

# 基于轻量级金字塔密集残差网络的红外图像超分辨增强

左岑<sup>1</sup>, 杨秀杰<sup>2</sup>, 张捷<sup>3</sup>, 王璇<sup>2</sup>

(1. 重庆电子工程职业学院 人工智能与大数据学院, 重庆 401331;

2. 重庆望江工业集团有限公司, 重庆 400071; 3. 中国人民解放军陆军重庆军代局, 重庆 400050)

**摘要:** 现有的红外制导武器严重依赖操作手对目标的捕获, 其捕获的精度与目标的纹理细节正相关。为了提升弱小区域的显示质量, 满足现有导引头小型化、模块化、低成本的设计要求, 本文设计了一种基于轻量级金字塔密集残差网络的图像增强模型, 该模型在密集残差网络基础上通过密集连接层和残差网络来学习不同尺度图像之间的非线性映射, 充分利用多尺度特征进行高频残差预测。同时, 采用深度监督模块指导网络训练, 有利于实现较大上采样因子的超分辨增强, 提高其泛化能力。大量仿真实验结果表明本文所提出的超分辨模型能够获得高倍率的超分辨增强效果, 其重建质量也优于对比算法。

**关键词:** 超分辨增强; 轻量级; 红外图像; 深度学习; 特征级联; 损失函数; 恒等映射  
**中图分类号:** TP391      **文献标识码:** A      **文章编号:** 1001-8891(2021)03-0251-07

## Super-resolution Enhancement of Infrared Images Using a Lightweight Dense Residual Network

ZUO Cen<sup>1</sup>, YANG Xiujie<sup>2</sup>, ZHANG Jie<sup>3</sup>, WANG Xuan<sup>2</sup>

(1. College of Artificial Intelligence and Big Data, Chongqing Vocational College of Electronic Engineering, Chongqing 401331, China;

2. Chongqing Wangjiang Industrial Co. Ltd., Chongqing 400071, China;

3. Chongqing Military Agency of the PLA Army, Chongqing 400050, China)

**Abstract:** Existing infrared-guided weapons heavily rely on operators to acquire targets, and the accuracy of acquisition is positively correlated with a target's texture details. To improve the display quality of weak small regions and meet the design requirements of miniaturization, modularization, and low-cost seekers, an image super-resolution(SR) reconstruction algorithm based on a pyramid dense residual network is proposed. The dense residual network is the basic framework of the proposed model. Through the dense connection layer and the residual network, the model can learn the non-linear mapping between images of different scales, and the multi-scale feature can be used to predict the high-frequency residual. In addition, using the deep supervision module to guide network training is conducive to the realization of SR reconstruction with a larger upper-sampling factor and improvements to its generalization ability. A large number of simulation results show that our proposed model outperforms comparison algorithms and that it has a high engineering application value.

**Key words:** SR reconstruction, lightweight, infrared image, dense residual-network, loss function, deep supervision

## 0 引言

红外热像仪是光电设备不可或缺的成像模块, 通过采集热辐射生成红外图像, 能够实现全天候、全天时目标搜索、跟踪与识别、实现导航制导、态势感知、

威胁告警、对地观瞄等功能<sup>[1]</sup>。由于红外设备作用距离远, 初始目标的对比度低、尺寸小, 如何能快速发现目标是克敌制胜的关键。然而, 红外热像仪易受大气湍流、气溶胶散射等干扰的影响, 导致获取的红外图像退化且分辨率较低, 很难从图像中分辨出目标细

收稿日期: 2019-05-19; 修订日期: 2020-03-23.

作者简介: 左岑(1986-), 女, 汉族, 重庆垫江人, 硕士, 高级实验师, 研究方向: 计算机技术、模式识别等。E-mail: xuzq1979@outlook.com.

基金项目: 重庆市教委课题(KJ1729409); 重庆市教委教改重点项目(162072); 装备预研船舶重工联合基金。

节<sup>[2]</sup>。因此,只有将低分辨红外图像进行超分辨增强才能看清楚目标,进而实现目标的高精度锁定。

随着大数据处理与硬件性能提升,深度学习模型已经在视觉任务中获得了成果的应用,并展现了强大的学习性能,如图像分割<sup>[3]</sup>、目标检测与识别<sup>[4]</sup>、地物分类等<sup>[5]</sup>。2016年,Dong等人<sup>[6]</sup>首次将深度模型应用于超分辨领域,通过对双三次插值结果进行端到端深度学习,获取到高分辨率与低分辨率之间的非线性映射关系,实现图像重建;Riegler等人<sup>[7]</sup>提出将深度卷积网络与总广义变分方法相结合,在总变差正则化约束下提升超分辨的重建质量。在此基础上,国内外学者提出了许多优秀的改进方法,通过引入不同的先验信息作为正则化约束条件,利用深度模型得到潜在的隐藏特征,先验约束确保学习到细节信息与基准一致。文献[8]设计了一种两阶段深度网络的重建模型,首先利用深度网络检测单帧图像中的边缘结构,然后在边缘结构引导下逐渐微调深度模型的参数,最终实现高质量的超分辨图像。由于红外图像存在大量的团状噪声,导致深度网络获取的高分辨图像存在伪影与划痕<sup>[9]</sup>。为了实现超分辨增强并抑制住噪声,文献[10]在SRCNN(super-resolution convolutional neural network)<sup>[6]</sup>重建模型中增加了一路图像增强分支,利用高频特征与低频特征的一致性,有效地恢复出超分辨后的高频信息。基于SRCNN的改进算法都是将图像插值一定的倍数作为输入图像,再通过不同的网络模型实现低质量图像块的非线性映射,然而插值图可能会引入噪声并大大增加计算复杂度,同时存在上采样二义性。杨明等人<sup>[11]</sup>重新设计卷积神经网络的结构,通过将低层次特征和高层次特征聚合连接形成新的特征,以此提高图像放大的性能,项目组对该方法仿真结果表明,该方法虽然增加了图像的显示效果,但引入了太多的虚假场景,尤其是在空中背景重建出规则纹理,不适合观瞄应用。不同于前面提出的深度模型,Hui等人<sup>[12]</sup>提出了一种基于多尺度引导网络的超分辨模型,该模型直接使用低分辨图作为输入,通过反卷积进行上采样,通过两个连续的卷积层进行特征融合,以重构丢失的细节信息。文献[13]设计了一个拉普拉斯金字塔深度网络,可以生成多种分辨率的高分辨结果。随着拉普拉斯金字塔结构的引入,超分辨网络可以进行有监督学习,并随即提出了许多改进的深度模型<sup>[14-15]</sup>。然而,现有的深度模型超分辨增强算法大都是通过堆叠卷积层使得模型更深更宽<sup>[16]</sup>,忽视了图像内部的层次结构,导致模型不适合低成本的嵌入式平台。而且,大多数深度网络都在单层次上

生成高分辨图像,主要应用于低倍率图像放大,对高倍率超分辨应用的重建效果差。

针对深度网络超分辨增强模型存在的不足,本文提出了一种基于轻量级金字塔密集残差网络,该模型并不直接预测高分辨图像,而是通过密集连接与残差网络直接学习出具有任意放大倍率的高频残差图像,所有特征提取操作均在低分辨空间域中进行。通过使用金字塔结构,该网络可以生成各种尺度因子的高分辨图,利用不同层次的特征逐步生成多层次高频图,降低模型训练难度,并进一步提高重建性能。在训练阶段,通过一次前向传播逐步生成各种层次的超分辨图,这使得网络更加灵活。实验结果表明,与现有对比方法相比,本文模型的重建效果具有显著提升。

## 1 本文提出的超分辨网络模型

现有的深度模型超分辨增强算法大都是通过堆叠卷积层使得模型更深更宽,虽然一定程度上增强了超分辨重构的性能,但都是以大量的计算资源为代价。对于硬件余量有限的武器装备,很难直接将超分辨模型运用于型号产品。

由于现有的深度模型忽视了图像内部的层次结构,仅仅在单一层次上生成高分辨图像,对高倍率超分辨应用的重建效果差。因此,本文提出了一个具有金字塔结构的深度密集残差网络,充分利用密集连接和残差学习实现高频残差预测。同时,采用深度监督模块指导网络训练,实现较大上采样因子的超分辨增强。该模型不需要构建更深更宽的深度网络就能实现任意尺度高精度的超分辨增强。本章将详细描述所提出的单帧图像超分辨率网络结构。

### 1.1 密集残差模块

密集残差模块的结构如图1所示,该结构包含两个分支:高频残差图预测和图像重建,其中高频残差图预测的核心功能是使用多层次卷积从输入的低分辨图中提取深度特征;图像重建则是利用低频图与高频残差图一起重构出高分辨图。假定 $H_{SF}$ 表示卷积运算, $F_{sf}$ 是密集模块的输入,高频残差图可以表示为如下等式:

$$F_{sf} = H_{SF}(d_l) \quad (1)$$

式中: $d_l$ 表示低分辨图。密集模块由 $L$ 个密集连接卷积层<sup>[17]</sup>和瓶颈层<sup>[18]</sup>组成。显然,密集模块中第 $l$ 个Conv层的输出可以表示成如下等式:

$$F_{d,l} = \sigma(W_{d,l} [F_{sf}, F_{d,0}, \dots, F_{d,l-1}]) \quad (2)$$




图1 密集残差模块

Fig.1 Dense residual module

式中:  $\sigma$ 表示激活函数;  $W_{d,l}$ 是第  $l$  个 Conv 层的权值。为了简化描述, 所有等式省略了偏置项。

$[F_{sf}, F_{d,0}, \dots, F_{d,l-1}]$  是指不同层次特征图的级联, 假设每一层的输出具有  $G$  通道, 因此密集连接模块具有  $L \times G$  特征图。瓶颈层自适应融合并控制密集模块中密集连接的 Conv 层的层次结构特征, 如等式(3)所示:

$$F_{db} = \sigma(W_{bn}[F_{sf}, F_{d,0}, \dots, F_{d,l}]) \quad (3)$$

式中:  $W_{bn}$ 是瓶颈层的权值矩阵。在此基础上, 增加两个以上的 Conv 层以提取深度特征, 如等式(4)所示:

$$F_{df} = H_{DF}(F_{db}) \quad (4)$$

式中:  $H_{DF}$ 表示深度特征提取。本文提出的模型采用残差学习<sup>[15]</sup>来组合多尺度特征得到高频残差  $F_{rf}$ 。针对以上分析, 我们能得到  $F_{rf} = F_{df} + F_{sf}$ 。由于卷积层的前向传播过程就是反卷积层的反向传播过程, 因此低分辨图可以由反卷积层进行尺度放大, 即:

$$F_{up} = H_{UP}(F_{rf}) \quad (5)$$

式中:  $H_{UP}$ 表示反卷积操作。因此, 高分辨图和双三次插值图之间的残差图像  $d_r$ 可以由卷基层  $H_{RI}$ 表示, 即:

$$d_r = H_{RI}(F_{up}) \quad (6)$$

由于图像重建则是使用双三次插值法将低频图放大2倍, 然后与高频残差图一起重构出高分辨图, 即  $d_{biscubic} = U(d_l)$ , 其中  $U$ 表示双三次插值, 其结果通过与预测的残差图合并(逐元素求和)以生成高分辨图。

$$d_h = d_r \oplus d_{biscubic} \quad (7)$$

## 1.2 轻量级超分辨增强模块

本文模型除了瓶颈层<sup>[18]</sup>和反卷积层(卷积核大小分别为  $1 \times 1$  和  $4 \times 4$ )之外, 其他卷基层 Conv 的大小都设置为  $3 \times 3$ 。密集模块具有8个 Conv 层, 得到16个特征图, 其他 Conv 层具有16个滤波器。所有滤波器的权重和偏置均通过文献[18]的策略进行初始化。本文选择 PReLU(parametric rectified linear unit)

作为非线性激活函数, 实验结果表明它比 ReLU 更鲁棒。为了保持所有层次输出的结果大小不变, 本文采用零填充进行处理。由于瓶颈层采用  $1 \times 1$  卷积可以降低特征维数, 以更多的信息损失进行更快的计算, 大大降低网络参数量。首先使用卷积模块和像素重整模块搭建深度残差网络, 使用独立的卷积层和数据叠加层得到图像残差信号, 然后中间数据经过像素重整模块, 里面的上采样操作将输入图像的清晰度提高, 该模型可以处理不同尺寸图像的超分辨率增强, 提高红外图像的清晰度和分辨率。

## 1.3 损失函数

通过引入金字塔结构, 本文模型可以生成不同分辨率的图像, 不仅得到中间特征图, 同时经过反卷积和上采样操作, 得到高分辨输出。本质上, 本文提出的网络是采用了深度监督机制, 利用底层和中层的特征图输出经过反卷积(Deconv)层, 得到与标签(label)一样大小的分辨率/空间大小, 经过 softmax+交叉熵/负对数似然, 求得损失。给定超分辨放大因子  $s$ , 在

尺度  $\log_2 s$  下的超分辨图像可以表示为  $d_h^{\log_2 s}$ , 其对应

的基准高分辨图像是  $D_h^{\log_2 s}$ 。为了便于网络的训练, 本文采用双线性下采样来获取在不同尺度下的基准高分辨图。目前, 大多超分辨网络采用  $l_2$  损失函数进行网络训练, 优化效率高但存在过平滑现象, 不能确保获得更好的超分辨性能。本文采用  $l_1$  损失函数对网络进行训练。给定  $N$  个训练样本  $\{D_{l(i)}, D_{h(i)}\}_i^N$ , 其损失函数可以采用如下等式表示:

$$L(\theta) = \sum_{j=1}^{\log_2 s} \frac{1}{N} \sum_{i=1}^N \left| D_{h(i)}^{\log_2 s} - d_{h(i)}^{\log_2 s} \right| \quad (8)$$

## 2 实验仿真及挂飞验证

为了验证本文提出的超分辨增强算法的有效性,

本章将从静态仿真与动态外场挂飞进行评价分析。

### 2.1 实验数据

由于红外图像很少有基准高/低分辨率数据库。为了便于定量性能分析，本文采用制冷型碲化铋红外探测器采集高分辨图像，其对应的低分辨红外图像是由双线性下采样获取。本文将每个训练库的图像按照尺度因子生成不同尺度的块作为训练样本，并排除了没有纹理信息的块，最终得到大约有 190000 个训练样本对。为了进一步扩大训练集，本文通过双三次插值对高分辨子图像进行下采样以获得低分辨样本。由于实际的红外图像没有对应的高分辨的图像用做定量分析，采用低成本非制冷探测器采集的低分辨红外图像 (320×240) 进行超分辨增强，从边缘锐度、对比对、纹理特性等角度定量分析重建性能。

### 2.2 网络模型参数设置及评价指标

网络在初始化后，采用更多的迭代 (大约 100 Epoch) 来训练模型，以获得更准确的特征表示。每个卷积层设置的步幅为 1，反卷积层设置的步幅为 2。学习率设置为 0.001，Dropout 参数设置为 0.8，最高迭代次数设置为 10000 次；为了提高优化效率，本文采用 ADAM 迭代地更新神经网络参数。本文针对  $2^{\times}$ 、 $4^{\times}$ 、 $8^{\times}$  和  $16^{\times}$  比例因子训练了网络，所提出的模型在 TensorFlow 框架下进行训练和测试，其中  $2^{\times}$ 、 $4^{\times}$ 、 $8^{\times}$  和  $16^{\times}$  超分辨的训练时间分别约为 3 h、6 h、13 h 和 16 h。本文硬件平台采用 Core i5 7600 处理器：主频 3.94 GHz，内存 32 G，GPU GTX1080Ti。本算法挂飞硬件平台是采用基于 ARM 的开发板。

为了分析密集连接，残差学习和深度监督的有效性，选用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity index measurement, SSIM) 进行定量描述。

### 2.3 模型分析

本文提出了一种基于金字塔密集残差网络的单帧图像超分辨增强模型，该模型的基本框架是密集残差块，通过密集连接层和残差学习来模拟高频残差和低分辨图像之间的非线性映射。表 1 展示了残余学习 (residual learning, RL)，密集连接 (dense connection, DC) 和深度监督 (deep supervision, DS) 模块对低分辨红外图像放大 4 倍的重建效果，其中黑色方块表明基准网络中替换掉的模块，无黑色方块则表示该模块与基线网络一致。首先，将没有 3 种模块的超分辨网络作为重建基准进行了训练与优化，其超分辨效果仅优于双线性插值。然后，将密集连接，残余学习与深度监督模块分别替换掉基准网络。从表 1 的结果可以看出密集连接模块和残差学习模块的性能都优于

基准网络，但深度监督模块改进网络的性能有限。这些比较表明了密集连接和残差学习的有效性，同时也说明简单地堆叠卷积层以使网络更深更宽并不能增强网络的性能。若同时替换基准网络中两个模块，可以看出采用任意个模块的性能要优于仅采用一个模块的性能。值得注意的是具有密集连接网络的性能总是比具有残差学习网络的性能更好，这是由于在预测高频残差时，残差学习仅利用浅层特征来转换成高层次深度特征，而密集连接则利用分层结构提取多尺度特征。实验结果也表明具有深度监督的网络比没有深度监督的网络表现更好，这是由于深度监督可以指导网络预测不同级别的高频残差。当上采样因子较大时，可以解决边缘模糊问题。当密集连接，残差学习和深度监督同时使用时，它们各自对超分辨网络都有不同的贡献，最终提升网络的整体性能。

表 1 不同模块性能分析

Fig.1 Performance analysis of different modules

RL	DC	DS	PSNR
■			29.8
	■		29.9
		■	29.7
■	■		31.7
■		■	31.0
	■	■	31.8
■	■	■	32.5

### 2.4 仿真结果与分析

本文选用了目前最新的 5 种超分辨方法进行定性定量比较：EDSR (enhanced deep-networks for super-resolution) [19]，SRCNN[6]，SRMD (super-resolution with multiple degradations) [20]，GANSR (super-resolution using a generative adversarial network) [21] 和 Meta-SR (magnification-arbitrary network) [22]。其中 Meta-SR 可以通过输入缩放因子动态地预测网络的权重，实现任意缩放因子问题。SRMD 是采用维度拉伸策略使得卷积神经网络可以处理维度不同的输入，实现多退化模型的图像 SR 增强；GANSR 是利用生成对抗网络实现红外人脸图像超分辨增强。所有的代码均从 Github 下载，并按配置要求设置，部分程序修改过配置参数，但不影响算法性能分析。为了客观公正地进行比较，所有基于深度学习模型的超分辨算法都采用相同的训练数据集进行重新训练。与以前的工作类似，采用 SSIM 与 PSNR 来定量分析重建的高分辨图的质量，其结果在表 2 中显示。可以看出，本文提出的超分辨网络在所有尺度因子下均获得较高的 SSIM 与 PSNR，尤其是

在 Image6 图像的 PSNR 比 SRCNN 高 0.48。同时,本文提出的方法与 MSG-Net 性能相当,大部分结果比 GANSR 高 0.3 dB 左右,一些结果甚至超过 0.51 dB 左右,充分说明本文模型具有一定的优势,适合复杂红外背景下低对比度区域超分辨增强。

定量分析结果表明基于生成对抗网络的超分辨率方法感知损失函数作为优化目标,有效解决了 SRCNN

基于  $l_2$  损失函数导致重建图像模糊的问题,但由于红外图像中存在大量模糊区域,通过对抗学习丢失的细节,会造成重构偏差。虽然一定程度上提升了视觉效果,但重构的图像与实际不符,严重影响武器装备的可靠性。另外,生成器与鉴别器的复杂度也较大,不满足实时需求。本文提出的模型在实际应用中能更有效地抑制噪声并增强细节特征。

表 2 不同算法的重建指标对比

Table 2 Comparison of reconstruction indexes of different algorithms

Images		SRCNN	EDSR	Meta-SR	GANSR	SRMD	Proposed
1	PSNR	32.087	32.237	32.297	32.347	32.507	32.777
	SSIM	0.954	0.955	0.955	0.958	0.961	0.962
2	PSNR	22.907	23.507	23.187	23.547	23.187	23.827
	SSIM	0.774	0.796	0.788	0.802	0.794	0.826
3	PSNR	24.147	25.617	24.467	25.477	24.567	26.287
	SSIM	0.89	0.928	0.912	0.931	0.901	0.948
4	PSNR	32.767	32.697	32.777	32.787	33.047	33.087
	SSIM	0.87	0.867	0.868	0.868	0.879	0.878
5	PSNR	29.297	30.207	29.557	30.167	29.567	30.487
	SSIM	0.898	0.911	0.906	0.913	0.905	0.921
6	PSNR	28.657	28.557	28.557	28.697	28.627	29.037
	SSIM	0.952	0.953	0.957	0.957	0.96	0.964
Average	PSNR	28.307	28.807	28.467	28.837	28.577	29.247
	SSIM	0.901	0.912	0.902	0.914	0.915	0.929

在对空的红外图像中,由于图像大部分区域都是空中背景且背景噪声较大,GANSR 本文提出的算法将图像中存在的随机斑点噪声进行了重建,导致获得的高分辨图像存在很多划痕,放大了背景噪声。而本文算法引入了深度监督模块,在超分辨的同时也完成了图像去噪增强,其性能也有显著提升。

图 2 是 Image 1 与 Image 6 图像下,不同算法的超分辨增强效果。从实验结果可以看出,所有算法的重建质量相比双线性插值有一定的提升,对于具有明显边界的区域够得到清晰的纹理。图 2(a)是 SRCNN 的结果,是最早利用深度模型学习非线性映射函数,并成功应用在超分辨率重建中,由于网络只有 3 层,其结果在均匀区域容易出现伪影,尤其是第一行图像中空区域出现大量虚假纹理信息;图 2(b)是 EDSR 的结果,该网络堆叠更多的残差层或者使每层提取更多的特征,从而得到更好的性能表现。由于本文是处理红外灰度图像,只选择了单通道进行重建,删除了多通道转移层,但实际效果也优于 SRCNN 模型。图 2(c)中,Meta-SR 模型对部分匀质区域过于平滑,而

缺少一些细节上的真实感。图 2(d)中,GANSR 是基于对抗网络的重建模式,其结果容易重建出一些虚假的纹理。图 2(e)中,SRMD 并不假设退化的图像服从某种先验分布,可对任意退化图像进行超分辨增强,实际结果中,该模型也优于其他 4 种对比算法。本文所提模型的结果如图 2(f)所示,该模型也适用于任意复杂退化先验,同时在深度监督模块约束下进行网络训练,有利于实现较大上采样因子的超分辨增强。超分辨结果中,图像细节明显,尤其是建筑边缘等具有规则纹理区域的重建效果较好。

图 3 展示了不同模型对低分辨红外图像的重建效果。可以看出,本文提出的网络对复杂的杂乱纹理的重建效果较好,尤其是建筑旁边栅栏、树枝等区域。草地上的杂乱区域也重建效果较好,细节比较清晰。得益于密集连接,残差学习和深度监督模块的引入,本文所提出的模型可以获得更加理想的高分辨图像,解决了不规则纹理的模糊问题。另外,通过采用金字塔结构,该网络可以生成不同尺度的高分辨图像而不需要额外加宽加深网络结构,降低了硬件资源的需

求。

### 2.5 挂飞视频对比分析

本文提出超分辨模型已经移植到 Hi3559AV100 嵌入式系统中,该平台可以将工作站上训练好的最优模型,以及对应的配置文件迁移到该框架下的对应目录中,实现红外图像超分辨重构。工程研制的硬件机械结构采用了 ATX 机箱,内置母版、信号处理板、主控接口板、电源板,其中信号处理板可以完成目标辅助识别与电子变倍等功能。该机箱接收非制冷红外热像仪采集的红外数字图像,其图像比较模糊,细节不明显,对比度也较低。通过本文设计的超分辨平获

得的高分辨图像比较清晰,一些模糊的区域也呈现出一些细节特征,有利于增强目标锁定的精度。本文挂飞的视频不便于论文展示。为了便于性能分析,本节对中科院技物所团队开源的 SITP-Infra 数据集进行对比分析。由于该数据集与挂飞热像仪的输出 CameraLink 图像都是 14 位原始图像,因此所有对比算法都相同非线性拉伸模型下进行 8 位转换并显示,最后对局部区域的超分辨结果进行对比,其结果如图 3 所示。图 3 所展示的数据已经在可以看出本文提出的方法对局部区域放大后的性能较好,生成具有丰富细节而清晰的高分辨红外图像。




图 2 不同算法的放大结果分析

Fig.2 SR results of different algorithms

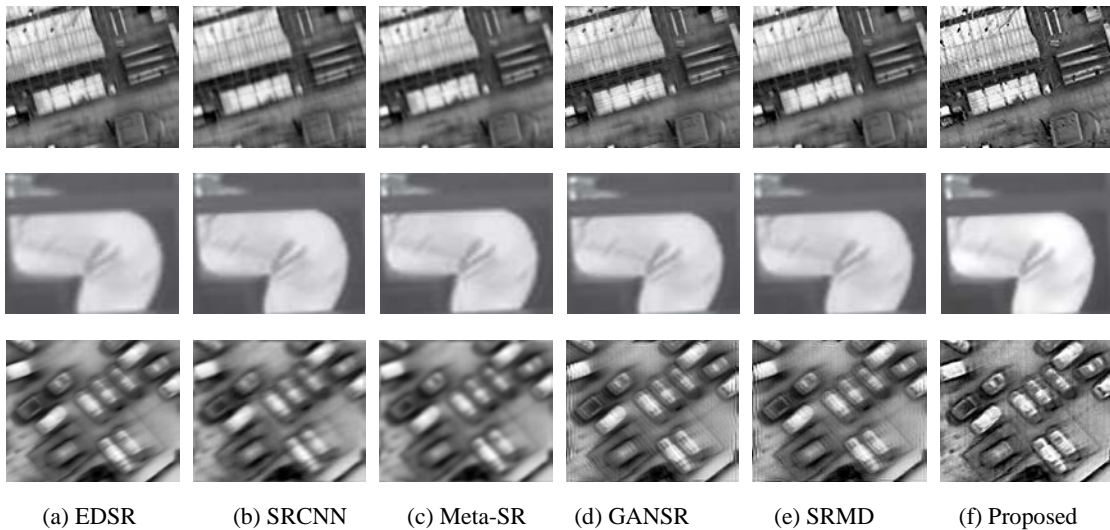


图 3 不同算法对 CASIA 数据集中真实红外定性分析

Fig.3 SR results of local region for different algorithms in CASIA dataset. (a) EDSR; (b) SRCNN; (c) Meta\_SR; (d) GANSR; (E) SRMD; (f) proposed algorithm

### 3 结论

针对深度网络超分辨增强模型存在的不足,本文提出了一种基于金字塔密集残差网络的单帧图像超分辨增强模型,该模型充分利用密集连接和残差学习进行高频残差预测,并在深度监督模块约束下进行网络训练,有利于实现较大上采样因子的超分辨增强。

实验仿真与外场挂飞结果表明本文模型能够生成具有丰富细节而清晰的高分辨红外图像,重建效果具有显著提升。在海思嵌入式深度学习平台上实现了高质量的超分辨增强,具有较高的工程应用价值。

#### 参考文献:

[1] 廖小华, 陈念年, 蒋勇, 等. 改进的卷积神经网络红外图像超分辨率

- 算法[J]. 红外技术, 2020, **42**(1): 075-80.
- LIAO Xiaohua, CHEN Niannian, JIANG Yong, et al. Infrared image super-resolution using improved convolutional neural network[J]. *Infrared Technology*, 2020, **42**(1): 075-80.
- [2] 田广强. 一种新颖高效的红外动态场景多目标检测跟踪[J]. 红外技术, 2018, **40**(3): 259-263.
- TIAN Guangqiang. A novel algorithm for efficient multi-object detection and tracking for infrared dynamic frames[J]. *Infrared Technology*, 2018, **40**(3): 259-263.
- [3] 曾金发, 吴恩斯, 李能勇. 基于双核协同学习模型的红外目标跟踪算法[J]. 红外技术, 2018, **40**(5): 438-443.
- ZENG Jinfa, WU Ensi, LI Nengyong. Infrared object-tracking algorithm based on dual-kernelized collaborative learning[J]. *Infrared Technology*, 2018, **40**(5): 438-443.
- [4] 韩团军, 尹继武. 一种鲁棒的自适应更新策略的弹载计算机红外目标跟踪算法[J]. 红外技术, 2018, **40**(7): 625-631.
- HAN Tuanjun, YIN Jiwu. Robust adaptive updating strategy for missile-borne infrared object-tracking algorithm[J]. *Infrared Technology*, 2018, **40**(7): 625-631.
- [5] 艾志伟, 嵇建波, 李静, 等. 快速反射镜状态模型构建方法及其控制系统设计[J]. 红外技术, 2020, **42**(1): 40-45.
- AI Zhiwei, JI Jianbo, LI Jing, et al. State model construction method for fast steering mirror and its control system design[J]. *Infrared Technology*, 2020, **42**(1): 040-45.
- [6] DONG C, Loy C C, He K, et al. Learning a deep convolutional network for image super-resolution[C]//*European Conference on Computer Vision*, 2014: 184-199.
- [7] Riegler G, Rother M, Bischof H. ATGV-Net: accurate depth super resolution[C]//*Proc. Eur. Conf. Comput. Vis.*, 2016: 268-284.
- [8] SHI Y, LI S, LI W, et al. Fast and Lightweight Image Super-resolution based on dense residuals two-channel network[C]//2019 *IEEE International Conference on Image Processing (ICIP)*, 2019: 2826-2830.
- [9] WANG Wei, JIANG Yongbin, LUO Yanhong, et al. An advanced deep residual dense network(DRDN) approach for image super-resolution[J]. *International Journal of Computational Intelligence Systems*, 2019, **12**(2): 1592-1601.
- [10] WU Y, JI X, JI W, et al. CASR: a context-aware residual network for single-image super-resolution[J]. *Neural Computing and Applications*, 2019: 1-16.
- [11] 杨明, 王璇, 高宏伟. 基于多级深度网络的高清晰度红外电子变倍算法[J]. 弹箭与制导学报, 2020, **40**(4): 14-19.
- YANG Ming, WANG Xuan, GAO Hongwei. High-definition infrared electronic zooming algorithm based on multi-level deep network[J]. *Journal of Projectiles, Rockets, Missiles and Guidance*, 2020, **40**(4): 14-19.
- [12] HUI T, Loy C C, TANG X. Depth map super-resolution by deep multi-scale guidance[C]//*Proc. Eur. Conf. Comput. Vis.*, 2016: 353-369.
- [13] QIU Y, WANG R, TAO D, et al. Embedded block residual network: a recursive restoration model for single-image super-resolution[C]//*Proceedings of the IEEE International Conference on Computer Vision*, 2019: 4180-4189.
- [14] CAO Y, HE Z, YE Z, et al. Fast and accurate single image super-resolution via an energy-aware improved deep residual network[J]. *Signal Processing*, 2019, **162**: 115-125.
- [15] Anwar S, Barnes N. Densely residual Laplacian super-resolution[J/OL]. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [2020-09-20](DOI: 10.1109/TPAMI.2020.3021088).
- [16] WANG Z, Chen J, Hoi S C H. Deep learning for image super-resolution: a survey[J/OL]. *IEEE Trans Pattern Anal Mach Intell.* [2020-09-20]. <https://ieeexplore.ieee.org/document/9185010>(doi: 10.1109/ TPAMI. 2020. 2982166).
- [17] LONG J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]// *Proc. Conf. Comput. Vis. Pattern Recognit.*, 2015: 3431-3440.
- [18] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on image net classification[C]//*Proc. Int. Conf. Comput. Vis.*, 2015: 1026-1034.
- [19] Lim B, Son S, Kim H, et al. Enhanced deep residual networks for single image super-resolution[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2017: 136-144.
- [20] HUI T W, Loy C C, TANG X. Depth map super-resolution by deep multi-scale guidance[C]//*European Conference on Computer Vision, Springer*, 2016: 353-369.
- [21] Guei A C, Akhloufi M. Deep learning enhancement of infrared face images using generative adversarial networks[J]. *Applied Optics*, 2018, **57**(18): 98-107.
- [22] ZHANG X, LI C, MENG Q, et al. Infrared image super resolution by combining compressive sensing and deep learning[J]. *Sensors*, 2018, **18**(8): 2587-2599.