

引用格式:陈雅玲,朱永贵.基于通道注意力机制的视频超分辨率方法[J].中国传媒大学学报(自然科学版),2023,30(05):55-62.
文章编号:1673-4793(2023)05-0055-08

基于通道注意力机制的视频超分辨率方法

陈雅玲*,朱永贵

(中国传媒大学数据科学与智能媒体学院,北京 100024)

摘要:基于视频帧间信息特征,提出了基于通道注意力机制的循环残差注意力网络,将连续的低分辨率视频帧、前一时刻输出帧和隐藏态作为输入进行特征提取,在隐藏态中引入残差连接和注意力机制,增强网络特征提取能力,经过亚像素卷积层重建出高分辨率视频帧。然后将本视频超分辨率网络模型在Vid4、UDM10、SPMCS视频数据集进行了测试。实验结果表明,与其他基于深度学习的视频超分辨率方法相比,本方法能利用帧间特征信息较好地恢复高频特征信息,恢复的视频图像PSNR和SSIM值都比其他主流方法要高,同时取得了较好的主观视觉效果。

关键词:视频超分辨率;循环神经网络;残差块;注意力机制

中图分类号:TP391.41 文献标识码:A

A video super-resolution method based on channel attention mechanism

CHEN Yaling*, ZHU Yonggui

(School of Data Science and Media Intelligence, Communication University of China, Beijing 100024, China)

Abstract: Based on the information between video frames, a recurrent residual attention network based on channel attention mechanism was proposed in this paper. Continuous low-resolution video frames, along with the output frame and the hidden state from the previous moment were input into the network for feature extraction. The residual connection and the attention mechanism were introduced in the hidden state to enhance the network's feature extraction ability. The high-resolution video frames were reconstructed through the sub-pixel convolution layer. The video super-resolution network model presented in this paper was tested on Vid4, UDM10 and SPMCS video datasets. The experimental results show that compared with other deep learning based video super-resolution methods, the proposed method uses interframe feature information to better recover high-frequency feature information. The PSNR and SSIM values of the recovered video images outperform other general methods, while the subjective visual effect is better.

Keywords: video super-resolution; recurrent neural network; residual block; attention mechanism

1 引言

随着高清专业影视摄像机、高清显示设备、高清视频监控等高清视频系统在生活中的逐步普及,人们

对高分辨率视频的需求也随之增加,但高清、超高清视频资源相对较为稀缺,这就需要使用视频超分辨率技术重建出更多高质量的视频资源。视频超分辨率技术不仅可以提高视频的分辨率,恢复视频丰富的细

节信息,还有助于降低高清或超高清视频的传播成本,被广泛应用在视频监控、视频成像、多媒体和医学等领域中。

相比传统的超分辨率插值技术,基于深度学习的超分辨率技术能更好地恢复图片的纹理细节及视觉效果。2014年,Dong等^[1]首次提出超分辨率卷积神经网络(Super-Resolution Convolutional Neural Network, SRCNN),证明使用卷积神经网络可以学习低分辨率图像到高分辨率图像的非线性映射。随着卷积神经网络在超分辨率技术发展中表现出显著的优势,基于深度学习的超分辨率技术不断涌现,并成为主流的研究方法之一。在此基础上,视频超分辨率技术更注重视频帧间信息的利用,可以看成是图像超分辨率技术的延伸,现阶段基于深度学习的视频超分辨率技术根据网络框架主要可以分为两大类:一是迭代网络,二是循环网络。

现有的基于迭代网络结构的算法以滑动窗口的方式,取连续的低分辨率视频帧作为网络的输入,通过不断迭代重建高分辨率的视频序列。然而这类网络结构对长距离依赖关系的捕获受限于窗口的大小,其性能难以达到实际应用的需求。相比之下,循环网络按时间顺序处理视频帧的方式可以弥补滑动窗口的缺陷,从而更有效地利用视频帧间信息。本文以循环网络为基础,在隐藏态中引入残差连接以保留纹理细节,避免梯度消失的问题,同时使用注意力机制增强通道间的有用特征信息,提出了一种基于通道注意力的循环残差注意力网络视频超分辨率方法。

2 相关工作

2.1 基于深度学习的视频超分辨率方法

在基于迭代网络框架的视频超分辨率方法中,对帧间信息的利用通常采用运动估计和运动补偿方法。然而,此类方法不仅计算量较大,并且依赖于精确的运动估计。Tian等^[2]提出了时域可变形对齐网络(Temporally-Deformable Alignment Network, TDAN),可以在不计算光流的情况下自适应地对齐相邻帧和目标帧,提升网络的空间变换能力,进而有效地提升模型性能。Ying等^[3]使用可变形三维卷积网络(Deformable 3D Convolution Network, D3D),灵活提取时空信息同时进行帧间运动补偿,生成的高分辨率视频具有较好的流畅度。Jo等^[4]使用动态上采样滤波器(Dynamic Upsampling Filters, DUF)提取时空特征,避

免了运动估计和运动补偿带来的潜在误差。渐进融合网络^[5]引入非局部残差块捕获长距离时空相关性,以隐式运动补偿的方法利用时空信息。基于迭代网络的方法虽然在多个基准上表现卓越,但该网络结构往往只考虑窗口内有限的视频帧,从而限制了此类算法在实际中的应用。

循环神经网络具有记忆特性,网络会将序列中先前时刻的信息应用到当前的计算中,适用于处理自然语言、视频、音频等序列数据。因此,基于循环网络的视频超分辨率算法可以利用历史信息和当前信息增强低分辨率帧的纹理细节。Frame-Recurrent Video Super-Resolution(FRVSR)^[6]首次将循环网络结构引入到视频超分辨率领域,提出了一个端到端训练的帧循环网络框架,在相邻帧间采用显式运动估计和扭曲操作,既能有效利用帧间信息,又能保证时间上的连续性。Fouli等^[7]采用与FRVSR相似的策略,提出Recurrent Latent Space Propagation(RLSP),但二者对时间信息的利用方式并不相同,RLSP通过隐藏态传递时间信息,将三个连续帧输入隐藏态,避免了显式运动估计存在对齐误差且计算量大的问题。Residual Invertible Spatio-Temporal Network(RISTN)^[8]中采用残差可逆模块和残差密集卷积模块提取时空信息,在模块中引入残差连接以降低信息丢失的可能性。Harris等^[9]提出循环反向投影网络(Recurrent Back-Projection Network, RBPN),根据相邻帧和相邻帧间的光流学习残差,使用反向投影迭代提取目标帧丢失的细节,弥补了循环神经网络的不足。

以上这些视频超分辨率方法的隐藏态中包含多个卷积层,传播过程中卷积层会对输入信息进行不可避免地衰减,从而导致纹理细节丢失,有些方法的输入帧较多,当遇到大运动场景时,输入帧越多,信息传播的准确性越差。本文以连续的两个视频帧作为输入,并在隐藏态中引入残差连接,增加网络的稳定性,保留更多的纹理细节。

2.2 注意力机制

注意力机制与人类的视觉注意力机制相似,将关注点聚焦于重要的信息上,降低对次要信息地关注,高效地从大量信息中筛选出有价值的信息。在超分辨率任务中,引入注意力机制可以使网络关注到更为重要的特征信息,提高模型的表现力。Hu等^[10]提出了挤压与激励网络(Squeeze-and-Excitation Network, SENet),研究特征图通道间的依赖关系。Wang等^[11]提出高效通道注

注意力机制,在SENet的基础上改进了注意力模块,避免了维度缩减带来的副作用,提高捕获通道间依存关系的能力,同时使模型更加轻量化。Residual Channel Attention Network(RCAN)^[12]在残差块中加入通道注意力机制,自适应地调整各通道权重,增强有用特征。本文在残差块中引入通道注意力机制,在深层残差网络中充分挖掘和利用通道间的特征信息。

3 循环残差注意力网络框架

本文提出了一种基于通道注意力的循环残差注意力网络,在循环神经网络中加入残差结构,以便于

更好地保留图片纹理细节,通过引入通道注意力机制,增强网络提取特征的能力。该网络模型由浅层特征提取模块、残差注意力模块和像素重组模块三部分组成,模型结构如图1所示,网络以连续两个低分辨率帧和先前输出的高分辨率帧以及隐藏态特征作为输入,先通过浅层特征提取模块获得初始特征图,将其输入残差注意力模块组进行深度的特征提取,再经过像素重组模块将特征图从低分辨率空间映射到高分辨率空间,最后与经过上采样的参考帧相加获得重建的高分辨率图像,网络中所有卷积层的卷积核大小均为 3×3 ,中间层通道数设为128。

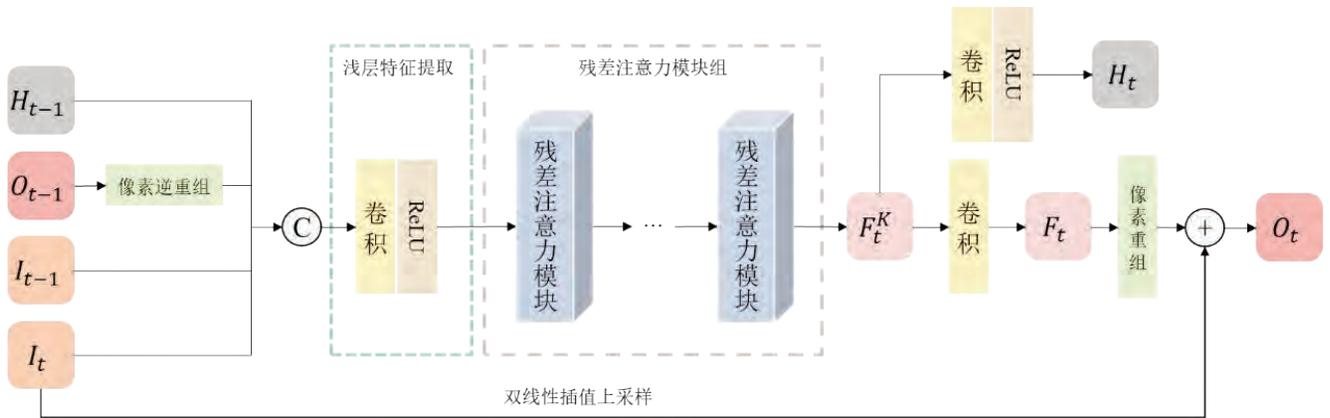


图1 循环残差注意力网络结构

3.1 浅层特征提取

将 t 时刻输入网络的低分辨率帧序列表示为： $\{I_{t-1}, I_t\}$,其中 I_t 为参考帧, I_{t-1} 为相邻帧,先将低分辨率帧 I_{t-1}, I_t 与上一时刻的隐藏态特征 H_{t-1} 和输出 O_{t-1} 输入浅层特征提取模块,用一层卷积运算和 $ReLU$ 激活函数对输入的特征信息进行初步提取,得到浅层特征图 F_t^0 ,用公式表示为:

$$F_t^0 = \sigma \left(\text{Conv} \left[I_{t-1}, I_t, \hat{O}_{t-1}, H_{t-1} \right] \right) \quad (1)$$

其中, $\sigma(\cdot)$ 表示 $ReLU$ 激活函数, $\text{Conv}(\cdot)$ 表示卷积操作, $[\cdot]$ 表示按通道拼接, \hat{O}_{t-1} 是经过像素逆重组的上一时刻输出帧,这一步操作是为了保证网络的输入尺寸一致。在初始时刻,上一步的输出和隐藏态特征均初始化为零。

3.2 残差注意力模块

传统的循环神经网络随着网络加深会出现梯度消失,从而无法学习长距离依赖关系,He等^[13]提出使用残差学习,引入残差连接可以保证网络在输入特征

不变的基础上学习到新的特征,使网络具有稳定提取深层特征信息的能力。实验结果显示,残差连接可以有效解决梯度消失的问题。此外,由于残差块中的批量归一化层(Batch Normalization Layer, BN层)会对图像特征进行归一化,破坏原本的色彩分布和对比度信息,影响图像的输出质量,受Lim等^[14]启发,本文将残差块中BN层移除,不仅可以提高网络输出质量,还能节约存储资源和算力资源。

为了提高模型的表达能力,本文还在经过修改的残差块中引入通道注意力机制,形成残差注意力模块,对不同通道的特征图赋予不同的注意力,使网络集中学习图片的高频信息,提高辨别学习的能力,该模块的结构如图2所示。

在 t 时刻,将经过浅层特征提取的初始浅层特征图 F_t^0 输入第一个残差注意力模块,通过 K 个残差注意力模块对 F_t^0 进行深层特征提取,具体过程如下:

在第 k 个残差注意力模块中,先输入上一个模块的输出结果 F_t^{k-1} 进行残差特征学习,获得残差特征信息 X_t^k :

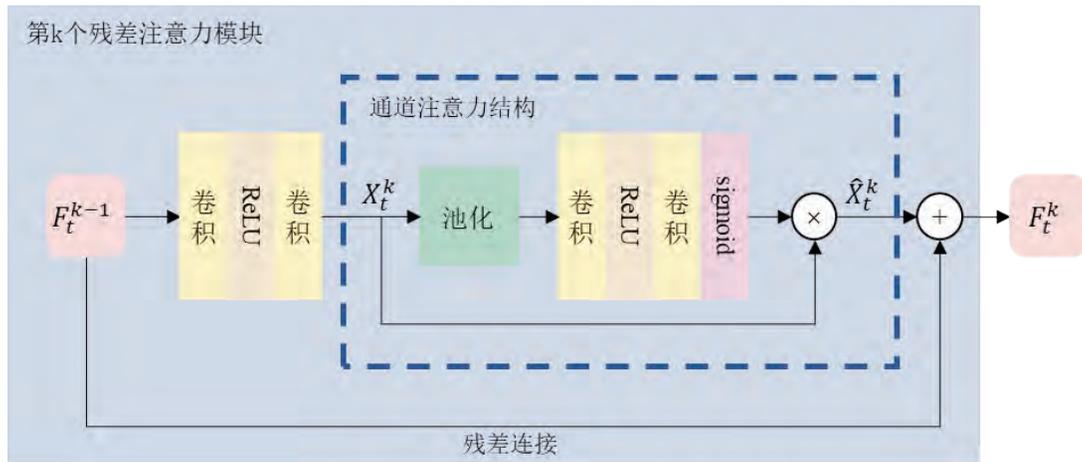


图2 残差注意力模块

$$X_t^k = \text{Conv}(\sigma(\text{Conv}(F_t^{k-1}))) \quad (2)$$

再将 X_t^k 输入通道注意力结构,对 X_t^k 进行全局平均池化,池化结果为一维张量 Z ,其中第 c 个通道的池化过程为:

$$Z_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_{t,c}^k(i,j) \quad (3)$$

其中, Z_c 和 $X_{t,c}^k$ 分别表示通道向量 Z 和残差特征信息 X_t^k 的第 c 个通道, H 和 W 分别表示第 c 个通道特征图的高和宽。

为了学习各通道间的依赖关系,使用卷积对 Z 进行通道下采样,使输出通道数变为原来的 $1/r$,再使用卷积进行通道上采样,恢复原始通道数,生成各个通道的权重 S :

$$S = \delta(U_r(\sigma(D_r Z))) \quad (4)$$

其中 $\delta(\cdot)$ 表示 sigmoid 函数, U_r 和 D_r 分别表示比例因子为 r 的通道上采样和下采样,这里设置 $r = 16$,通过卷积的方式使通道数按比例缩放,最后获得各通道的注意力权重。

将输出的注意力权重按通道加权到残差特征信息的通道上:

$$\hat{X}_{t,c}^k = S_c \cdot X_{t,c}^k \quad (5)$$

其中, $\hat{X}_{t,c}^k$ 表示经过通道注意力加权的残差特征信息 X_t^k 的第 c 个通道, S_c 表示第 c 个通道的注意力权重。

最后,引入残差连接,将经过通道注意力加权的残差特征信息 \hat{X}_t^k 与输入的特征信息 F_t^{k-1} 相加获得该残差注意力模块的输出 F_t^k :

$$F_t^k = F_t^{k-1} + \hat{X}_t^k \quad (6)$$

依次经过残差注意力模块组,学习到特征信息

F_t^k ,再对其分别进行一次卷积得到深层特征信息 F_t ,进行一次卷积和 ReLU 激活函数得到隐藏态特征 H_t :

$$F_t = \text{Conv}(F_t^k) \quad (7)$$

$$H_t = \sigma(\text{Conv}(F_t^k)) \quad (8)$$

3.3 像素重组模块

如图3所示,亚像素卷积层的本质是将多通道的特征图重新排列,从而完成从低分辨率张量 T^{LR} 到高分辨率张量 T^{HR} 的重构,这个过程也可以称为像素重组,即从 $H \times W \times c$ 转化为 $rH \times rW \times c/r^2$, H 和 W 分别为图像的高和宽, r 为比例因子。同理,为了在网络输入阶段将上一时刻的高分辨率输出 O_{t-1} 与低分辨率帧拼接起来,也需要对 O_{t-1} 进行像素逆重组,保证网络的输入尺寸一致,像素逆重组与像素重组过程相反,它将图像的空间特征重新排列为多通道的下采样子图像,且不会造成信息丢失。

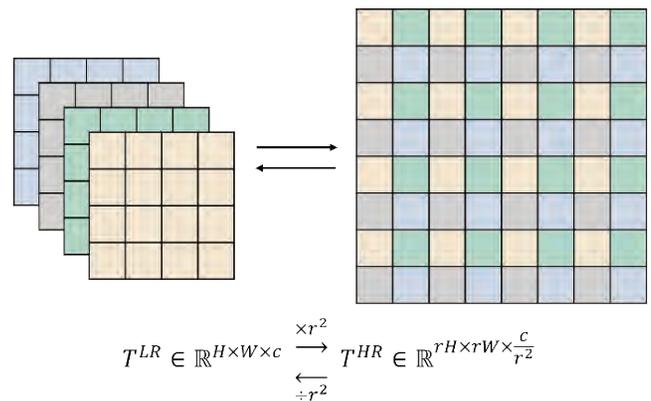


图3 像素重组模块

网络的最后将经过残差注意力模块组生成的深

层特征信息 F_i 进行亚像素卷积,并与经过上采样的低分辨率参考帧 I_i 相加,获得高分辨率输出 O_i :

$$O_i = PS(F_i) + US(I_i) \quad (9)$$

其中, $PS(\cdot)$ 表示亚像素卷积, $US(\cdot)$ 表示双线性插值上采样。

4 实验设置与结果分析

4.1 数据集与实验参数

本文采用 Vimeo-90k 数据集作为训练集,该训练集涉及大量的场景和运动,包含 64612 个 7 帧的视频段,每帧图像尺寸为 448×256 。训练时将高分辨率图像先裁剪成 256×256 的大小,再使用 $\sigma = 1.6$ 的高斯模糊和比例因子为 4 的下采样,最后获得 64×64 的低分辨率图像。另外,选取 Vid4、UDM10、SPMCS 数据集作为测试集评估模型的效果。

在训练阶段,使用 PyTorch 构建网络,设置初始学习率为 1×10^{-4} ,每 60 个 epoch 乘 0.1 直至结束,共训练 70 个 epoch, mini batch 设置为 8,总迭代次数约 560000 次。使用 Adam 优化器优化网络参数,设置 $\beta_1 = 0.9$, $\beta_2 = 0.999$,权重衰减为 5×10^{-4} 。在损失函数的选取上,Zhao 等^[15]经过实验证明,在图像复原领域 L1 损失比 L2 损失更容易得到更小的损失值,这是由于 L2 损失容易陷入局部最优点,且 L2 损失会导致图像过于平滑^[16],相比之下,使用 L1 损失更能提升模型性能,获得更好的视觉效果,因此本文选择使用 L1 损失作为损失函数,计算公式如下:

$$L1 = \frac{1}{N} \sum_{i=1}^N \|O_i - I_i\| \quad (10)$$

其中, N 为输入网络的总帧数。

模型测试阶段,采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性系数 (Structural Similarity Index Measure, SSIM) 作为客观评价指标,在测试集上逐帧计算超分辨率输出帧与原高分辨率帧在亮度 (Y) 通道上的 PSNR 和 SSIM, PSNR 值越大,说明超分辨率重建的效果越好, SSIM 越接近 1,则生成的图像与原图的结构相似度越高,视觉效果越好。

4.2 网络深度验证

在保持其他参数不变的前提下,分别设置了由 10 个和 20 个残差注意力模块构成的网络进行网络深度验证实验,在测试集上的测试结果如表 1 所示。实验证明, PSNR 和 SSIM 随着残差注意力模块的增加而增加,这是因为超分辨率的本质是学习低分辨率图像和高分辨率图像间的非线性映射,更深层的网络模型就意味着更好的表达能力,模型通过加深网络学习到更复杂的变换,从而可以拟合更复杂的特征输入。但一味地加深网络可能使 PSNR 和 SSIM 趋于饱和或者导致梯度不稳定,从而造成模型性能难以提升甚至下降。此外,加深网络带来的庞大的数据量和计算量使其对硬件设备的要求也随之增加,因此需要选择合适的网络深度进行训练。经过对比,综合考虑模型性能和训练成本等问题,本文最终选用 20 个残差注意力模块进行实验。

表 1 网络深度验证结果对比 (PSNR(dB)/SSIM)

残差注意力模块数	参数量	Vid4	UDM10	SPMCS
10	3.3×10^6	27.00/0.819	38.14/0.956	29.56/0.867
20	6.4×10^6	27.39/0.835	38.67/0.958	30.09/0.878

4.3 算法先进性验证

将本文提出的算法与传统的双三次插值 (Bicubic) 算法以及 FRVSR^[6]、D3D^[3]、RBPN^[9] 和 DUF^[4] 等多个基于深度学习的视频超分辨率算法在 Vid4 数据集上进行比较,使用 PSNR 和 SSIM 作为 4 倍超分辨率重建效果的评价指标,比较结果如表 2 所

示。根据表 2 可知,本算法在 Vid4 数据集上的 PSNR 和 SSIM 分别为 27.39dB 和 0.835,超分辨率效果总体上优于以上其他模型的效果, PSNR 有 0.08-3.94dB 的提升, SSIM 提升 0.003-0.219。此外,各模型的参数量与 PSNR 的对比关系如图 4 所示。总体来说,本文提出的模型参数量适中,与模型的性能取得了较好的平衡。

表2 各模型在 Vid4 上的测试结果对比 (PSNR(dB)/SSIM)

方法	calendar	city	foliage	walk	平均
Bicubic	20.26/0.553	24.92/0.588	23.14/0.539	25.51/0.783	23.45/0.616
RISTN	22.95/0.765	27.04/0.769	25.53/0.738	29.28/0.890	26.20/0.790
D3D	23.26/0.775	27.23/0.780	25.88/0.745	29.72/0.896	26.52/0.799
FRVSR	23.44/0.784	27.65/0.804	25.97/0.753	29.70/0.899	26.69/0.810
RBPN	23.93/0.803	27.64/0.802	26.27/0.757	30.65/0.911	27.16/0.819
DUF	24.09/0.813	28.26/0.833	26.38/0.771	30.50/0.912	27.31/0.832
OUR	24.15/0.816	28.27/0.832	26.51/0.778	30.65/0.914	27.39/0.835



图4 各模型参数量与PSNR对比关系

图5对比了不同方法在 Vid4 测试集中的 calendar 和 city 两个场景进行 4 倍超分辨率重建后的视觉效果。放大图中蓝色框区域,通过细节对比可以看出,

本算法在 calendar 中恢复的文字及纹理清晰,细节丰富,颜色过渡相比其他方法也更接近于真实图像。在 city 中,经其他方法生成的图像均有一定程度的模糊和结构失真,从细节图可以看出本文算法生成的图像中,墙面的网格结构更加清晰,能较好地恢复出建筑物的外观细节。再选取 SPMCS 和 UDM10 中的视频片段进行比较,从图 6 中 auditorium 的放大区域可以看出,相比于其他方法,本算法生成的图像中钢架的形变较少,边界清晰,墙上数字的轮廓也相对更好辨认。在 Jvc_009_001 的视频帧中,仔细观察屋檐和木门部分,D3D 和 DUF 生成的图片相对更模糊,尤其是屋檐的瓦片,与原图有较明显的区别,本算法对屋檐和木门的恢复则具有更好的视觉效果,在细节上更接近原图。

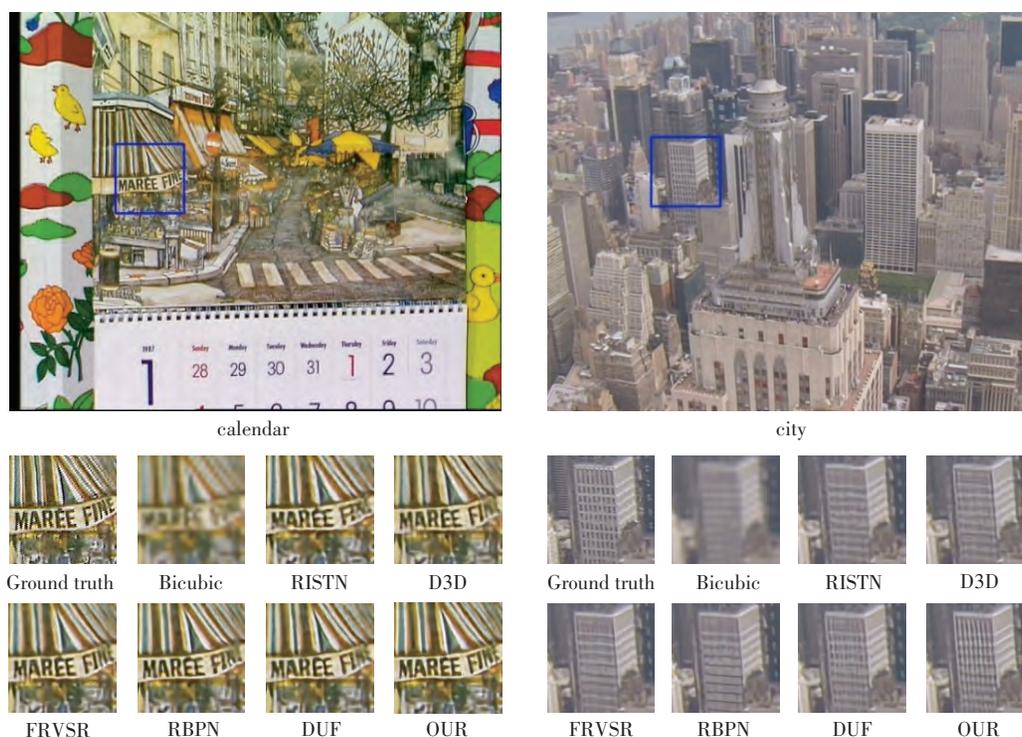


图5 各模型在 Vid4 上的重建结果对比

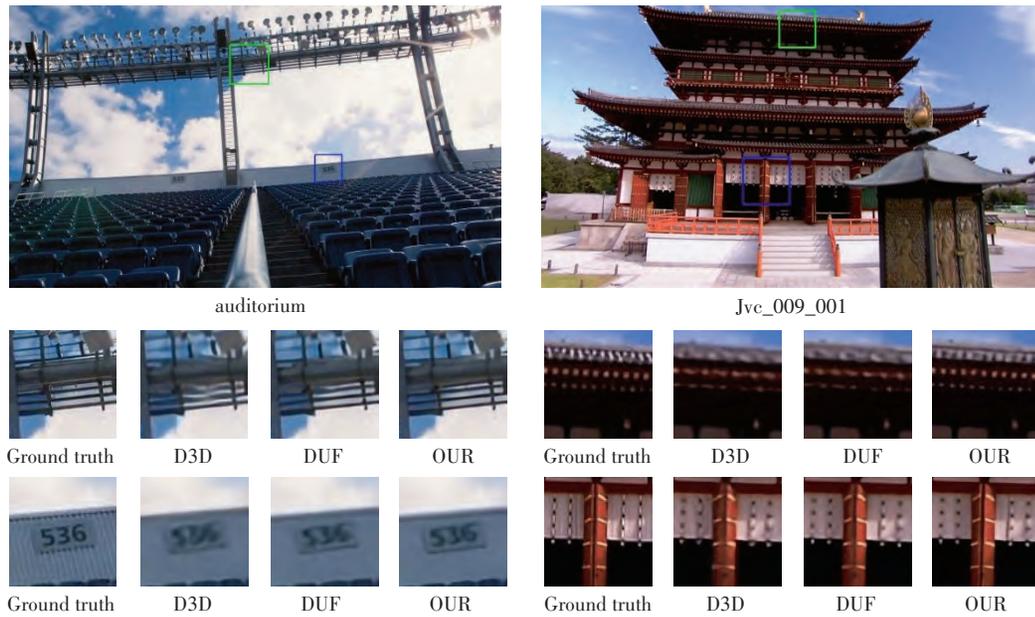


图6 各模型在SPMCS和UDM10上的重建结果对比

5 结论

本文提出的循环残差注意力网络以低分辨率视频帧以及前一时刻的输出帧和隐藏态特征作为输入,使用加入通道注意力机制的残差块进行特征提取,经过亚像素卷积提升分辨率再与上采样的参考帧相加,重建出高分辨率视频帧。通过与传统的双三次插值和其他基于深度学习的视频超分辨率算法进行对比实验,验证了本文算法可以更有效地利用帧间信息恢复更多的高频细节,减轻图像噪声,主观视觉效果更好,客观评价指标更优,但在大运动场景中的重建效果还有待加强,后续将继续研究改进。

参考文献 (References):

- [1] 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, 2015, 38 (2): 295-307.
- [2] Tian Y, Zhang Y, Fu Y, et al. TDAN: temporally-deformable alignment network for video super-resolution [C] //CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 3360-3369.
- [3] Ying X, Wang L, Wang Y, et al. Deformable 3d convolution for video super-resolution[J]. IEEE Signal Processing Letters, 2020, 27: 1500-1504.
- [4] Jo Y, Oh S W, Kang J, et al. Deep video super-resolution network using dynamic upsampling filters without explicit motion compensation[C] //IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3224-3232.
- [5] Yi P, Wang Z, Jiang K, et al. Progressive fusion video super-resolution network via exploiting non-local spatio-temporal correlations [C] //IEEE/CVF International Conference on Computer Vision, 2019: 3106-3115.
- [6] Sajjadi M S M, Vemulapalli R, Brown M. Frame-recurrent video super-resolution [C] //IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6626-6634.
- [7] Fuoli D, Gu S, Timofte R. Efficient video super-resolution through recurrent latent space propagation [C] //IEEE/CVF International Conference on Computer Vision Workshop (ICCVW), 2019: 3476-3485.
- [8] Zhu X, Li Z, Zhang X Y, et al. Residual invertible spatio-temporal network for video super-resolution [C] //33th AAAI Conference on Artificial Intelligence, 2019: 5981-5988.
- [9] Haris M, Shakhnarovich G, Ukita N. Recurrent back-projection network for video super-resolution [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 3897-3906.
- [10] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [11] Wang Q, Wu B, Zhu P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11534-11542.
- [12] 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), 2018: 294-310.
- [13] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C] //IEEE Conference on Computer Vision

- and Pattern Recognition, 2016: 770-778.
- [14] 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, 2017: 136-144.
- [15] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on Computational Imaging, 2017, 3(1): 47-57.
- [16] He X, Cheng J. Revisiting L1 loss in super-resolution: a probabilistic view and beyond[DB/OL]. arXiv: 2201.10084, 2022.

编辑:王谦

(上接第14页)

线网络的覆盖,使农村地区具备良好的网络连接和通信能力。同时积极推动数字教育在农村地区的普及,提供在线教育资源和培训机会,培养农村居民的数字技能,帮助他们适应信息时代的发展。此外,政府还应该加大对农村电子商务平台的支持,提供相关的培训和金融支持,鼓励农民通过互联网销售农产品,拓宽农村居民的收入渠道,从直接效应上也能贯彻乡村振兴的伟大方针。

参考文献(References):

- [1] 管廷全,周仪涵,周赟.智能传播系统模型及其经济学意义[J].中国传媒大学学报(自然科学版),2022,29(04): 57-64.
- [2] 党东耀,李瑜琪.智能传播研究的演进,主题与发展趋势[J].新闻战线,2022(2):103-106.
- [3] 查雅雯,孙小龙.移动互联网使用对农村居民幸福感的提升效果及政策建议[J].江苏农业科学,2022,50(19): 226-231.
- [4] 黄凯迪,陈江华.乡村振兴背景下互联网使用对农户贫困脆弱性的影响——基于CFPS数据的实证分析[J].新疆农垦经济,2022(07):21-33.
- [5] 杨红.互联网使用对农户收入的影响[D].兰州:西北师范大学,2019.
- [6] 黄嘉文.教育程度、收入水平与中国城市居民幸福感——一项基于CGSS2005的实证分析[J].社会,2013,33(05):181-203.
- [7] 李涛,史宇鹏,陈斌开.住房与幸福:幸福经济学视角下的中国城镇居民住房问题[J].经济研究,2011,46(09):69-82+160.
- [8] 胡晓鹏,李昕.养老保险提升中国农村居民幸福感的实证研究[J].上海经济研究,2020(07):66-80.
- [9] 冷晨昕,祝仲坤.互联网对农村居民的幸福效应研究[J].南方经济,2018(08):107-127.
- [10] 雷晓康,陈泽鹏.促进还是抑制:互联网使用对老年人主观幸福感的影响研究[J/OL].海南大学学报(人文社会科学版),2023:1-11[2023-06-21].https://doi.org/10.15886/j.cnki.hnus.202109.2211.
- [11] 许海平,黄雅雯,刘玲.互联网使用、疏离感与农村居民幸福感——基于CGSS的微观经验证据[J].海南大学学报(人文社会科学版),2021,39(06):86-94.
- [12] 甘小立,汪前元.互联网使用能提高农村居民幸福感吗?——基于信息获取视角的一个实证检验[J].产经评论,2021,12(04):129-142.
- [13] 李艳燕.互联网使用视角下城乡居民文化消费差异研究[J].商业经济研究,2021(24):72-76.
- [14] 蔡蔚萍.个体受教育水平与被剩下的概率——基于CGSS2015的实证研究[J].湖北社会科学,2019(07): 145-154.
- [15] 李磊,刘鹏程,孙嫒.男性与女性,谁更幸福[J].统计研究,2017,34(07):82-93.
- [16] 吴天昊.基本医疗保险对居民幸福感的影响研究[J].市场周刊,2022,35(11):5-8.

编辑:赵志军