

基于可逆网络的单一图像超分辨率

陈国俊^{1,2}, 羊洁明³, 葛洪伟³

1. 无锡太湖学院物联网工程学院, 江苏 无锡 214064;
2. 江苏省物联网应用技术重点实验室(无锡太湖学院), 江苏 无锡 214064;
3. 江南大学人工智能与计算机科学学院, 江苏 无锡 214122

通信作者: 羊洁明, 572785530@qq.com 收稿/录用/修回: 2020-10-09/2021-01-15/2021-04-25

摘要

本文提出了一种基于可逆神经网络的单一图像超分辨率算法. 最近提出的基于深度神经网络的单一图像超分辨率模型都是利用生成的超分辨率图像和对应的高分辨率图像之间的差异定义目标函数以及更新模型参数, 这些模型仅利用了超分辨率正向过程中高分辨率图像对于低分辨率图像的依赖, 并没有建立低分辨率图像与高分辨率图像之间的相互依赖. 本文提出的超分辨可逆网络利用具有可逆结构的神经网络建立低分辨率图像与高分辨率图像之间的相互依赖, 它能够将低分辨率图像和高分辨率图像分别投影到相互的图像空间之中, 然后利用两个投影的误差反馈来优化模型在低分辨率和高分辨率图像空间的相互映射, 基于模型的可逆特性, 实现从正向和逆向两个过程分别对超分辨率过程的优化. 通过实验, 提出的模型在超分辨率基准数据集上取得了优异的结果.

关键词

深度学习
图像处理
超分辨率
可逆网络

中图法分类号: TP391

文献标识码: A

Single Image Super-resolution Based on Reversible Network

CHEN Guojun^{1,2}, YANG Jieming³, GE Hongwei³

1. College of Computer Internet of Things Engineering, Taihu University of Wuxi, Wuxi 214064, China;
2. Jiangsu Key Construction Laboratory of IoT Application Technology (Taihu University of Wuxi), Wuxi 214064, China;
3. School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, China

Abstract

A single image super-resolution algorithm based on reversible network is proposed in this paper. Many models based on deep neural network (DNN) are proposed recently to solve the problem of single image super-resolution. In these models, the difference between the generated super-resolution image and the corresponding high-resolution image used to define the objective function and update the model parameters. These methods only take advantage of the dependence of high resolution image on low resolution image, and do not establish the inter-dependence between them. In this paper, we propose a super-resolution reversible network (SRRRevnet) model based on reversible network to establish the Mutual mapping between the high-resolution image and low-resolution image. This model maps low resolution image and high resolution image to each other's resolution space respectively, and then use the error feedback to optimize those two opposite process. because the model is reversible, this model can optimize the process of super-resolution from forward and backward respectively. To our knowledge, this paper is the first to use the neural network with reversible structure to solve the problem of single image super-resolution. Through experiments, our model has achieved excellent results on the super-resolution benchmark datasets.

Keywords

deep learning;
image process;
super-resolution;
reversible network

0 引言

最近几十年来, 图像超分辨率, 尤其是单一图像超分辨率(single image super-resolution, SISR)获得了越来越多

的研究和关注. SISR的目标是在低分辨率图像和高分辨率图像之间建立一种映射, 并通过输入的低分辨率图像生成超分辨率图像. SISR被广泛应用于医疗成像、卫星成像、视频监控、数字娱乐及计算机视觉模式识别中. 目前超分

分辨率的方法主要包括基于插值、基于重建、基于学习的方法。常见的插值方法有双线性插值、双三次插值方法等, 但是通过插值得到的重建图像容易产生模糊、锯齿现象, 并且缺少纹理细节。基于重建的方法是利用低分辨率图像作为约束的前提下, 结合图像的先验知识进行重建还原, 例如迭代反向投影法 (IBP)^[1]、凸集投影法 (POCS)^[2]。而基于学习的方法是通过提取高分辨率图像和低分辨率图像的特征学习两者之间的映射关系来对高分辨率图像进行重建, 这也是目前比较主流的方法。研究者们提出了很多的基于学习的重建方法, 例如邻域嵌入方法^[3-4]、概率图模型^[5-6]、线性及非线性回归^[7-9]、稀疏编码^[10-11]及随机森林^[12]。

近些年, 随着深度神经网络的飞速发展, 越来越多的研究人员开始使用各种深度神经网络结构来解决超分辨率问题。相对于其他传统的超分辨率方法, 具有深度神经网络结构的超分辨率重建方法能够取得更高的 PSNR (峰值信噪比) 和 SSIM (结构相似性)^[13] 值。SRCNN^[14] (super resolution with convolution neural network) 提出利用深度卷积网络来解决超分辨率重建问题, 其设计了由 3 个卷积核大小不同的卷积层构成的网络, 将三层卷积网络分别解释为 3 个步骤: 补丁提取、非线性映射、图像重建。在图像输入到 SRCNN 中去之前, 会经过一个基于插值的超分辨率过程将其尺寸放大到预期尺寸。FSRCNN^[15] (fast super resolution with convolution neural network) 在 SRCNN 网络模型的最后端添加了一个反卷积网络结构从而避免了扩张图像尺寸的预处理, 提升了网络传播效率。ESPCN^[16] (Efficient Sub-Pixel Convolutional Neural network) 提出了一种新的扩张图像尺寸的结构: 亚像素卷积层, 通过减少图像的通道数增加图像的尺寸。VDSR (Super Resolution with Very Deep convolutional networks)^[17] 通过跳跃连接学习超分辨率图像与高分辨率图像之间的残差。DRCN (super resolution with Deeply-Recursive Convolutional Network)^[18] 将跳跃连接和递归神经网络相结合构成了 SRCNN^[14] 中的非线性映射模块。SRGAN (super resolution with generative adversarial networks)^[19] 利用残差神经网络来设计超分辨网络结构, 通过结合对抗学习和迁移学习取得了杰出的感知表现。

上述基于深度神经网络的方法都是将低分辨率图像投影到高分辨率图像空间来估计一个超分辨率图像, 然后利用超分辨率图像和高分辨率图像之间的差异来构建损失函数。这些方法没有利用低分辨率图像和高分辨率图像之间的相互依赖, 导致了其超分辨率效果较差。在本文中, 提出利用具有可逆结构的神经网络建立超分辨率模型。将低分辨率图像从模型的一端输入, 生成超分辨率重建图像。将高分辨率图像从模型的另一端输入, 生成低分辨率重建图像, 然后分别利用得到的超分辨率重建图像和低分辨率重建图像来设计损失函数作为优化目标。基于可逆网络的可逆特性, 这两个分别在低分辨率图像空间和高分辨率图像空间的损失函数都能够优化超分辨率重建过程。通过实验表明, 本文提出的模型针对超分辨率重建问题能够在基准数据集上取得更好的 PSNR 和 SSIM 值。

1 可逆网络

可逆网络是具有可逆结构的网络。对于可逆网络来说, 输入数据经正向传播得到输出后, 可以通过逆向传播由输出以相反的过程得到最初的输入数据, 在这个过程中输入数据没有任何信息的丢失。

较早前, 就有论文应用神经网络中的某些可逆特性, 例如 Maclaurin 等^[20] 利用随机梯度下降的可逆性质对超参数进行微调。近些年, 又出现了很多研究与利用可逆网络的论文。NICE (non-linear independent components estimation)^[21] 和 RNVP (real-valued non-volume preserving)^[22] 将可逆网络与最大似然估计相结合提出了基于流的生成模型, 利用网络的可逆特性, 通过最大化生成过程的逆过程得到的潜变量的对数似然函数值来优化模型生成能力与拟合真实数据分布的能力。NICE 提出了一种耦合层的结构来实现可逆。在加性耦合层中, 每一层的输入从通道或者空间上被分成两个部分 x_1 和 x_2 , 通过下面公式计算输出:

$$y_1 = x_1 \quad (1)$$

$$y_2 = x_2 + F(x_1) \quad (2)$$

将 y_1 和 y_2 拼接得到输出 y 。当网络逆向传播时, 将该层输出 y 以与拼接相反的方式分成两个部分 y_1 和 y_2 , 通过下面公式得到输入 x :

$$x_1 = y_1 \quad (3)$$

$$x_2 = y_2 - F(y_1) \quad (4)$$

在 RNVP 中, 首先引入了卷积操作, 为了保证卷积操作所需的局部相关性, 只能对图像进行通道处或空间棋盘式分割。其次, RNVP 提出了更为一般的仿射耦合层。在仿射耦合层中, 在每一层输入 x 被分割成两部分 x_1 和 x_2 后, 通过式 (5)、式 (6) 得到输出 y :

$$y_1 = x_1 \quad (5)$$

$$y_2 = x_2 \otimes \exp(F(x_1)) + G(x_1) \quad (6)$$

在逆向传播时, 将 y 分割成 y_1 和 y_2 , 通过式 (7)、式 (8) 得到输入 x :

$$x_1 = y_1 \quad (7)$$

$$x_2 = (y_2 - G(y_1)) / \exp(F(x_1)) \quad (8)$$

其中, \otimes 和 $/$ 分别代表了 Hadamard 乘积或逐元素乘积及它们的逆过程。NICE 和 RNVP 中为了得到不平凡的变化, 使用了交错和随机两种方式打乱耦合顺序, Glow^[23] 中提出了一种可逆 1×1 卷积打乱耦合顺序, 并实验性地证明了可逆 1×1 卷积相比交错打乱和随机打乱能得到更好的结果。除此外, Glow 还采用激活归一化 (activation normalization, act-norm) 替代了批归一化 (batch normalization, batch-norm)^[24], 取得了更好的结果。flow-GAN^[25] 将 GAN^[26] 和基于流的生成模型相结合, 让生成图像能够拟合真实数据的分布, 同时在视觉上取得更好的结果。

2 基于可逆网络的单一图像超分辨率

本文的主要思想是通过建立一个可逆网络实现低分辨率图像空间和高分辨率图像空间之间的相互映射, 通过这两个映射的结果与真实图像之间的差异来优化这个双射过

程. 对于低分辨率图像空间映射到高分辨率图像空间这个正向映射的优化能够直接提升超分辨率的效果. 基于网络的可逆特性, 优化高分辨率图像空间到低分辨率图像空间的逆向映射也有助于提升超分辨率的效果.

训练时, 将低分辨率图像 I^{LR} 从网络的一端进行输入, 经过正向传播得到了超分辨率图像 I^{SR} , 然后将高分辨率图像 I^{HR} 从网络的另一端进行输入, 经过逆向传播得到了低分辨率重建图像 I_{re}^{LR} . 利用 I^{SR} 与 I^{HR} 之间以及 I^{LR} 与 I_{re}^{LR} 之间的差异设计损失函数, 然后将两个损失函数加权作为优化目标来训练本文模型.

对于有 C 通道数的低分辨率的图像 I^{LR} 和低分辨率重构图像 I_{re}^{LR} , 分别将其表示为尺寸为 $W \times H \times C$ 的实值张量, 对于高分辨的图像 I^{HR} 、 I^{SR} 则分别表示为尺寸为 $rW \times rH \times C$ 的实值张量, 其中 r 为大于 1 的正整数. 本方法的整体流程如图 1 所示.

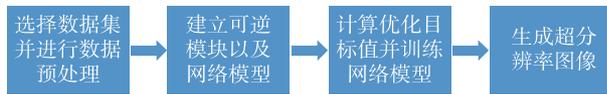


图 1 本文所提方法的流程图

Fig.1 The flow chart of the proposed method

2.1 预处理和尺寸调整操作

将低分辨率图像 I^{LR} 输入模型之前, 先利用一个双三次差值将其尺寸 $W \times H \times C$ 扩张到期望尺寸 $rW \times rH \times C$, 然后通过一个挤压操作 (squeeze operation)^[17] 将其转换成一个尺寸为 $\frac{r}{2}W \times \frac{r}{2}H \times 4C$ 的张量. 挤压操作通过等距离的采样来降低分辨率并提高数据的通道量. 在高分辨率图像 I^{HR} 输入模型之前, 只需要对其进行一个挤压操作将其尺寸由 $rW \times rH \times C$ 减小至 $\frac{r}{2}W \times \frac{r}{2}H \times 4C$. 对于模型的输出超分辨率图像 I^{SR} 和低分辨率重建图像 I_{re}^{LR} , 都对其执行一个解压操作 (unsqueeze operation)^[17] 将其尺寸由 $\frac{r}{2}W \times \frac{r}{2}H \times 4C$ 增加至 $rW \times rH \times C$. 解压操作通过将数据中多个

通道中的数值等距地放置在单一通道中来降低数据通道量, 并提高数据的分辨率. 图 2 和图 3 中展示了相应的操作.

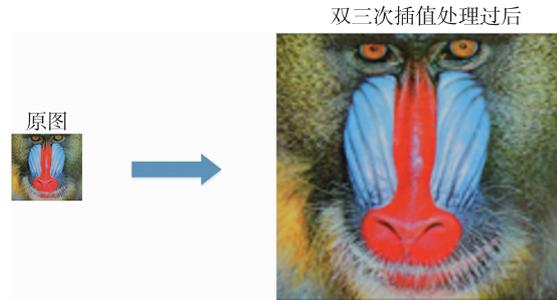


图 2 基于双三次插值的预处理

Fig.2 The preprocess based on bicubic interpolation

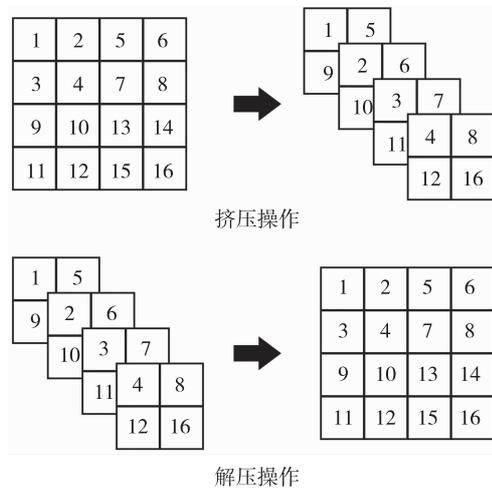


图 3 数据的挤压与解压操作

Fig.3 The squeeze and unsqueeze operation of data

2.2 网络结构

本文所提出的超分辨率可逆网络由 K 个可逆模块 (revnet block) 组成, 除了数据的预处理以及改变输入和输出数据尺寸的挤压和解压操作, 整个网络的结构和数据流程如图 4 所示.

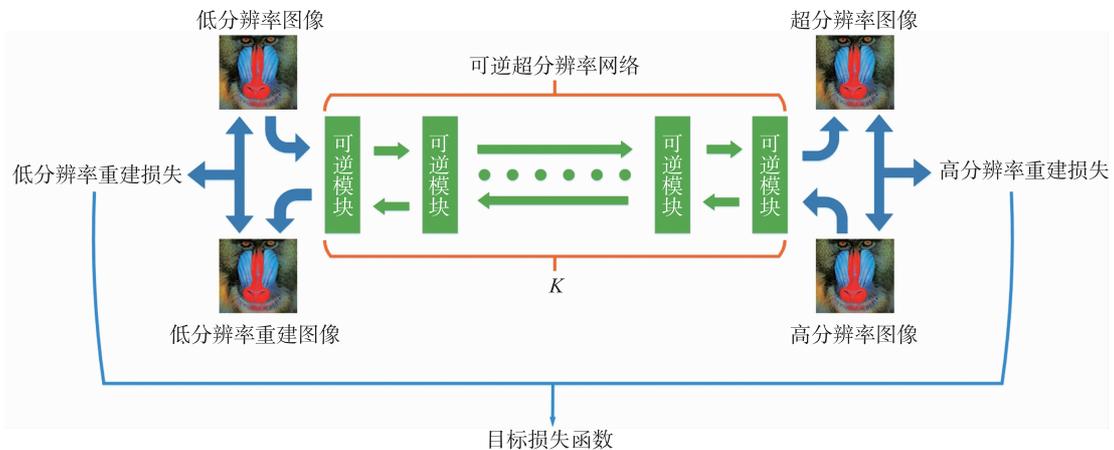


图 4 模型结构和数据流向

Fig.4 The structure of model and data flow

如图 4 可见, 提出的算法中的整个网络模型由 K 个可逆模块组成. 在计算目标函数时, 首先将低分辨率图像 I^L 输入模型的左端生成超分辨率图像 I^{SR} , 然后将对应的高分辨率图像 I^{HR} 输入模型的右端生成低分辨率重建图像 I_{re}^{LR} . 其次, 分别利用 I^L 与 I_{re}^{LR} 以及 I^{HR} 与 I^{SR} 之间差异来构建两个图像空间的损失函数, 利用这两个损失函数的加权来作为优化目标. 由于采用了全卷积结构, 在重建高分辨率图像时, 可以将任意尺寸的低分辨率图像作为输入.

2.3 可逆模块

本文设计了可逆模块来实现整个模型的可逆. 可逆模块包括分别在两端的 1×1 可逆卷积层和中间的仿射耦合层. 相较于 Glow 中的 flow 模块, 本文的可逆模块少了激活归一化层, 这是因为在实验中发现, 模型的近似计算导致的微小误差在多次经过激活归一化层的缩放和移动之后会变得十分巨大, 导致模型不可逆. 除此外, 为了更深入地打乱耦合顺序, 在可逆模块的末端也加上了一个 1×1 可逆卷积层. 最终形成了如图 5 所示的可逆模块.

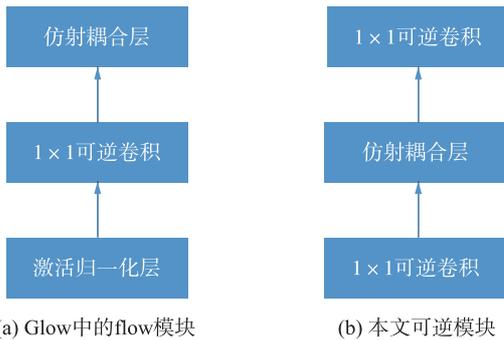


图 5 Glow 中的 flow 模块和本文可逆模块

Fig.5 The flow block in Glow and the proposed reversible block

2.4 仿射耦合层

借鉴并改进了 RNVP 中提出的仿射耦合层作为本文可逆块的核心. 在输入向量 x 输入到仿射耦合层之前, 将其从通道处分成两个部分 x_1 、 x_2 , 然后通过式 (9)、式 (10) 得到输出:

$$y_1 = x_1 \quad (9)$$

$$y_2 = x_2 \cdot \exp(F(x_1)) + G(x_1) \quad (10)$$

这里, 与 RNVP 不同, \cdot 只表示了逐元素的相乘. $F(x_1)$ 和 $G(x_1)$ 表示没有任何限制的非线性映射的耦合函数. 得到输出 y_1 和 y_2 后, 将其从通道处进行拼接得到最终输出 y . 仿射耦合层的逆过程公式如下:

$$x'_1 = y'_1 \quad (11)$$

$$x'_2 = (y'_2 - G(y'_1)) / \exp(F(y'_1)) \quad (12)$$

这里, $/$ 表示了逐元素的相除, 和正向传播过程相同, 通过将 x'_1 和 x'_2 在通道处进行合并得到最终输出 x' . 图 6 展示了整个正向和反向传播过程.

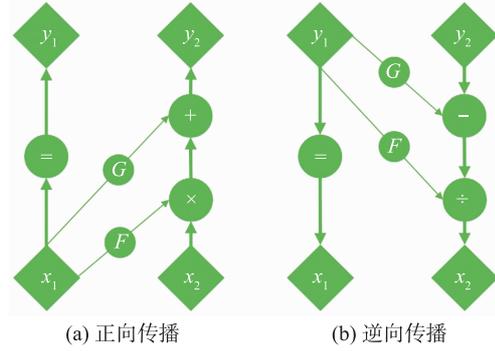


图 6 仿射耦合层正向传播过程和逆向传播过程

Fig.6 The forward-propagation and the reverse-propagation of the affine coupling layer

2.5 1×1 可逆卷积层

在本文的网络结构中采用了 1×1 可逆卷积层作为置换操作来打乱向量通道顺序, 以此来确保输入向量的每一部分都能经过仿射耦合函数. 1×1 可逆卷积层的权重矩阵 W_{deconv} 拥有 1×1 的卷积核大小, 输入和输出的通道数相同. 对于一个尺寸为 $W \times H \times C$ 的输入向量, 1×1 可逆卷积层的权重矩阵尺寸为 $1 \times 1 \times C \times C$, 前两个维度表示了卷积核尺寸, 后两个维度分别表示了输入和输出向张量的通道数, 然后计算该权重矩阵的逆矩阵作为卷积操作的权重矩阵来实现 1×1 可逆卷积层的逆过程. 在正向传播过程中, 数据输入到 1×1 可逆卷积层中, 通过权重尺寸为 $1 \times 1 \times C \times C$ 的卷积操作得到输出结果. 在逆过程中, 将输入通过权重为正向过程中权重的逆矩阵的卷积操作得到输出结果. 为了方便计算变化的雅可比矩阵的行列式, Glow 利用 LU (Lower triangular matrices and Upper triangular matrices) 分解来直接对 1×1 可逆卷积层的权重矩阵进行参数化:

$$W = PL(U + \text{diag}(s)) \quad (13)$$

其中, P 是一个置换矩阵, L 是一个对角线元素为 1 的下三角矩阵, U 是一个对角线元素为 0 的上三角矩阵, s 是一个向量.

如果采用 LU 分解对 1×1 可逆卷积层的权重矩阵 W 进行初始化, 在其逆过程中, 需要直接计算 P 、 L 以及 $U + \text{diag}(s)$ 的逆矩阵, 这增加了模型的计算量. 由于在本文模型训练时不需要计算变换的雅可比矩阵的行列式, 以及为了容易计算权重矩阵的逆矩阵, 本文提出利用奇异值分解的方法来对 W 进行参数化:

$$W = USV^T \quad (14)$$

其中, U 和 V^T 分别表示正交矩阵, S 表示了对角矩阵. 在参数化过程中, 首先初始化一个尺寸为 $C \times C$ 的随机矩阵 W , 然后对 W 执行奇异值分解计算 U 、 S 以及 V^T . 与 LU 分解不同, 在 1×1 卷积层的逆过程中, 不需要直接计算 U 、 S 及 V^T 的逆矩阵. 对于 U 和 V^T , 直接对其进行转置操作就能得到其逆矩阵 U^T 和 V . 对于 S , 只需要对其每个对角线元素求倒数就能得到其逆矩阵 S^{-1} , 然后就能够通过式 (15) 得到 1×1 可逆卷积层的逆过程的整个权重矩阵 W^{-1} :

$$W^{-1} = VS^{-1}U^T \quad (15)$$

2.6 损失函数

本文所提出的模型的损失函数由两部分组成, 一个是通过高分辨率图像 I^{HR} 和超分辨率图像 I^{SR} 之间的逐元素均方误差定义的高分辨率重建损失函数:

$$\text{loss}_{re}^{HR} = \frac{1}{r^2 WH} \sum_{x=1}^r \sum_{y=1}^H (I_{x,y}^{HR} - I_{x,y}^{SR})^2 \quad (16)$$

另一个是通过低分辨率图像 I^{LR} 和低分辨率重建图像 I_{re}^{LR} 之间的逐元素均方误差定义的低分辨率重建损失函数:

$$\text{loss}_{re}^{LR} = \frac{1}{WH} \sum_{x=1}^W \sum_{y=1}^H (I_{x,y}^{LR} - I_{(re)x,y}^{LR})^2 \quad (17)$$

其中, r 表示超分辨率因子, W 、 H 表示输入向量的宽度和高度.

将高分辨率重建损失函数和低分辨率重建损失函数的加权和作为优化目标来训练本文模型:

$$\text{loss} = \lambda_1 \text{loss}_{re}^{HR} + \lambda_2 \text{loss}_{re}^{LR} \quad (18)$$

3 实验

3.1 实验设置

在 3 个应用广泛的基准数据集 Set5^[27]、Set14^[28]、BSD100^[29] 上进行测试实验, 报告中的 PSNR 和 SSIM 是在 Y 通道上通过 python 库 skimage 进行计算. 本文将提出的

表 1 在 Set5 数据集上的定量对比

Tab.1 The quantitative comparison on Set5

set5	nearest	bicubic	glasner	ScSR	SRCNN	Kim	SelfExSR	VPGF	SRRevnet(ours)
PSNR	26.489 7	28.579 9	28.926 9	29.195 8	30.123 0	30.123 8	30.374 0	30.510 0	30.791 8
SSIM	0.764 8	0.821 8	0.833 3	0.839 3	0.862 6	0.866 1	0.873 2	0.863 2	0.883 2

表 2 在 Set14 数据集上的定量对比

Tab.2 The quantitative comparison on Set14

Set14	nearest	bicubic	glasner	ScSR	SRCNN	Kim	SelfExSR	VPGF	SRRevnet(ours)
PSNR	24.493 3	25.789 5	26.199 4	25.763 7	26.354 9	25.239 1	26.768 4	27.23	28.13
SSIM	0.679 7	0.719 5	0.734 9	0.740 5	0.756 7	0.761 0	0.770 46	0.748 6	0.789 5

表 3 在 BSD100 数据集上的定量对比

Tab.3 The quantitative comparison on BSD100

BSD100	nearest	bicubic	glasner	ScSR	SRCNN	Kim	SelfExSR	VPGF	SRRevnet(ours)
PSNR	25.092 6	25.991 8	26.191 9	26.621 5	26.706 5	26.725 7	26.878 1	27.01	27.690 2
SSIM	0.653 4	0.683 7	0.692 2	0.716 0	0.719 6	0.721 4	0.729 8	0.710 5	0.737 9

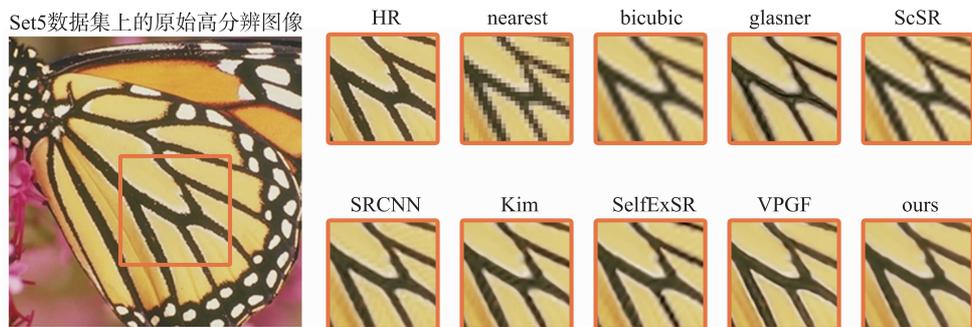


图 7 在 Set5 数据集上的视觉效果对比

Fig.7 The visual effect comparison on Set5

算法与最近邻插值、双三次差值、ScSR^[10]、Kim^[30]、Glasner^[31]、SRCNN^[14]、转换自范式的单一图像超分辨率方法 (SelfExSR)^[32] 和变为生成框架的单一图像超分辨率方法 (VPGF)^[33] 等算法进行了比较.

在整个实验中, 采用的超分辨率因子为 $4 \times$, 即 r 为 4. 所使用的训练图片来自于 RAISE 数据集, 该数据集包括了 8 156 对低分辨率图片以及其对应的高分辨率图片. 其中低分辨率图片是由对应的高分辨率图片经过一个缩放因子为 $4 \times$ 的双三次插值缩放得到. 在训练的时候, 从不同的 16 张图片各截取一个尺寸为 144×144 的子图片作为批数据, 采用 $\beta_1 = 0.9$ 的 Adam 优化器, 学习率为 0.000 1, 迭代 50 万次, 并且在 25 万次后将学习率降到 0.000 01. 目标损失函数中的权重因子 λ_1 和 λ_2 都是 1.

本文的模型包括了 8 个在 2.3 节所介绍的可逆模块. 和 Glow 相同, 耦合函数 F 和 G 定义为 3 个卷积层, 其中两个隐含层采用 Relu 激活函数, 输出通道数为 1 024, 最后一层不使用激活函数. 第一个和第三个卷积层的卷积核为 3×3 , 中间的卷积层的卷积核为 1×1 .

3.2 实验结果

表 1 ~ 表 3 展示了本文中提出的方法的超分辨率结果与其他超分辨率算法的定量比较. 图 7 ~ 图 9 展示了本文中提出的方法与其他超分辨率算法的定性比较.

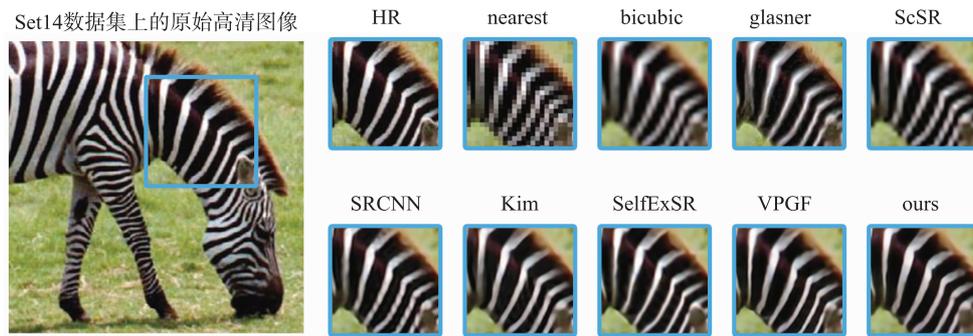


图8 在 Set14 数据集上的视觉效果对比

Fig.8 The visual effect comparison on Set14

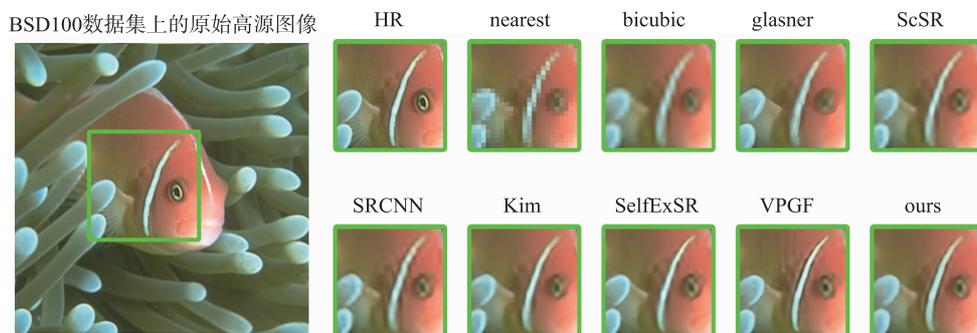


图9 在 BSD100 数据集上的视觉效果对比

Fig.9 The visual effect comparison on BSD100

3.3 实验结果分析

定量比较时,由表1~表3可以看出,相对于其他超分辨率方法,本文所提出的超分辨率方法就 PSNR 和 SSIM 而言,在数据集 Set5、Set14 和 BSD100 上都取得了最好的结果.其中,在数据集 Set5 中,相对于性能第二的方法,本文提出的方法在 PSNR 和 SSIM 上分别提高了 0.281 8 和 0.02.在数据集 Set14 中,相对于性能第二的方法,本文提出的方法在 PSNR 和 SSIM 上分别提高了 0.9 和 0.040 9.在数据集 BSD100 中,相对于性能第二的方法,本文提出的方法在 PSNR 和 SSIM 上分别提高了 0.68 和 0.027 4.

定性比较时,图7给出了不同超分辨率方法在 Set5 中图像上的重建图像块.相比于高分辨率图像,方法 nearest 得到的重建图像具有严重的锯齿状纹理,方法 bicubic、ScSR、SRCNN 和 SelfExSR 得到的重建图像在蝴蝶翅膀的黑色纹理周围具有不同程度的黑色伪影,会影响图像块的视觉效果.方法 glasner、Kim、VPGF 以及本文提出的方法都没有上述的锯齿状纹理和黑色伪影.但是方法 glasner 生成的重建图像中蝴蝶翅膀上的黑色纹理较细,与高分辨率图像不符,而方法 Kim 和 VPGF 生成的重建图像在左下角的黑色纹理上存在少量着高分辨率图像中所没有的白色杂纹.而本文提出的方法所得到的重建图像与高分辨率图像最接近.

图8给出了不同超分辨率方法在 Set14 中图像上的重建图像块.方法 nearest 依旧生成了具有严重锯齿状纹理的图像.方法 bicubic、ScSR 和 SRCNN 得到的重建图像中,斑

马的白色纹理上都出现了黑色条纹伪影.方法 glasner 生成的重建图像中,斑马的第一个白色条纹出现了高分辨率图像中所没有的分叉.相对而言,方法 Kim、SelfExSR、VPGF 和本文提出的方法所生成的重建图像都具有较好的视觉效果.

图9给出了不同超分辨率方法在 BSD100 中图像上的重建图像块.方法 nearest 生成的重建图像依然具有严重的锯齿状纹理.方法 bicubic、glasner、ScSR 和 SRCNN 生成的重建图像中,鱼头的白色条纹上都出现了不同程度的黑色条纹状伪影.方法 VPGF 生成的重建图像在鱼头部左边出现了高分辨率图像中所没有的条纹状伪影.相对而言,方法 Kim、SelfExSR 和本文提出的方法所生成的重建图像具有更清晰的纹理,还原出了更多的细节以及具有最接近原始高分辨率图像的视觉效果.

由定量和定性两方面的比较可以看出,本文所提出的方法具有优越的超分辨率性能.

4 结论

本文提出了一个基于可逆网络的超分辨率模型来解决目前基于深度神经网络的超分辨率模型没有利用低分辨率图像与高分辨率图像之间的相互依赖的问题.利用可逆网络建立模型,将低分辨率图像和高分辨率图像输入到网络模型中得到超分辨率图像和低分辨率重建图像,然后利用两个重建图像和真实图像的差异设计两个图像域的损失函数,将这两个损失函数进行加权得到目标损失函数.通过

优化目标损失函数强化模型在低分辨率图像空间以及高分辨率图像空间的重建能力, 基于模型的可逆特性, 超分辨率过程得到了来自正向与逆向的分别优化. 本文就超分辨率问题, 对 Glow 中的 flow 模块进行改进, 设计了构成可逆网络的可逆模块, 解决了直接应用 flow 模块导致的模型不可逆问题. 本文针对 flow 与超分辨率可逆网络训练方式的

不同, 对 Glow 中 1×1 可逆卷积的权重矩阵初始化方式进行改进, 提出了基于奇异值分解的权重矩阵初始化, 提升了网络逆向传播过程中计算 1×1 可逆卷积权重矩阵逆矩阵的速度. 本文实现了将可逆网络应用到图像超分辨率领域. 通过实验, 证实了基于可逆网络的单一图像超分辨率模型具有优越性能.

参考文献

- [1] Irani M, Peleg S. Improving resolution by image registration[J]. CVGIP: Graphical Models and Image Processing, 1991, 53(3): 231–239.
- [2] Stark H, Oskoui P. High-resolution image recovery from image plane arrays, using convex projections[J]. Journal of the Optical Society of America A Optics & Image Science, 1989, 6(11): 1715–1726.
- [3] Chang H, Yeung D Y, Xiong Y. Super-resolution through neighbor embedding[C]//IEEE Computer Society Conference on Computer Vision & Pattern Recognition. Piscataway, USA: IEEE, 2004: 275–282.
- [4] Gao X B, Zhang K B, Tao D C, et al. Image super-resolution with sparse neighbor embedding[J]. IEEE Transactions on Image Processing, 2012, 21(7): 3194–3205.
- [5] Freeman W T, Pasztor E C, Carmichael O T. Learning low-level vision[J]. International Journal of Computer Vision, 2000, 40(1): 25–47.
- [6] Polatkin G, Zhou M, Carin L, et al. A Bayesian nonparametric approach to image super-resolution[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 37(2): 346–358.
- [7] Timofte R, De Smet V, Van Gool L. A+: Adjusted anchored neighborhood regression for fast super-resolution[C]//Asian Conference on Computer Vision. Berlin, Germany: Springer, 2014: 111–126.
- [8] 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.
- [9] Wang H J, Gao X B, Zhang K B, et al. Single-image super-resolution using active-sampling Gaussian process regression[J]. IEEE Transactions on Image Processing, 2015, 25(2): 935–948.
- [10] Yang J C, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. IEEE Transactions on Image Processing, 2010, 19(11): 2861–2873.
- [11] He L, Qi H, Zaretski R. Beta process joint dictionary learning for coupled feature spaces with application to single image super-resolution[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2013: 345–352.
- [12] Schuler S, Leistner C, Bischof H. Fast and accurate image upscaling with super-resolution forests[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2015: 3791–3799.
- [13] Wang Z, Bovik A C, Sheikh H, et al. Image quality assessment: From error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600–612.
- [14] Dong C, Chen C L, He K, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 38(2): 295–307.
- [15] Dong C, Chen C L, Tang X. Accelerating the super-resolution convolutional neural network[C]//European Conference on Computer Vision. Berlin, Germany: Springer, 2016: 391–407.
- [16] Shi W, Caballero J, Huszar F, et al. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network[C]//IEEE Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2016: 1874–1883.
- [17] Kim J, Lee J K, Lee K M. Accurate image super-resolution using very deep convolutional networks[C]//IEEE Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2016: 1646–1654.
- [18] Kim J, Lee J K, Lee K M. Deeply-recursive convolutional network for image super-resolution[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2015: 1637–1645.
- [19] Ledig C, Wang Z, Shi W, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//IEEE Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2017: 105–114.
- [20] Maclaurin D, Duvenaud D, Adams R. Gradient-based hyperparameter optimization through reversible learning[C]//International Conference on Machine Learning. Berlin, Germany: Springer, 2015: 2113–2122.
- [21] Dinh L, Krueger D, Bengio Y. Nice: Non-linear independent components estimation[EB/OL]. (2015–04–10)[2019–12–15]. <https://arxiv.org/abs/1410.8516>.
- [22] Dinh L, Sohl-Dickstein J, Bengio S. Density estimation using real-NVP[EB/OL]. (2017–02–27)[2019–12–20]. <https://arxiv.org/abs/1605.08803>.
- [23] Kingma D P, Dhariwal P. Glow: Generative flow with invertible 1×1 convolutions[C]//Advances in Neural Information Processing Systems. Red Hook, USA: Curran Associates, Inc., 2018: 10215–10224.

- eration, *Transmission & Distribution*, 2019, 13(8): 1277 – 1286.
- [15] Corradini M L, Cristofaro A. Robust detection and reconstruction of state and sensor attacks for cyber-physical systems using sliding modes[J]. *IET Control Theory and Applications*, 2017, 11(11): 1756 – 1766.
- [16] Ye L, Zhu F L, Zhang J. Sensor attack detection and isolation based on sliding mode observer for cyber-physical systems[J]. *International Journal of Adaptive Control and Signal Processing*, 2020, 34(4): 469 – 483.
- [17] 汪慕峰, 胥布工, 陈立定. 周期拒绝服务干扰攻击下信息物理系统的 H_∞ 控制[J]. *浙江大学学报*, 2019, 53(11): 2146 – 2153.
Wang M F, Xu B G, Chen L D. H_∞ control for cyber-physical system under periodic denial-of-service jamming attack[J]. *Journal of Zhejiang University*, 2019, 53(11): 2146 – 2153.
- [18] Luo X Y, Wang X Y, Zhang M Y, et al. Distributed detection and isolation of bias injection attack in smart energy grid via interval observer[J]. *Applied Energy*, 2019, 256: 113703.
- [19] Guo S H, Zhu F L, Xu L Y. Unknown input observer design for Takagi-Sugeno fuzzy Stochastic system[J]. *International Journal of Control, Automation and Systems*, 2015, 13(4): 1003 – 1009.
- [20] 郭胜辉, 朱芳来. 基于 LMI 的 H_∞ 未知输入观测器设计[J]. *同济大学学报(自然科学版)*, 2014, 42(9): 1421 – 1425.
Guo S H, Zhu F L. H_∞ Unknown input observer design based LMI[J]. *Journal of Tongji University (Nature Science)*, 2014, 42(9): 1421 – 1425.
- [21] 胡志坤, 孙岩, 姜斌, 等. 一种基于最优未知输入观测器的故障诊断方法[J]. *自动化学报*, 2013, 39(8): 1225 – 1230.
Hu Z K, Sun Y, Jiang B, et al. An optimal unknown input observer based fault diagnosis method[J]. *Acta Automatica Sinica*, 2013, 39(8): 1225 – 1230.
- [22] Jia Q, Chen W, Zhang Y, et al. Fault reconstruction and fault-tolerant control via learning observers in Takagi-Sugeno fuzzy descriptor systems with time delays[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3885 – 3895.

作者简介

唐明珠(1997 -), 女, 硕士生. 研究领域为信息物理系统安全状态估计与控制.

张雯阳(1998 -), 男, 硕士生. 研究领域为信息物理系统故障诊断等.

郭胜辉(1983 -), 男, 博士, 副教授. 研究领域为观测器, 故障诊断.

(上接第 608 页)

- [24] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[EB/OL]. (2015-03-02) [2019-11-29]. <https://arxiv.org/abs/1502.03167>.
- [25] Grover A, Dhar M, Ermon S. Flow-GAN: Combining maximum likelihood and adversarial learning in generative models[EB/OL]. (2018-01-03) [2019-06-20]. <http://arxiv.org/abs/1705.88068>.
- [26] Goodfellow I J, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//International Conference on Neural Information Processing Systems. Berlin, Germany: Springer, 2014: 2672 – 2680.
- [27] Bevilacqua M, Roumy A, Guillemot C, et al. Low-complexity single-image super-resolution based on nonnegative neighbor embedding[C]//British Machine Vision Conference. London, UK: Cambridge, 2012: 135.1 – 135.10.
- [28] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[C]//International Conference on Curves and Surfaces, Berlin, Germany: Springer, 2010: 711 – 730.
- [29] Martin D, Fowlkes C, Tal D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//IEEE International Conference on Computer Vision. Piscataway, USA: IEEE, 2001: 416 – 423.
- [30] Kim K I, Kwon Y. Single-image super-resolution using sparse regression and natural image prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(6): 1127 – 1133.
- [31] Glasner D, Bagon S, Irani M. Super-resolution from a single image[C]//IEEE 12th International Conference on Computer Vision. Piscataway, USA: IEEE, 2009: 349 – 356.
- [32] Huang J B, Singh A, Ahuja N. Single image super-resolution from transformed self-exemplars[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA: IEEE, 2015: 5197 – 5206.
- [33] Wang Z, Chen B, Zhang H, et al. Variational probabilistic generative framework for single image super-resolution[J]. *Signal Processing*, 2019, 156: 92 – 105.

作者简介

陈国俊(1982 -), 男, 博士生, 副教授. 研究领域为大数据, 深度学习, 人工智能, 图像处理.

羊洁明(1995 -), 男, 博士生. 研究领域为深度学习, 图像处理, 多目标跟踪.

葛洪伟(1967 -), 男, 博士, 教授, 博士生导师. 研究领域为人工智能与模式识别, 图像处理与分析, 信息管理与数据挖掘, 嵌入式系统.