

doi: 10.3969/j.issn.2095-0411.2025.01.004

基于金字塔可形变卷积的多分支视频超分模型

孙立辉^{1,2}, 赵宜友¹

(1. 河北经贸大学 信息技术学院, 河北 石家庄 050051; 2. 河北省跨境电商技术创新中心, 河北 石家庄 050051)

摘要: 为利用帧间的空时相关性特点, 提升红外视频超分辨率重建效果, 提出了一种改进 BasicVSR 的超分辨率重建方法。首先, 使用金字塔可形变对齐代替 BasicVSR 中使用的光流法进行帧对齐, 将参考帧和相邻帧当作输入, 使用可形变卷积对帧间的偏移量进行测量, 使不同帧进行信息上的叠加, 最大限度得到图像中的细节特征。其次, 在上采样时, 将参考图像与经过融合后的图像进行级联, 通过浅层特征与深层特征的融合, 增强特征表达能力。文章设计的模型具有轻量、运行时间短、重建图像主观视觉效果好等优点, 且峰值信噪比 (PSNR) 与结构相似度 (SSIM) 以及模型运行时间等客观评价指标得到了改进。本文所提模型 EbasicVSR 比相关模型运行时间平均提升了 19 s, 信噪比提升了 0.14 dB 以上, 结构相似度提升了 2.9% 以上, 实验结果表明, 相比于原 BasicVSR 模型, 本文提出的模型取得了更好的重建效果。

关键词: 超分辨率重建; BasicVSR; 帧对齐; 可形变卷积; 级联融合

中图分类号: TP 391

文献标志码: A

文章编号: 2095-0411(2025)01-0028-09

Multi-branch video super-resolution model based on pyramid deformable convolution

SUN Lihui^{1,2}, ZHAO Yiyu¹

(1. School of Information Technology, Hebei University of Economics and Business, Shijiazhuang 050051, China; 2. Hebei Cross-Border E-Commerce Technology Innovation, Shijiazhuang 050051, China)

Abstract: In order to make use of the spatial and temporal correlation between frames to improve the performance of video super-resolution reconstruction, an improved BasicVSR super-resolution reconstruction method was proposed. Firstly, using deformable alignment to replace the optical flow method used in BasicVSR for frame alignment, taking the reference frame and adjacent frames as inputs, and using deformable convolution to measure the offset between frames, so that different frames can be superimposed on information to maximize the details of the image. Secondly, during the up-sam-

收稿日期: 2024-06-15。

基金项目: 河北省重点研发计划“军民科技协同创新专项”资助项目(20350801D)。

作者简介: 孙立辉(1971—), 男, 河北石家庄人, 博士, 教授。E-mail: Sun-lh@163.com

引用本文: 孙立辉, 赵宜友. 基于金字塔可形变卷积的多分支视频超分模型[J]. 常州大学学报(自然科学版), 2025, 37(1): 28-36.

pling, the reference image is cascaded with the fused image, and the feature expression ability was enhanced through the fusion of shallow features and deep features. The model designed in this paper has the advantages of light weight, short running time, good subjective visual effect of reconstructed images. In addition, objective evaluation indicators such as PSNR, SSIM and model running time have been improved. The EbasicVSR model proposed in this paper has an average improvement of 19 s in running time, more than 0.14 dB in signal-to-noise ratio and more than 2.9% in structural similarity compared with the relevant models. The experimental results show that the model proposed in this paper achieves better reconstruction results, compared with the original BasicVSR model.

Key words: super-resolution reconstruction; BasicVSR; frame alignment; deformable convolution; cascade fusion

红外热成像通过感受场景中物体之间的温度差进行成像,具有可夜间工作、穿透雨雾的能力较强等优点,被广泛应用于军事侦察、红外导引以及卫星遥感图像等领域^[1]。受红外波段以及红外传感器性能限制,一般来说红外图像的分辨率较低,加大了后续图像分析的难度。超分辨率重建技术(Super Resolution, SR)在可见光图像处理中的应用研究已经比较深入且取得不错的效果。但是受成像原理和器件的制约,红外图像整体较模糊,细节缺失严重,如何对红外图像进行超分辨率重建是目前研究的一个热点^[2]。

根据生成高分辨率图像参照信息的不同,SR分为单帧超分(Single Image Super-Resolution Reconstruction, SISR)和视频超分(Video Super-Resolution Reconstruction, VSR)^[3]。SISR通过研究单张图像的内在空间信息,实现高分辨率图像重建。VSR由于利用了视频序列帧间的时间相关性特点,因此能够更加有效地提升重建效果。WOODCOCK等^[4]提出的VSRnet最早将神经网络算法应用到视频超分领域,同时在模型中添加运动估计与运动补偿模块,输入不再是单张图像而是变成视频序列,图像的帧间时间信息也得以利用。SHI等^[5]提出VESPCN,引入空域运动补偿变换模块,运动补偿后的帧通过卷积神经网络再进行特征提取与融合,该算法具有简单,能够实时处理的优点。WANG等^[6]提出EDVR,首先在模型中加入可形变卷积对齐模块用于解决运动复杂以及运动幅度较大的帧对齐问题,然后加入时空注意融合模块将对齐以后的特

征图进行融合。CHAN等^[7]提出的BasicVSR采用双向视频流循环结构,使得原始图像承载信息的局限性得到弥补,重建速度还有重建效果均优于传统视频超分重建模型。

基于图像空时相关性信息的超分辨率重建算法在可见光领域虽然已经取得不错的重建效果,但这些算法大多采用光流法,对图像进行运动估计来实现帧间对齐。光流法对光线比较敏感,受光线变化影响较大。而红外图像是通过物体散发红外光线的热效应产生,光流特征不明显,因此光流法并不适用于红外图像重建。针对此问题,在BasicVSR基础上,提出了适用于红外图像的视频超分辨率重建EbasicVSR模型,实验证明文章所提模型生成图像重建效果更好,且生成图像速度更快。

1 视频超分模型 BasicVSR

VSR本质来源于SISR,但相比SISR结构更为复杂,VSR进行重建时在利用图像空间信息基础上融入视频帧间的时间关联信息,得到的图像特征更加丰富。BasicVSR在进行图像超分辨率重建过程中,分为特征传播(Propagation)、帧间对齐(Alignment)、特征融合(Fusion)、上采样(Upsampling)4个步骤。首先,通过双向视频流循环结构进行帧间特征信息的传播,双向传播分为前向传播与后向传播,通过双向传播能够将信息最大程度进行聚合。然后,采用基于光流的Feature-wise方式进行相邻帧间对齐,通过对输入序列的帧间时间信息进行建模,充分考虑到较远帧的特征信息对目标帧重构的辅

助作用, 捕获了较长时间的依赖, 最大程度提高帧间利用率。最后, 进行图像的重建, 将对齐后的图像特征信息进行融合, 生成特征图, 并通过亚像素卷积层来进行上采样, 重建出高分辨率图像, BasicVSR 模型结构图如图 1 所示。 x_{i-1} , x_i , x_{i+1} 代表相邻帧图像; F_b 与 F_f 表示特征的双向传播; Concat 表示特征的融合; U 代表上采样过程。其中, 帧间对齐过程最为重要, 帧间对齐效果是影响重建图像质量高低的关键。

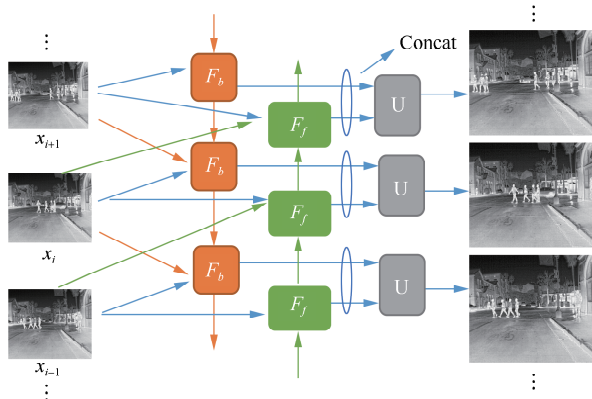


图 1 BasicVSR 模型结构图

Fig.1 Model structure of BasicVSR

BasicVSR 是一种轻量且高性能的 VSR 模型, 无论是运行速度还是图像的重建效果均优于其他 VSR 模型, 可以作为后续研究视频超分的 Baseline。

2 视频超分模型 EbasicVSR

相比于单帧图像的超分辨率重建, 视频帧与帧之间具有强关联的时间信息与空间信息, 如何最大程度利用这些信息是视频超分研究的重要内容。针对红外图像整体模糊、细节缺失以及受光线变化影响较大等特点, 文章提出了一种适用于红外视频超分辨率重建模型 EbasicVSR。

2.1 EbasicVSR 模型设计

为使模型适用于模糊的红外图像, 同时加强生成图像的纹理细节, 文章对原 BasicVSR 模型的帧间对齐方式及上采样方式进行优化。采用金字塔可形变卷积法代替光流法实现帧间特征对齐, 并将原模型中直接进行后置上采样的方法升级为多分支级联融合上采样法, 特征传播与特征融合部分保持原方法不变, 改进后的模型 EbasicVSR 结构图如图 2 所示。 b_1, b_2, \dots, b_M 代表 M 张相邻帧基础图像, 低分辨率图像 (LR) 先通过金字塔可形变卷积进行对齐, 再通过多分支级联融合模块进行上采样, 最后生成高分辨率图像 (SR)。虚线框内分别为改进后的对齐模块与上采样模块。

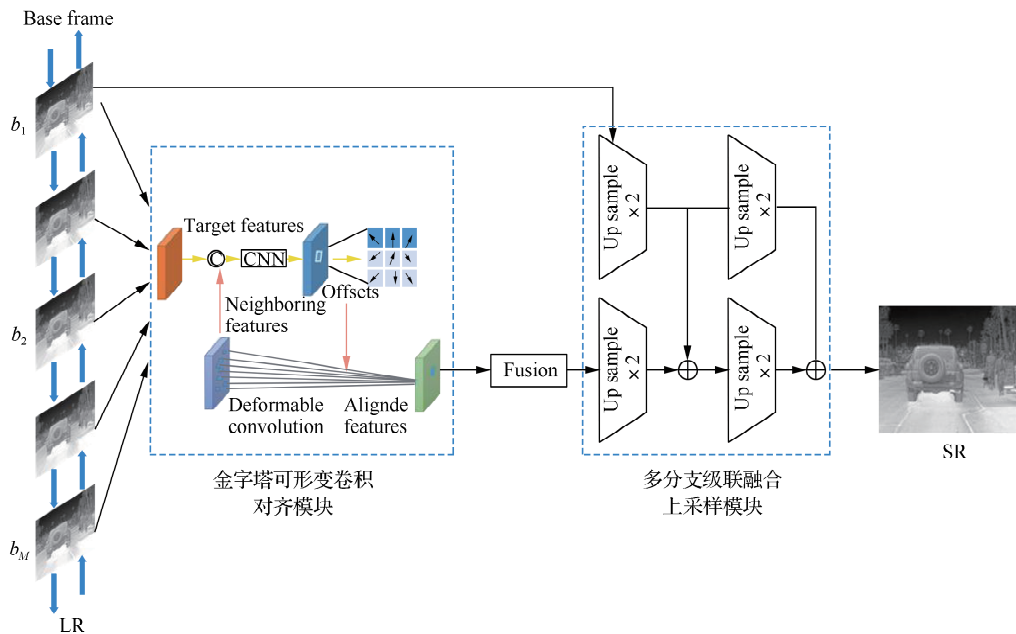


图 2 EbasicVSR 模型结构图

Fig.2 Model structure of EbasicVSR

2.2 金字塔可形变卷积对齐模块

传统卷积的卷积核形状是固定的矩形, 只适合提取形状固定的目标, 与卷积核大小固定的一般卷积相比, 可形变卷积在卷积核中添加偏移量, 扩大了卷积核的采样区域, 增加了感受野, 提高了模型的泛化能力^[8]。且可形变卷积具有不受光线以及场景变换影响的特征, 在提取特征时, 使用额外的卷积对特征的相对偏移量进行学习, 增强网络对特征位置的建模能力。即使是特

征不清晰的红外图像, 也可以合理地利用相邻帧间的特征变化信息, 将不同帧的时间与空间信息进行融合。

针对红外图像目标形状多变且边缘高频细节模糊的特点, 文章引入金字塔可形变卷积进行帧间特征对齐, 该模型为一个上下层连接的金字塔结构^[9], 通过垂直与水平两个方向共同作用实现相邻两个视频帧的特征对齐, 具体结构示意图如图 3 所示。

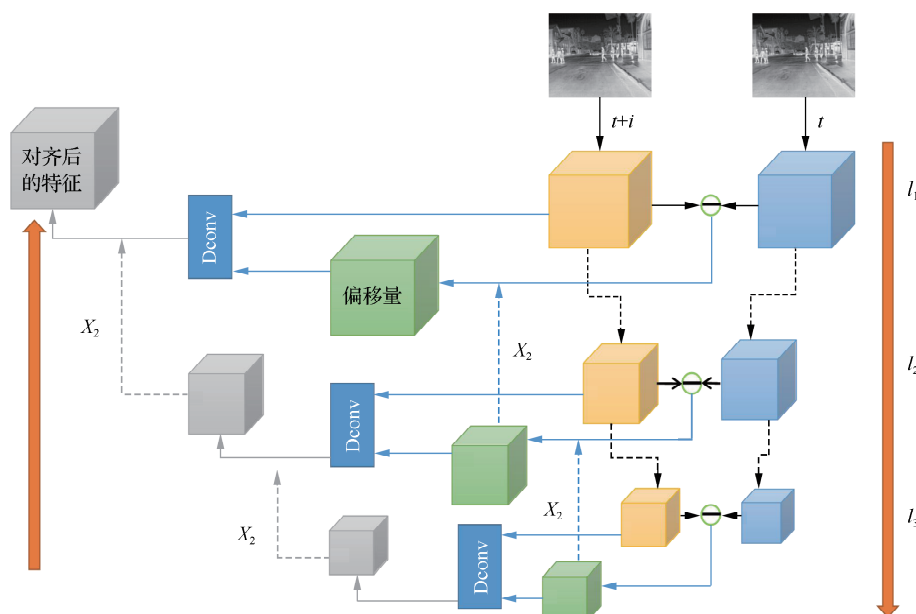


图 3 金字塔可形变卷积结构图

Fig.3 Deformable convolution structure of pyramid

输入第 t 帧与第 $t+i$ 帧两张相邻图像时, 垂直方向主要进行金字塔各层特征信息的提取。首先, 将输入的参考帧图像与相邻帧图像分别进行卷积, 得到这两帧的特征图作为金字塔第一层 l_1 的特征信息。然后, 将第一层特征信息通过跨步卷积进行 2 倍下采样得到金字塔第二层 l_2 的特征信息。同理自上而下, 经过相同操作得到 l_3 , l_4 , \dots , l_n 层特征图。其中, 特征提取过程使用的卷积并非普通卷积而是动态卷积 (Dconv), 动态卷积可以根据不同的输入图像对各个图像赋予不同的权重 ($K_1 \sim K_3$), 也可以对同一图像的不同特征信息赋予不同权重, 有针对性地对信息进行提取。动态卷积结构图如图 4 所示。在水平方向金字塔每层都进行偏移量的测量以及特征的

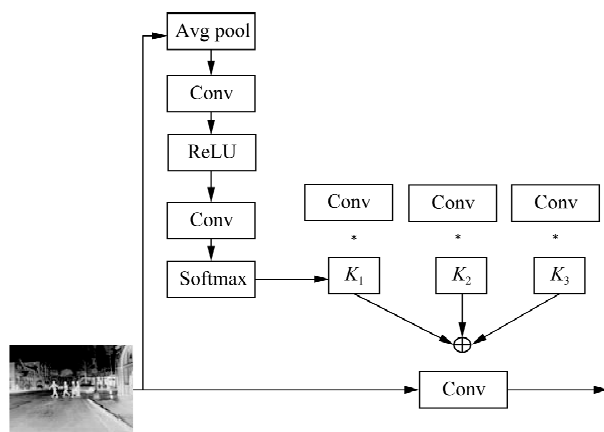


图 4 动态卷积结构图

Fig.4 Structure diagram of dynamic convolution

对齐, 以 l_n 层为例, 首先, 第 t 帧与第 $t+i$ 帧的特征图进行 concat 操作。然后, 通过可形变

卷积得到这两帧之间的偏移量。最后,将偏移量经过可形变卷积作用于第 $t+i$ 帧的特征图,进行特征的对齐,得到 l_n 层新的第 $t+i$ 帧特征图。分别得到水平与竖直方向的特征信息后,将 l_n 层得到的偏移量以及对齐后的特征图经过二次上采样 (X_2),与其上层 (l_{n-1} 层) 相应信息进行融合,同理各层之间自下而上进行特征信息汇总,直至所有特征融合到金字塔第一层,最终得到第 $t+i$ 帧的特征信息。

金字塔结构将不同尺度、不同维度的特征进行融合,可形变卷积自适应性强,灵活度高,两者结合进行逐层估计,卷积核能够更加适应所要提取特征对象的形状,更好地对几何模型进行变换。金字塔可形变卷积结构增大了感受野,且每层均进行下采样操作,因此计算量不会有太大提升。对于第 l 层金字塔,可得到第 t 帧与第 $t+i$ 帧偏移量以及对齐后第 $t+i$ 帧的公式,分别见式 (1) 与式 (2),采样过程采用双线性插值法。

$$\Delta P_{t+i}^l = f(F_{t+i} - F_t, (\Delta P_{t+i}^{l+1})^{\uparrow 2}) \quad (1)$$

$$(F_{t+i}^a)^l = g(\text{Dconv}(F_{t+i}^l, \Delta P_{t+i}^l), ((F_{t+i}^a)^{l+1})^{\uparrow 2}) \quad (2)$$

式中: f 表示特征的融合; F_{t+i} 表示第 $t+i$ 帧图像的特征; F_t 表示第 t 帧图像的特征; $(\Delta P_{t+i}^{l+1})^{\uparrow 2}$ 表示在第 $l+1$ 层,第 t 帧与第 $t+i$ 帧之间偏移量的 2 倍上采样; g 表示多层卷积组成的简单网络结构; Dconv 表示动态卷积; F_{t+i}^l 表

示第 l 层的第 $t+i$ 帧的特征; ΔP_{t+i}^l 表示第 l 层的第 t 帧的偏移量; $((F_{t+i}^a)^{l+1})^{\uparrow 2}$ 表示第 $l+1$ 层第 $t+i$ 帧特征的 2 倍上采样。

2.3 多分支级联融合上采样

一般视频超分辨率重建采用后置上采样法,如图 5 所示。后置上采样结构简单,在低维空间进行特征提取,在末端进行端到端的学习,具有计算量小且空间复杂度低的优点。但当上采样倍数较大时,后置上采样学习难度相应变大,高分辨率图像重建效果较差,而且一次性完成上采样的过程只适用于单个比例因子的训练,当缩放系数发生变化时,模型需要重新开始训练。




图 5 后置上采样示意图

Fig.5 Schematic diagram of post upsampling

针对后置上采样不适用于多尺度训练任务、且上采样因子较大、生成高分辨率图像 (HR) 质量较差的问题,本文提出一种多分支级联融合上采样法,如图 6 所示。通过把上采样过程分级




图 6 多分支级联融合上采样

Fig.6 Multi branch cascade fusion upsampling

重构,将复杂问题简单化,降低学习难度,对分次上采样后的图像进行叠加操作,实现有用信息的多次复用。多次特征融合相较于 BasicVSR 单次融合重建得到的图像特征信息更为丰富,且融合在特征级别进行,结合各个维度信息,极大增强了特征的表达能力。

具体的每个虚线框的上采样体系结构,如图 7 所示。前两个卷积层进行图像特征的提取,并

通过跳跃连接的方式将提取到的浅层特征传输到网络的末端,实现深层特征与浅层特征的融合。网络主体部分为残差密集模块 (RESM),用于图像局部特征的提取。同样 RESM 模块在作为下一个残差密集块输入的同时,也通过跳跃连接将局部特征传输到网络末端,实现特征的融合。最后通过直接上采样实现图像的重建。

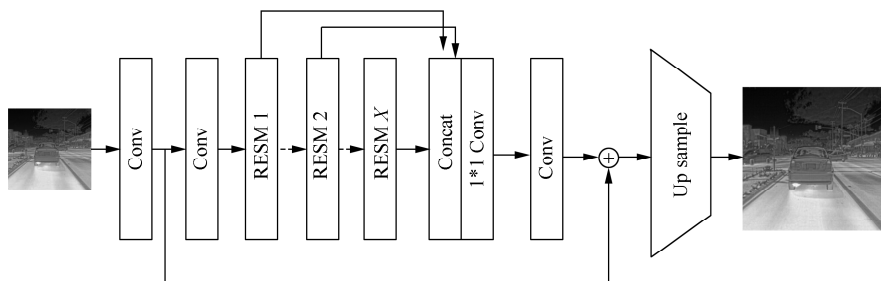


图 7 上采样体系结构

Fig.7 Architecture of upsampling

残差密集模块 (RESM) 由残差网络与密集网络组合而来,其结构如图 8 所示。该模块主要由卷积层与激活函数 ReLU 组成,每个卷积层有不同的感受野,充分利用所有层的特征信息来重建图像,通过 1×1 卷积层实现跨通道信息的整合。最后通过跳跃连接,以逐像素相加的方式实现特征在该模块的融合。




图 8 RESM 结构图

Fig.8 Structure diagram of RESM

3 实验结果及性能评价

3.1 实验数据集

实验采用公开数据集以及自制红外数据集结合进行实验,所有数据集均包含自然景观、行人、车辆等多种场景图。公开数据集使用

FLIR^[10] 公开数据集和灰度化以后的 REDS^[11] 数据集,从 FLIR 数据集挑选出 10 400 张连续帧的图像,分为 104 个文件夹,每个文件包含 100 张连续帧图像,分辨率为 640×512 (数据集 D1)。经过灰度化操作的 REDS 数据集包含 270 个视频,每组视频 100 帧,图像分辨率为 $1\,280 \times 720$ (数据集 D2)。自制红外数据集包含 40 个真实场景红外视频,每个视频包含 100 张连续帧,分辨率为 480×640 (数据集 D3)。所有数据集的原图作为高分辨率图像 HR,将原图进行双三次下采样得到的图像作为低分辨率图像 LR,将所有 LR 图像进行随机剪裁得到 128×128 的图像块,并在 HR 中得到对应的块,组成图像对。

3.2 实验环境

实验使用的计算机操作系统为 Ubuntu18.04, GPU 型号为 RTX2080Ti,运行内存为 16 GB, CUDA 版本为 11.4,采用的深度学习框架是 Pytorch1.3.1,编程语言使用 Python,训练时的优化算法为 Adam 优化器。训练的 Batchsize 设置为 64,验证 Batchsize 设置为 32,损失函数为 Charbonnier loss,设置初始学习率为 1×10^{-3} ,每迭代 5 000 次学习率都将乘以

0.1, 总的迭代次数为 3×10^5 。

3.3 评测指标

峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 与结构相似度 (Structural Similarity, SSIM) 是深度学习模型中评价图像质量最常用的两个客观评价指标^[12], 文章依然采用这两个指标来对生成的超分图像进行评价。PSNR 通过计算生成图像与对比图像全局像素的均方误差来衡量生成图像的质量, 通过量化误差的大小比较不同算法的表现, PSNR 与均方误差成反比。因此, 全局均方误差越小, PSNR 越大, 表明生成图像的质量越好。人在观察图像时, 关注的其实是背景中物体的结构, SSIM 是一种比较符合人类视觉的图像客观评价指标, 它从亮度、对比度以及结构 3 方面对两张图像进行对比, 并将输出结果设置为 0~1, 结果越接近 1, 说明图像间的结构相似度越高。

3.4 实验结果分析

对文章模型与几个经典模型在测试集上的运行时间以及在采样因子不同的情况下, 信噪比、相似度以及图像的重建效果进行对比。其中上采样因子选择 2, 4, 8, 对比方法选择最传统的双三次上采样法 (Bicubic) 以及 VESPCN, EDVR, BasicVSR, EbasicVSR 模型。各模型的模型大小以及在测试集上的运行时间见表 1。表 2 与表 3 分别为它们在测试集上的峰值信噪比 (PSNR) 与结构相似度 (SSIM)。

表 1 各模型的模型大小以及在测试集上的运行时间

Table 1 Model size of each model and running time on test set

模型	模型大小	运行时间/s
VESPCN	2.048×10^7	378
EDVR	2.670×10^7	346
BasicVSR	6.300×10^6	287
EbasicVSR	8.800×10^6	268

由表 1 可知, VESPCN 以及 EDVR 等传统视频超分模型较大, 参数量较多, 使用相同的测

试集 (400 帧序列红外图像), 网络运行时间要远长于 BasicVSR 以及文章改进后的 EbasicVSR 模型。BasicVSR 模型相较于传统模型主干更加轻量化, 模型运行速度也大大提高, 运行时间大大缩短。文章提出的 EbasicVSR 模型, 模型大小与 BasicVSR 相差不大, 但运行时间相比于 BasicVSR 更有优势。

表 2 测试集上的 PSNR 对比

Table 2 Comparison of PSNR on the test set dB

上采样因子	Bicubic	VESPCN	EDVR	BasicVSR	EbasicVSR
2	24.81	25.48	25.84	26.32	26.57
4	23.66	25.21	25.36	25.87	26.01
8	20.48	21.57	21.98	22.69	22.81

由表 2 可知, 其他模型产生的信噪比远高于简单的双三次上采样 (Bicubic), 上采样因子越大, 图像的重建指标越低, 即重建效果越差。但是不管采样因子多大, 文章提出的 EbasicVSR 模型较 BasicVSR 模型均有明显提升, 提升了 0.12~0.25 dB。PSNR 通过计算两幅图像对应像素点的误差衡量图像质量, 针对同一数据集, 改进后模型的 PSNR 更大, 说明改进后生成的高分辨率图像失真更小。同时, 由表 3 可知, 改进后模型的 SSIM 在不同模型上也均有所提升, 提升范围为 1.3%~4.1%, 本文提出的模型生成的超分图像越来越接近于真实高分辨率图像。

表 3 测试集上的 SSIM 对比

Table 3 Comparison of SSIM on the test set

上采样因子	Bicubic	VESPCN	EDVR	BasicVSR	EbasicVSR
2	0.803	0.856	0.864	0.870	0.883
4	0.664	0.694	0.697	0.701	0.730
8	0.564	0.587	0.598	0.613	0.654

图 9 为应用场景图。对应的各模型在不同场景的实验效果图, 见表 4。由表 4 可以看出, Bicubic 并没有利用图像帧与帧之间的信息, 只是对图像进行简单拉伸, 上采样后的图像最为模糊。VESPCN 模型相比于 Bicubic 产生的图像较为清晰, 重影现象明显减少。EDVR 模型在

VESPCN 模型基础上产生的细节纹理更多。BasicVSR 模型在加入双向传播后,信息的传播更加高效,产生图像视觉效果更好。而经过创新后的 EbasicVSR 模型产生的高分辨率图像高频成

分明显多于 BasicVSR 模型处理后的图像,改进后的模型对于纹理特征的表达能力更强,说明文章的改进模型对于更加合理地利用帧与帧之间的信息是有效的。

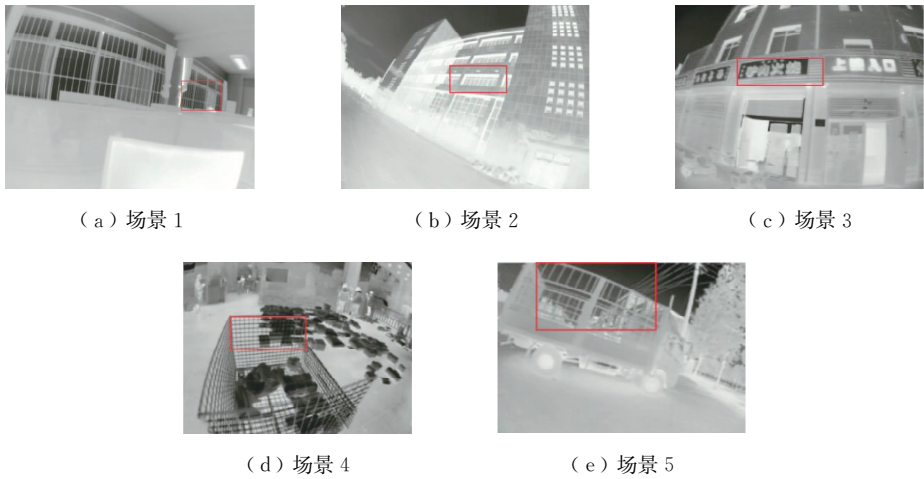


图 9 应用场景图

Fig.9 Application scenarios of each model

表 4 不同场景的实验效果

Table 4 Experimental effects of each model in different scenarios

场景	Bicubic	VESPCN	EDVR	BasicVSR	EbasicVSR
场景 1					
场景 2					
场景 3					
场景 4					
场景 5					

结合各模型产生的实验效果图以及模型运行时间,可以看出,相较于之前的模型,改进后的模型图像质量更好;产生图像质量相似时,模型运行时间上更有优势。

4 结 论

提出了一种适用于红外序列图像的超分辨率

重建模型,首先,通过金字塔可形变卷积进行红外图像的帧间对齐,利用可形变卷积层中学习偏移量对图像内容的高度自适应性,来对相邻帧之间特征的偏移量进行计算,将帧间特征进行对齐。其次,在上采样时实行多分支级联融合上采样,将基础帧与上采样后的图像进行多次融合,对有用特征信息进行加强。实验结果表明,所改

进模型相较于原模型图像纹理细节更加清晰,且图像的客观指标 PSNR 与 SSIM 均有提升。目前超分辨率重建技术很多应用于电子设备,但电子设备储存空间有限,文章所提模型还不够精简,接下来会考虑将模型进行优化,提高运行效率的同时,减少储存空间的占用。

参考文献:

- [1] 伍利兵,陈朝方,林国生,等. 红外热成像技术在安全检测领域的应用现状[J]. 品牌与标准化, 2021(4): 97-100.
- [2] 李苗苗. 红外图像数字细节增强关键技术研究[D]. 南京: 南京邮电大学, 2019.
- [3] 冷佳旭,王佳,莫梦竟成,等. 基于深度学习的视频超分辨率重建进展综述[J]. 计算机科学, 2022, 49(2): 123-133.
- [4] WOODCOCK J, BOCA P. ABZ2008 VSR-net workshop[C]//International Conference on Abstract State Machines. Heidelberg: Springer, 2008: 378-379.
- [5] SHI W Z, CABALLERO J, HUSZÁR F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 1874-1883.
- [6] WANG X T, CHAN K C K, YU K, et al. EDVR: video restoration with enhanced deformable convolutional networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Long Beach: IEEE, 2019: 1954-1963.
- [7] CHAN K C K, WANG X T, YU K, et al. BasicVSR: the search for essential components in video super-resolution and beyond[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 4945-4954.
- [8] 吴昊月,张惊雷,赵俊亚. 基于导向型级联可形变卷积的电气设备红外图像检测[J]. 计算机应用与软件, 2023, 40(4): 204-210.
- [9] 樊凌雁,彭义辉,王洪波. 基于金字塔结构超分辨率网络的图像拼接方法: 202211547399. 6[P]. 2022-12-05[2023-10-09].
- [10] 薛培,薛国新,张亚洲,等. 一种基于小波系数加权平均的 Retinex 图像增强算法[J]. 常州大学学报(自然科学版), 2010, 22(4): 39-42.
- [11] NAH S, BAIK S, HONG S, et al. NTIRE 2019 challenge on video deblurring and super-resolution: dataset and study[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Long Beach: IEEE, 2019: 1996-2005.
- [12] 郑德品,沈海斌,赵武峰. 一种抗模糊失真的结构相似度图像质量评价法[J]. 机电工程, 2007, 24(10): 82-84.

(责任编辑:谭晓荷)