hongxing, Wang Jiayin, et al. A Scheme and Its Analysis for Fast Line-ar Image Interpolation[J]. Acta Electronica Sinica, 2009, 37(7): 1481-1486.
- [2] Zhao Y, Chen Q, Sui X, et al. A Novel Infrared Image Super-Resolution Method Based on Sparse Representation [J]. Infrared Physics & Technology (S1350-4495), 2015, 71: 506-513.
- [3] Dong C, Loy C C, He K, et al. Image Super-Resolution Using Deep Convolutional Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence(S0162-8828), 2015, 38(2): 295-307.
- [4] Keys R. Cubic Convolution Interpolation for Digital Image Processing[J]. IEEE Transactions on Acoustics, Speech, and Signal Processing (S0096-3518), 1981, 29(6): 1153-1160.

- [5] Shi W, Caballero J, Huszár F, et al. Real-time Single Image and Video Super-resolution Using an Efficient Sub-Pixel Convolutional Neural Network [C]//IEEE Conference on Computer Vision And Pattern Recognition. Piscataway, NJ, USA: IEEE, 2016: 1874-1883.
- [6] Lim B, Son S, Kim H, et al. Enhanced Deep Residual Networks for Single Image Super-resolution [C]//IEEE Conference on Computer Vision And Pattern Recognition Workshops. Piscataway, NJ, USA: IEEE, 2017: 136-144.
- [7] Zhang Y, Tian Y, Kong Y, et al. Residual Dense Network for Image Super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 2472-2481.
- [8] Ledig C, Theis L, Huszár F, et al. Photo-realistic Single Image Super-resolution Using a Generative Adversarial Network[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2017: 4681-4690.
- [9] Zhang Y, Li K, Li K, et al. Image Super-resolution Using Very Deep Residual Channel Attention Networks [C]// European Conference on Computer Vision (ECCV). Berlin, Germany: Springer, 2018: 286-301.
- [10] 李方彪, 何昕, 魏仲慧, 等. 生成式对抗神经网络的多帧红外图像超分辨率重建[J]. 红外与激光工程, 2018, 47(2): 17-24.
- Li Fangbiao, He Xin, Wei Zhonghui, et al. Multiframe Infrared Image Super-resolution Reconstruction Using Generative Adversarial Networks[J]. Infrared and Laser Engineering, 2018, 47(2): 17-24.
- [11] Wang Y, Perazzi F, McWilliams B, et al. A Fully Progressive Approach to Single-image Super-resolution [C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops. Piscataway, NJ, USA: IEEE, 2018: 864-873.
- [12] 段友祥, 张含笑, 孙歧峰, 等. 基于拉普拉斯金字塔生成对抗网络的图像超分辨率重建算法[J]. 计算机应用, 2021, 41(4): 1020-1026.
- Duan Youxiang, Zhang Hanxiao, Sun Qifeng, et al. Image Super-resolution Reconstruction Algorithm Based on Laplacian Pyramid Generative Adversarial Network[J]. Journal of Computer Applications, 2021, 41(4): 1020-1026.