

DOI: 10.13382/j.jemi.B2003451

# 基于多尺度耦合的密集残差网络红外图像增强\*

李萍<sup>1</sup> 刘以安<sup>2</sup> 徐安林<sup>1</sup>

(1. 无锡职业技术学院 物联网学院 无锡 214121; 2. 江南大学 物联网工程学院 无锡 214122)

**摘要:** 为了提升非制冷红外热像仪的图像质量,满足低对比度弱小区域的观瞄与锁定的需求,提出了一种基于多尺度密集残差网络的红外图像超分辨率重建模型,该模型的基本框架是通过级联多个残差特征进行学习,以粗到细的方式重建高分辨率图像。首先提出一种多尺度跨域融合模块,通过对不同感受野的分支结果进行融合,不仅可以融合不同感受野的互补信息,还可有助于提升梯度收敛和特征传输;然后叠加多个跨域融合模块,并采用残差特征学习进行优化,最终学习出高分辨率细节信息。仿真实验结果表明,所提出的超分辨率模型能够较好的超分辨率重建效果,在微弱结构保持和点目标保持上的性能也更加突出。所提的模型已经在海思嵌入式深度学习平台上实现了高质量的红外增强,具有较高的工程应用价值。

**关键词:** 红外图像;图像增强;深度学习;特征级联;密集残差网络;多尺度耦合

**中图分类号:** TN219 **文献标识码:** A **国家标准学科分类代码:** 510.8040

## Infrared image enhancement using dense residual network with multi-scale coupling

Li Ping<sup>1</sup> Liu Yian<sup>2</sup> Xu Anlin<sup>1</sup>

(1. School of Internet of Things, Wuxi Institute of Technology, Wuxi 214121, China;

2. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

**Abstract:** In order to improve the image quality of uncooled infrared thermal imager, and meet the needs of viewing and locking in low contrast and dim-area, a super-resolution reconstruction model of infrared image based on multi-scale dense residual network is proposed in this paper. The basic framework of the model is to reconstruct high-resolution image by cascading multiple residual features. Firstly, a multi-scale cross-channel fusion module is proposed. By fusing the branch results of different receptive fields, it not only fuses the complementary information of different receptive fields, but also helps to improve the gradient convergence and feature transmission. Then, multiple cross-fusion modules are cascaded and optimized by residual feature learning to learn high-resolution detail information. The simulation results show that the super-resolution model proposed in this paper can achieve better super-resolution reconstruction effect, and has better performance in weak structure maintenance and point target maintenance. Our proposed model has achieved high-quality super-resolution reconstruction on the embedded deep learning platform of Hisilicon, and has high engineering application value.

**Keywords:** infrared image; image enhancement; deep learning; feature cascade; dense residual network; multi-scale coupling

## 0 引言

红外热像仪是一种利用信号处理、光电转换等技术手段,将目标区域的红外辐射转换成可视图像的设备,在态势感知、故障诊断、对地观瞄等军/民领域具有广泛的应用前景<sup>[1]</sup>。然而,红外热像仪易受到大气气溶胶、大气

湍流等影响而发生吸收与衰减造成成像质量下降<sup>[2]</sup>,尤其是国产非制冷红外热像仪的非均匀性差导致成像对比度低、图像模糊,严重影响目标的观瞄与锁定<sup>[3]</sup>。

为了提升非制冷红外热像仪的成像质量,目前主流的思路是采用先进工艺与技术提升焦平面的探测性能<sup>[4]</sup>,以及采用处理算法提升信号重建性能。前者受限于工艺的不足以及技术的封锁,短期内很难有质的突破。

收稿日期: 2020-08-31 Received Date: 2020-08-31

\* 基金项目: 国家自然科学基金青年项目(21706096)资助

因此,利用信号处理思想,从含噪微弱信号中重构出高质量红外图像是目前可行的方法,如图像超分辨重建<sup>[5]</sup>。图像超分辨重建旨在从其低分辨率图像中学习出中对应的高分辨率图像,在视频监控、医学成像和智能交通领域具有广泛的应用。西南技术物理研究所已经在红外图像增强应用中做了大量的工程化研制工作,提出了邻域嵌入增强网络,在一定程度上改进了低成本红外导引头的成像质量<sup>[6]</sup>。然而,图像重建的过程本质上是一个不适定的逆问题,目前的成果与高质量仍然存在一定的差距。因此有必要研究重建过程的先验信息,以确保重建图像具有保真性与稳定性<sup>[6]</sup>。

传统的算法主要致力于通过概率图形模型、邻域嵌入、稀疏编码或非线性回归提高高分辨图像的质量<sup>[6]</sup>。随着硬件性能的提升以及海量数据集的建立,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。目前,神经网络对低分辨率图像到高分辨图像的空间映射建模的有效性和效率方面取得了优异性能<sup>[7-13]</sup>。Dong等<sup>[7]</sup>首次验证了卷积神经网络可以实现端到端地超分辨重建,并设计出一种具有3层卷积网络结构的重建模型,最终学习出内插图像与高分辨图像之间的映射关系。由于越深的网络结构具有越大的感受野来捕获更多的上下文信息,Kim等<sup>[8-9]</sup>构建两个深度神经网络模型,VDSR和DRCN,它们分别利用全局残差学习和递归监督来提高超分辨结果的准确性,但更深的结构为梯度收敛和特征传输带来了困难。为了控制模型参数数量和融合多特征,Hu等<sup>[11]</sup>在全局和局部残差学习基础上构建了具有紧密连接结构特征递归模块,在增加模型深度的同时有效的降低的训练参数。Hu等<sup>[12]</sup>在VDSR网络架构的基础上,提出了深度邻域嵌入的超分辨模型,进一步提高了重建性能。文献[13]将低层次特征和高层次特征聚合连接形成新的特征,以提高非线性映射关系的表征能力。邵保泰等<sup>[14]</sup>通过引入深度对抗的思想,提升了生成模型的学习能力,获得了更好的微弱细节的重建能力。

相对于自然图像来说,红外图像具有特有的成像特征与属性,其重建目的不仅仅是提升目标的显示效果,更是为了提升弱小目标的保持能力以及区域的保真度。因此,直接将现有的算法用于红外图像增强的效果并不理想。随着超分辨技术逐渐应用到红外图像重建领域,一些改进的重建模型相继提出。Wang等<sup>[15]</sup>提出了一个具有3个平行子网的联合残差网络来学习图像中的低频信息和高频信息,证实了多个子网络的融合也可以提高超分辨的整体性能。文献[16]将跨连接层和并行重构网络集成到一个深层网络架构中,以更少的计算资源获得更好的重建性能。

基于深度网络的图像超分辨重建中各网络层之间的

输入、输出和信息具有高度的相关性。如何将不同层次、不同尺度的特征结合起来是提升超分辨重建性能的关键。虽然现有针对红外图像的超分辨算法大都利用更深层次的网络特征来获取更多的上下文信息,但由于在其设计的网络中采用了主干网结构,忽视了图像内部的层次结构,因此不同感受野下的多尺度互补信息的融合仍然较困难。华中科技大学对于现有的深度网络结构进行了分析,证明了超分辨应用中增加宽度比增加深度更有效<sup>[12]</sup>。因此,采用多分支结构和子网级联可能更有助于提升超分辨中多层次信息融合。另一方面,将残差特征学习和级联递归结构应用到网络模型中,可以简化超分辨网络的收敛效率与重建性能。基于以上分析,本文提出了一种用于超分辨重建的多尺度深度信息跨域融合网络,由一个特征提取模块、多个级联子网络和重构模块组成,其中多组级联子网络可以逐步重构出高分辨特征,每组子网络具有两个分支的多尺度耦合模块,用于融合不同感受野的多尺度信息,然后堆叠多个多尺度耦合模块来学习输入和输出特征之间的残差信息。在训练过程中,本文采用级联监督策略约束各子网的预测结果,最终提升整个超分辨模型的输出性能。

## 1 基于多尺度耦合的密集残差网络超分辨重建

虽然现有的深度模型在一定程度上通过堆叠深度模块提升超分辨重建的性能,但都是以大量的计算资源为代价,且忽视了图像内部的层次结构。对于硬件余量有限的装备,很难直接将重建模型应用于老装备的改造升级。

针对深度网络超分辨重建模型存在的不足,本文提出了一个多层次密集连接的跨通道耦合网络,结构如图1所示通过级联多个残差特征进行学习,以粗到细的方式重建高分辨率图像。首先提出一种多尺度跨域融合模块,通过对不同感受野的分支结果进行融合,不仅可以融合不同感受野的互补信息,还可有助于提升梯度收敛和特征传输;然后叠加多个跨域融合模块,并采用残差特征学习进行优化,最终捕获更多的特征表示以学习出高分辨率细节信息。

### 1.1 多尺度跨域融合模块

由于ResNet中的恒等映射可以跨连接多个残差分支,这使得网络的深度可以很深,且很容易训练<sup>[17]</sup>。为了进一步降低训练难度和改善特征传递中梯度消失问题,一些学者提出通过叠加多个Merge-and-Run模块构建深度神经网络,该模块通过对残差分支的输入进行平均,并将平均结果添加到每个残差分支的输出中,以此作为

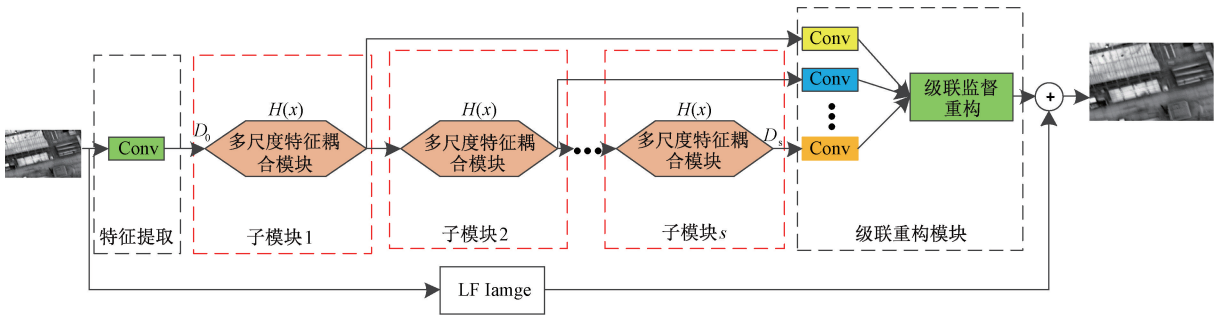


图 1 多尺度耦合的密集残差网络

Fig. 1 Dense residual network with multi-scale cross-channel fusion

后续残差分支的输入<sup>[18]</sup>。可以看出,并行分支之间的参数共享有利于更好地训练网络,从而增强深度网络的泛化能力。由于不同感受野的卷积层可以捕获不同的上下文信息,有助于提升超分辨的性能。因此,本文设计了一种多尺度跨通道融合模块,可实现对不同感受野的分支结果进行融合。

多尺度跨域融合模块采用 Merge-and-Run 映射并行地构建两个不同卷积核的残差网络分支,其中每一个分支包含两个卷积层,其每个卷积层都会跟一个 BN 层和一个 LeakyReLU 层,且每个卷积层的卷积核大小不同,如图 2 所示。可以看出,该模块的两个分支可以在多尺度空间上提供互补的信息,并通过 Merge-and-Run 映射来进一步融合这些信息。图 1 的子模块是图 2 结构的级联组成。众所周知,跨连接操作可以使基础模块多次融合而提升特征的表征能力,也就是说多种中等规模的网络组合具有更高的泛化能力。假定  $H^{b1}(\cdot)$  与  $H^{b2}(\cdot)$  分别表示为两个残差分支的转移函数,所提模块如下:

$$x_o^{b1} = H^{b1}(x_i^{b1}) + \frac{x_i^{b1} + x_i^{b2}}{2} \quad (1)$$

$$x_o^{b2} = H^{b2}(x_i^{b2}) + \frac{x_i^{b1} + x_i^{b2}}{2} \quad (2)$$

式(1)与(2)可以合并成矩阵形式表示:

$$\begin{bmatrix} x_o^{b1} \\ x_o^{b2} \end{bmatrix} = \begin{bmatrix} H^{b1}(x_i^{b1}) \\ H^{b2}(x_i^{b2}) \end{bmatrix} + 0.5 \begin{bmatrix} I & I \\ I & I \end{bmatrix} \begin{bmatrix} x_i^{b1} \\ x_i^{b2} \end{bmatrix} \quad (3)$$

式中:  $x_i^{b1}$  ( $x_o^{b1}$ ) 与  $x_i^{b2}$  ( $x_o^{b2}$ ) 分别表示该模块两个分支的输入(输出);  $I$  表示模块中的恒等映射。可以看出,多分支并行结构大大提升了内部层次结构的表征能力,等效的恒等映射结构进一步降低训练难度和改善特征传递中梯度消失问题。

### 1.2 级联监督重构

为了降低深度超分辨模型对细节重建的难度,本文采用多级联深度子网从提取的浅层特征中重建高分辨特征,所有的级联子网都采用相同的结构和参数设置,并且在有监督约束下进行联合训练。每一级子网都可以提升




图 2 多尺度耦合结构

Fig. 2 Structure of multi-scale cross-channel fusion

重建的性能,并在逐渐级联优化中降低重建的误差。可以看出,级联的操作类似工程优化中的迭代,逐渐逼近最优解。所有子网的高分辨重建特征输入相应的重建层以获得最终的高分辨重建图像。假定  $x$  与  $y$  分辨表示本文所提网络的输入低分辨图像与输出高分辨图像。本文采用带有 BN 和 LeakyReLU 层的卷积模块从低分辨输入图像  $x$  中提取浅层特征,其特征提取网络的公式如下:

$$D_0 = H(x) \quad (4)$$

式中:  $H(\cdot)$  表示特征提取网络的函数;  $D_0$  是提取到的特征,并将其输入到子网的第一级。假定有  $N$  个子网被级联到一起逐步提升重建性能,其重建过程可以表示成式(5)。

$$D_s = H^s(H^{s-1}(\dots(H^1(D_0))\dots)) \quad (5)$$

式中:  $H^l(\cdot)$  表示第  $l$  个子模块的传递函数。为了使每个级联子模块的输出更接近于基准高分辨图像,本文采用级联监督策略对级联模块的所有结果进行监督。每个子模块的输出都输入到重构网络中,该网络的卷积层将所有子模型的输出作为其输入,以重构相应的残差图像。与文献[18]类似,本模块也通过在网络中添加恒等映射分支增加全局残差学习的能力。因此,第  $q$  ( $q = 1, 2, \dots, S$ ) 个中间预测结果可以表示为:

$$y_q = R_q(D_q) + x \quad (6)$$

式中:  $D_q$  是第  $q$  个子模块的输出特征;  $R_q(\cdot)$  则是相应重构层的变换函数。最终,所有的中间层结果可以进行加

权平均获得高分辨结果,即:

$$y = \sum_{q=1}^S w_q \cdot y_q \quad (7)$$

式中:  $w_q$  表示第  $q$  个子模块的权值系数。所有的权值都是经过训练获得,最终实现监督学习获得高分辨结果。

### 1.3 基于级联监督约束的损失函数

损失函数是用来估量深度重构模型的预测值  $f(x)$  与基准  $y$  的不一致程度,其损失函数越小,重构模型的鲁棒性就越好。通过引入多尺度跨域融合结构,本文模型可以对不同感受野的分支结果进行融合,得到最优的重构结果,而不损失点目标与面目标的性能。本质上,本文提出的网络是采用了多尺度迭代优化的思想,利用中间级特征与参数组合优化,以粗到细的方式重建高分辨率图像。给定超分辨训练数据集  $\{x^{(k)}, y^{(k)}\}_{k=1}^K$ , 其中  $K$  表示训练样本的数量,  $\{x^{(k)}, y^{(k)}\}$  表示第  $k$  个高低分辨率/低分辨率样本对。本文采用的级联监督模型的损失函数如下:

$$L = \alpha \frac{1}{2K} \|y^{(k)} - \sum_{q=1}^S w_q y_q^{(k)}\|_2^2 + (1 - \alpha) \sum_{q=1}^S \sum_{k=1}^K \|y^{(k)} - y_q^{(k)}\|_2^2 \quad (8)$$

式中:  $\alpha$  是平衡不同子模块的偏移因子,其经验值设为  $2/(S + 2)$ 。

## 2 实验结果及其应用分析

为了验证本文提出的多尺度耦合超分辨重建算法的有效性与其可行性,从定性定量仿真分析与工程应用角度进行对比分析。

### 2.1 实验数据集

海量数据集是深度网络模型性能提升的关键。为了解决红外图像超分辨任务中数据量不足的问题,本文采用目前自然图像超分辨领域广泛采用的数据集进行预训练,如 BSD100<sup>[12]</sup> 和 Urban100<sup>[19]</sup>, 并将获得的超参数作为本文自建数据集训练的初值,其中自然图像的数据集都转换成 8 bit 的灰度图。本文实验使用的自建数据集采用南京航空航天大学物联网与控制技术重点实验室研制的蜂群平台采集的高清红外数据,其中红外热像仪采用高德红外的制冷型碲化铋红外探测器,分辨率为 1 080×1 024。同时,本文还使用了数据增强功能扩充样本数量,包括图像翻转、比例缩放与旋转,其中缩放的比例为 0.5、0.6、0.7、0.8 与 0.9; 旋转则是按照 10° 步长进行。本文所有的训练数据集中低分辨率红外图像全部来自高分辨图像双线性模糊下采样获取。本文构建的训练样本来自图像非重叠分块,其块大小为 41×41; 最终通过分块得到大约有 190 000 个训练样本对。

本文采用的低分辨率测试数据集一部分来自高分辨图像进行双线性模糊下采样,剩下都是低成本非制冷探测器采集的低分辨红外图像。由于外场采集的红外图像没有对应的高分辨图像,无法直接用于定量分析,本文主要是从对比度、清晰度、点/线目标保持度等角度定性描述。

### 2.2 参数设置及实验评价指标

为了提高优化效率,本文采用随机梯度下降优化模型,其参数设置如下: mini-batch 的大小为 32, 动量参数为 0.9, 权重衰减为  $10^{-4}$ 。学习速率被初始化为 0.1, 然后每 10 轮 (Epoch) 减少 10 倍。为了解决训练过程中梯度消失的问题,采用梯度裁剪操作提升模型收敛过程,单个梯度裁剪到  $[-0.4, 0.4]$ 。实验结果表明本文所提模型在约 50 轮训练后就能稳定收敛。本文所提模型中每个卷积层都有 64 个滤波器,并增加一个 BN 层和 LeakyReLU 激活层,其中激活函数为所有负值赋予一个非零斜率。除多尺度耦合模块中的卷积层外,所有卷积层的卷积核大小设置为 3×3。本文模型在 NVIDIA Titan X Pascal GPU 上采用 PyTorch 深度网络架构搭建本文的算法模型进行模型训练和测试。

本文所提的模型已经完全移植到硬件平台,其硬件架构是 Hi3559AV100, 该嵌入式系统可以将训练好的模型,以及对应的配置文件迁移到对应目录进行运行,只需少量的优化就实现基于深度模型的实时图像增强应用。

为了衡量本文所提出的多尺度耦合的超分辨重建算法的性能,本实验对重建图像进行定性与定量性能评价,其中定量客观评价方法采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似性 (structural similarity index measurement, SSIM) 进行分析<sup>[22]</sup>。

### 2.3 消融分析

本文提出了一种基于多尺度深度信息耦合网络的单帧图像超分辨重建模型,由一个特征提取模块、多个级联子网络和一个重构模块组成。为了分析与验证多尺度特征耦合,残差学习和级联重建对模型重建性能的贡献,本小节对各模块进行了消融分析。表 1 为残余学习 (residual learning, RL), 多尺度特征耦合模块 (multi-scale feature fusion, MFF) 和级联监督 (cascade supervision, CS) 模块对低分辨红外图像放大 2 倍的超分辨效果,其中  $\square$  表明基准网络中采用的模块。为了分析多尺度特征耦合对整个模型的贡献,表 1 中第 1 行与第 3 行对多尺度特征耦合模块和一个普通级联结构进行比较,其结果如 PSNR 与 SSIM 所示。可以看出,对于堆叠 6 个卷积层的普通级联结构,虽然可以提升重建信息,但对于图像的细节重建仍然不及多尺度特征耦合模块的结果。

本文所提的级联结构模型选用了 3 个子网,且每个

子网包含 6 个多尺度耦合模块。为了便于公平地进行消融比较,每一个模块都采用交替分析,其中每一个模块都有对应的基础模块进行对比。从结果可以看出,具有相同数量参数的级联重建与普通重建相比,其性能得到提升。同时,级联结构可以使得网络中间级特征自由融合,并且在有监督约束下进行联合训练,进一步提高超分辨率重建的性能。从消融分析结果也可以看出,相对于多尺度特征耦合模块,级联结构是超分辨率性能提升的关键。

表 1 不同模块性能分析

Table 1 Performance analysis of different modules

RL	MFF	CS	PSNR	SSIM
			29.612	0.782
☑			29.844	0.763
	☑		29.975	0.794
		☑	30.165	0.826
☑	☑		31.711	0.840
☑		☑	31.089	0.819
	☑	☑	31.823	0.852
☑	☑	☑	32.557	0.861

为了分析残差学习对整个模型性能的贡献,实验通过固定多尺度特征耦合与级联重建进行比较。实验结果表明,残差学习和级联监督重构都可以提高重建性能,但增加的性能有限,只有三者相互配合才能获得具有更好的性能。

### 2.4 仿真结果与分析

本文选用了目前最新的 5 种超分辨率方法进行定性定

表 2 不同算法的重建指标对比

Table 2 Comparison of reconstruction indexes of different algorithms

Image	Zoom	EDSR		MemNet		DRCN		GANSR		SRCNN		Proposed	
		SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR
Image1	×2	0.94	37.06	0.96	38.11	0.96	38.33	0.95	38.48	0.95	36.61	0.96	38.51
	×3	0.92	33.16	0.93	34.42	0.94	34.97	0.90	34.97	0.92	33.03	0.94	34.93
	×4	0.86	30.26	0.88	30.81	0.92	31.74	0.84	31.57	0.85	29.05	0.91	31.59
Image2	×2	0.96	35.15	0.98	36.66	0.98	36.59	0.89	36.70	0.98	35.85	0.98	36.71
	×3	0.94	30.99	0.96	32.42	0.96	32.43	0.87	32.57	0.96	31.55	0.96	32.62
	×4	0.88	27.25	0.92	28.45	0.92	28.87	0.78	28.78	0.92	28.14	.93	28.87
Image3	×2	.91	37.94	.94	38.62	0.94	38.71	0.95	38.69	0.92	37.61	0.95	38.61
	×3	0.90	34.36	0.91	35.51	0.91	35.94	0.89	35.83	0.90	35.12	0.91	35.58
	×4	0.83	31.61	0.86	32.38	0.87	33.07	0.81	32.90	0.86	32.37	0.87	32.77
Image4	×2	0.89	37.01	0.95	37.50	0.95	37.80	0.95	37.89	0.93	36.24	0.95	37.86
	×3	0.87	33.11	0.90	33.55	0.90	33.94	0.90	34.06	0.88	33.09	0.90	33.97
	×4	0.78	29.72	0.81	30.05	0.83	30.54	0.81	30.64	0.81	30.12	0.83	30.60

图 3 所示为不同超分辨率对比方法的定性视觉比较。可以看到,本文提出的重建算法能够获得更加明显的纹理、轮廓边缘和点目标,而对比方法重构的结果中包含严重的失真和伪影。第 1 行的高分辨率图像中,大楼的墙体呈现出自相似的周期性网格,且轮廓明显,其对应的低分辨率红外图像虽然仍然可以看清楚网格轮廓,但边界已经模糊。SRCNN 与 DRCN 的结果仍然较模糊,尤其是密集

量比较,EDSR<sup>[20]</sup>、SRCNN<sup>[6]</sup>、MemNet<sup>[11]</sup>、GANSR<sup>[21]</sup>和 DRCN<sup>[9]</sup>。EDSR 在残差网络的基础上构建了多尺度缩放融合模型,在保持模型紧凑的情况下提升图像重建性能;GANSR 是利用生成对抗网络实现红外图像超分辨重建;DRCN 网络模型在超分辨应用中也采用了多分支预测和多监督策略,通过采用卷积层作为级联模块,并利用链式结构将相同的卷积层递归堆叠。MemNet 也采用类似 DRCN 模型的结构,但 MemNet 采用了包含递归卷积层和门单元的记忆块构造级联模块。值得注意的是,DRCN 与 MemNet 这两种模型的大多数特征提取层都无法从先前的层或块中接收信息。本文选用的对比模型的代码均可以从 Github 下载,并按配置要求进行设置,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,所有对比模型都采用相同的训练集进行重新训练。

表 2 为 3 种放大尺度下的不同测试图像的定量结果。由于 GANSR 模型没有提供针对 3 倍放大因子的训练模型,本文则对该模型进行 4 倍放大,然后在下采样获得相应的结果。从表 2 可以看出,在多种超分辨率尺度下本文模型的 PSNR 与 SSIM 均明显优于现有方法。即便是对极富挑战性的自建低质量非制冷红外图像的超分辨重建,本文模型在 2×、3×和 4×时的 PSNR 指标分别提升了 0.16、0.13 和 1.20 dB,明显优于对比深度模型,如 MemNet、GANSR 等。

的纹理也存在严重失真。相比之下,本文模型通过多尺度特征耦合,残差学习和级联重建进行超分辨重建,可以有效地提升低分辨率红外图像的清晰度,同时抑制失真和伪影。第 2 行是挂飞时采集一张建筑区域的红外影像。从对比结果可以看出,只有本文提出模型能够重建出更精细的边缘和更清晰的轮廓;GANSR 模型采用由粗到精的方法预测各通道的残差,但重构过程中却采用反卷积

进行上采样,导致结果在部分细节上产生非常模糊的结果。因此,以上定性分析结果表明了本文提出的模型对

红外图像超分辨重建具有较高性能,特别是对边缘轮廓区域具有明显优势。




图3 不同算法的放大结果分析

Fig. 3 SR results of different algorithms

本文提出的模型有两个主要的性能参数,子网数量(Num\_N)和多尺度耦合模块(Num\_M)的数量,其值的选取决定了模型的复杂度以及重建的性能。为了实现轻量级参数的前提下获得较优的重建性能。本文对测试数据集2倍放大的重构性能进行消融分析。随着子网数量Num\_N增大,其性能也相应的提升。当Num\_N=3时,其PSNR的增长率达到最大;虽然Num\_N=6时,其PSNR仍然有提升,此时模型的复杂度也相应的增加较多。同理,固定子网数量时,模型的性能随多尺度耦合模块的数量而提升。由于较大的模块数量导致网络更深,虽然可实现更好的重建性能,但其运行时间更长。因此,为了平衡模型的性能和速度,本文模型的主要参数设置为Num\_N=3与Num\_M=6。

## 2.5 工程研制及其性能对比分析

本文主要是依托预研项目,以华为海思Hi3559AV100为核心平台,开发出具有超分辨重建功能的样机,实现低成本红外热像仪高清超分辨重建,降低对进口探测器依赖。单帧影像的处理时间是衡量模型的实时性的关键。为了便于实时性比较,本实验将对比较算法的运行时间进行了分析。由于大多数模型是在Windows平台上运行,所有对比算法都在相同的硬件平台上运行。不同模型的平均运行时间对比可知,本文提出模型的运行时间明显优于所有所选对比方法。基于HI3559V200的红外超分辨重建系统具有国产化程度高、功耗低、智能化强与实用性高,将极大拓展人工智能算法在装备中应用。基于HI3559V200的嵌入式仿真平台如图4(a)所示,该平台支持深度学习框架caffe或PyTorch,具有

NNIE神经网络加速单元,算力达到4.0Tops。图4(b)是本文依托的预研项目设计的3U ATX机箱,内置底板、图像增强板、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跟踪等功能;图像增强板则是对图像进行信号增强,提升图像的画质,便于操作手实现对地观瞄与打击。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,不仅获得了更锐利的边缘,而且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。由于非制冷红外热像仪采集的红外图像存在大量噪声,且细节模糊,尤其是对于田野小目标图像,目标特征不明显,本文提出的算法考虑了保真项的约束,增强了原始图像的弱小目标的细节。

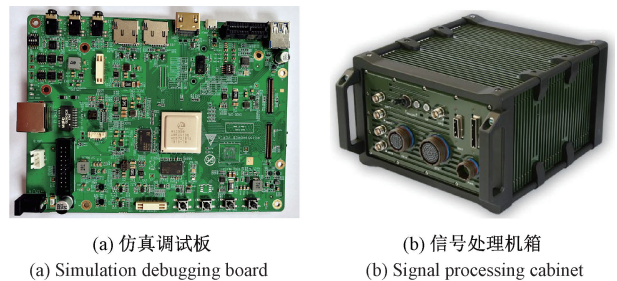


图4 硬件平台

Fig. 4 Hardware platform

为了便于性能分析,对真实红外图像局部区域的超分辨结果进行对比,其结果如图5所示。图5为了不同模型重建结果的局部放大区域,其中RAW图像是由高

德红外提供的高分辨率的 GAVIN1212 制冷红外热像仪采集。为了便于分析,试验仅仅选用了 DRCN、GANSR 与 MemNet 的 3 个局部区域进行分析。可以看出,本文

所提模型的超分辨结果更接近高分辨图像,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。

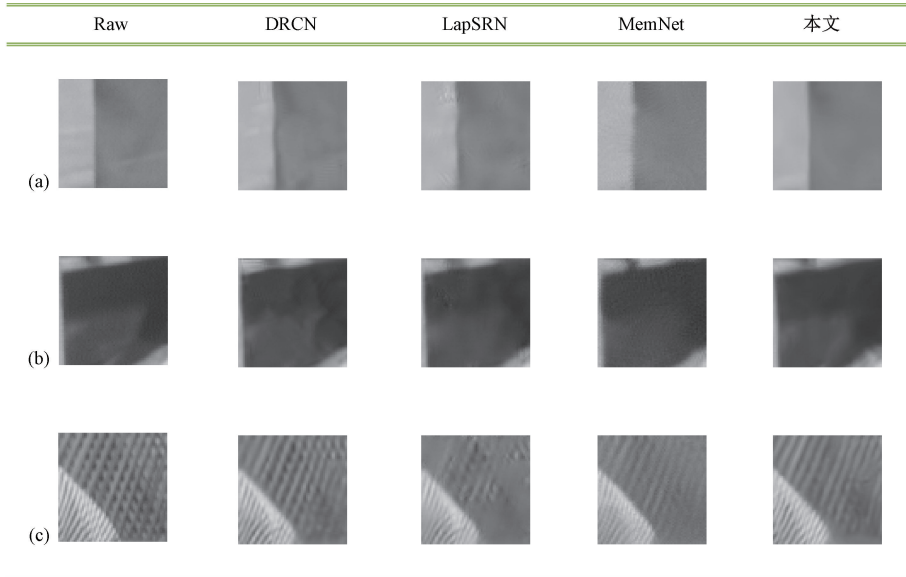


图 5 不同模型重建结果的局部放大区域

Fig. 5 The local detail and structure comparison for different models

### 3 结 论

虽然现有的深度模型在一定程度上通过堆叠深度模块提升超分辨重建的性能,但都是以大量的计算资源为代价,且忽视了图像内部的层次结构。针对深度网络超分辨重建模型存在的不足,本文提出了一个多层次密集连接的跨通道耦合网络,通过级联多个残差特征进行学习,以粗到细的方式重建高分辨率图像,通过对不同感受野的分支结果进行融合,不仅可以融合不同感受野的互补信息,还可有助于提升梯度收敛和特征传输。仿真实验结果表明本文所提出的超分辨模型能够较好的超分辨重建效果。

#### 参考文献

[ 1 ] 姜维,王学春,杨勇. 基于结构特征先验与多尺度反锐化掩模机制的红外图像增强算法[J]. 电子测量与仪器学报,2019,33(4):1-9.  
JIANG W, WANG X CH, YANG Y. Infrared image enhancement algorithm based on structural feature prior and multiscale unsharp masking mechanism [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (4): 1-9.

[ 2 ] 邢志勇,肖儿良,简献忠. 双判别生成对抗网络的红外图像超分辨重建[J]. 小型微型计算机系统, 2020, 41(3): 662-667.

XING ZH Y, XIAO E L, JIAN X ZH. Double discrimination generative adversarial networks of infrared image super-resolution reconstruction [J]. Journal of Chinese Computer Systems, 2020, 41(3): 662-667.

[ 3 ] 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 X, CHEN N, JIANG Y, et al. Infrared image super-resolution using improved convolutional neural network[J]. Infrared Technology, 2020, 42(1): 75-80.

[ 4 ] 贺瑜飞,高宏伟. 基于多层连接卷积神经网络的单帧图像超分辨重建[J]. 计算机应用与软件, 2019, 36(5): 220-224, 326.  
HE Y F, GAO H W. Single frame image super-resolution reconstruction based on multilayer connected convolutional neural network [J]. Computer Applications and Software, 2019, 36 (5): 220-224, 326.

[ 5 ] TANG Z, WANG S, HUO J, et al. Bayesian framework with non-local and low-rank constraint for image reconstruction [C]. Journal of Physics Conference Series, 2017, 1972-1978.

[ 6 ] 王华兵,万烂军. 基于Contourlet 及目标特性分析的弱小红外目标检测[J]. 电子测量与仪器学报, 2019, 33(3): 120-125.  
WANG H B, WAN L J. Dim infrared target detection based on contourlet and target characteristic analysis [J]. Journal

- of Electronic Measurement and Instrumentation, 2019, 33(3): 120-125.
- [7] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [8] KIM J, LEE J K, LEE K M. Accurate image super-resolution using very deep convolutional networks [C]. IEEE Conference on Computer Vision & Pattern Recognition (CVPR), 2016: 1646-1654.
- [9] KIM J, LEE J K, LEE K M. Deeply-recursive convolutional network for image super-resolution [C]. IEEE Conference on Computer Vision & Pattern Recognition (CVPR), 2016: 1637-1645.
- [10] TAI Y, YANG J, LIU X. Image super-resolution via deep recursive residual network [C]. IEEE Conference on Computer Vision & Pattern Recognition (CVPR), 2017: 3147-3155.
- [11] HU Y, WANG N, TAO D, et al. SERF: A simple, effective, robust, and fast image super-resolver from cascaded linear regression [J]. IEEE Transactions on Image Processing, 2016, 25(9): 4091-4102.
- [12] HU Y, LI J, HUANG Y, et al. Channel-wise and spatial feature modulation network for single image super-resolution [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2019, DOI: 10.1109/TCSVT.2019.2915238.
- [13] HUANG Y, LI J, GAO X, et al. Improving image super-resolution via feature re-balancing fusion [C]. IEEE International Conference on Multimedia and Expo, 2019: 580-585.
- [14] 邵保泰, 汤心溢, 金璐, 等. 基于生成对抗网络的单帧红外图像超分辨率算法 [J]. 红外与毫米波学报, 2018, 37(4): 427-432.
- SHAO B, TANG X, JIN L, et al. Single frame infrared image super-resolution algorithm based on generated countermeasure network [J]. Journal of Infrared and Millimeter Wave, 2018, 37(4): 427-432.
- [15] WANG B, ZHANG B F, LIU X W, et al. Novel infrared image enhancement optimization algorithm combined with DFOCS [J]. Optik, 2020, 12(8): 224-0239.
- [16] KIM B H, BOHAK C, KWON K H, et al. Cross fusion based low dynamic and saturated image enhancement for infrared search and tracking systems [J]. IEEE Access, 2020, doi: 10.1109/ACCESS.2020.2966794.
- [17] EL-SAMIE F E A, ASHIBA H I, SHENDY H, et al. Enhancement of infrared images using super resolution techniques based on big data processing [J]. Multimedia Tools and Applications, 2020, 79(11): 2503-2531.
- [18] HU Y, GAO X, LI, J, et al. Single image super-resolution via cascaded multi-scale cross network [J]. Signal Processing, 2020, 125(58): 996-1014.
- [19] TIMOFTE R, AGUSTSSON E, GOOL L V, et al. NTIRE 2017 Challenge on single image super-resolution: Methods and results [C]. IEEE Conference on Computer Vision & Pattern Recognition Workshops, 2017: 1-35.
- [20] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2017.
- [21] LEDIG C, THEIS L, HUSZAR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [J]. IEEE Computer Society, 2016, 25(21): 635-652.
- [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.

### 作者简介



**李萍**, 2009年于江南大学获得硕士学位, 现为无锡职业技术学院副教授, 主要研究方向为模式识别、人工智能。

E-mail: lipingswx@sina.com

**Li Ping** received her M. Sc. degree in 2009 from Jiangnan University. Now she is an associate professor at Wuxi Institute of Technology. Her main research interests include pattern recognition, artificial intelligence.



**刘以安**, 2005年于南京航空航天大学获得博士学位, 现为江南大学教授、研究生导师, 主要研究方向为数据融合、模式识别与智能系统。

E-mail: lya\_wx@jiangnan.edu.cn

**Liu Yian** received his Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 2005. Now he is a professor, M. Sc. supervisor at Jiangnan University. His main research interests include data fusion, pattern recognition and intelligent system.



**徐安林**, 2012年于南京航空航天大学获得硕士学位, 现为无锡职业技术学院副教授, 主要研究方向为机械设计、智能制造。

E-mail: xual@wxit.edu.cn

**Xu Anlin** received his M. Sc. degree from Nanjing University of Aeronautics and Astronautics in 2012. Now he is an associate professor at Wuxi Institute of Technology. His main research interests include mechanical design, intelligent manufacturing.