

# 基于深度学习和稀疏编码的图像超分辨率重建

谭成兵<sup>1</sup> 姚宏亮<sup>2</sup> 詹林<sup>3</sup>

<sup>1</sup>(亳州职业技术学院信息工程系 安徽 亳州 236813)

<sup>2</sup>(合肥工业大学计算机与信息学院 安徽 合肥 230009)

<sup>3</sup>(安徽理工大学计算机科学与工程学院 安徽 淮南 232000)

**摘要** 针对基于深度神经网络的图像超分辨率重建技术训练时间长的的问题,提出一种基于深度学习和稀疏编码的图像超分辨率重建算法。采用卷积神经网络学习低分辨率图像每一块的深度视觉特征,利用局部约束线性编码的局部平滑稀疏能力对深度特征进行编码;利用字典学习技术学习低分辨率图像和高分辨率图像每一块之间的判别关系字典;通过低分辨率字典和低分辨率图像估计稀疏表示系数,利用该系数实现图像超分辨率的重建。实验结果表明,该算法在视觉效果和评价指标上均获得了较好的超分辨率效果,并且速度较快。

**关键词** 深度神经网络 卷积神经网络 局部约束线性编码 字典学习 图像超分辨率 图像重建

**中图分类号** TP391 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2022.12.033

## IMAGE SUPER-RESOLUTION RECONSTRUCTION BASED ON DEEP LEARNING AND SPARSE CODING

Tan Chengbing<sup>1</sup> Yao Hongliang<sup>2</sup> Zhan Lin<sup>3</sup>

<sup>1</sup>(Department of Information Technology, Bozhou Vocational and Technical College, Bozhou 236813, Anhui, China)

<sup>2</sup>(School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230009, Anhui, China)

<sup>3</sup>(College of Computer Science and Engineering, Anhui University of Science & Technology, Huainan 232000, Anhui, China)

**Abstract** Aiming at the problem that the image super-resolution reconstruction techniques based on deep neural networks need long training time, we propose an image super-resolution reconstruction algorithm based on deep learning and sparse coding. Convolutional neural network was adopted to learn deep visual features of each block of low resolution images. The local smoothing and sparsity ability of locally constrained linear coding was used to encode depth features. We applied the dictionary learning technique in learning the discriminant relationship dictionary between each block of low resolution image and high resolution image. The sparse representation coefficient was estimated through low resolution dictionary and low resolution image. The coefficient was used to reconstruct the image super resolution. Experimental results indicate that the proposed algorithm realizes good super resolution effect on both visual quality and evaluation indices, and it also has fast speed.

**Keywords** Deep neural network Convolutional neural network Locality constrained linear coding Dictionary learning Image super resolution Image reconstruction

## 0 引言

图像超分辨率重建技术是指对模糊的低分辨率图像通过图像处理技术或者信号处理技术转化成清晰且

细节信息丰富的高分辨率图像,该技术在卫星图像、人脸识别和医学图像领域中发挥了极大的应用价值<sup>[1]</sup>。在临床医疗诊断过程中 CT(Computed Tomography)图像、MRI(Magnetic Resonance Imaging)图像和超声图像中往往缺少重要的高频信息,这部分高频信息是观察

病理细节的关键依据,借助超分辨率技术可以有效重建此类医学图像的细节信息<sup>[2]</sup>。人工智能的发展进一步推动了超分辨率技术的进步,使其在计算机视觉领域得到广泛的应用。

超分辨率重建技术经历了若干年的发展,从早期基于插值法的重建方法到近期基于深度学习的重建方法,逐渐解决了重建图像高频部分的模糊效应、混叠效应、振铃效应。基于插值法的重建方法主要有:双三次插值法<sup>[3]</sup>、双线性插值法<sup>[4]</sup>、凸集投影(Projection Onto Convex Sets, POCS)法<sup>[5]</sup>和迭代反投影(Iterative Back Projection, IBP)法<sup>[6]</sup>。此类方法能够有效地增强低分辨率图像的细节信息,但此类方法所重建的高频部分容易受到模糊效应、混叠效应等影响。基于深度学习的方法主要有:基于双向循环神经网络的方法<sup>[7]</sup>、基于不同结构深度残差网络的方法<sup>[8-9]</sup>及基于卷积神经网络的方法<sup>[10]</sup>。根据众多学者的研究成果,目前卷积神经网络在图像重建问题上取得了最佳的结果,重建效果普遍高于经典的插值法。但当前基于深度卷积神经网络(Convolutional Neural Networks, CNN)的方法通常对大量的训练数据进行训练,在 GPU 等并行计算环境下仍然需要训练 4 至 8 天时间<sup>[11]</sup>,严重影响了此类方法的实用性。

为了利用卷积神经网络的优势,同时解决 CNN 训练时间过长的问题,提出一种基于深度学习和稀疏编码的图像超分辨率重建算法。上述 CNN 训练时间过长的一个主要因素是训练集包含大量的高分辨率图像,而本文算法则利用已训练的 CNN 模型提取低分辨率图像的深度视觉特征,对高分辨率图像和低分辨率图像的差异图像进行字典学习。此外,利用了局部约束线性编码(Locality-constrained Linear Coding, LLC)<sup>[12]</sup>良好的特征重构性与局部平滑稀疏性,对 CNN 特征进行编码,然后送入字典学习进行处理。最终,本文在保留了 CNN 优势的前提下,有效避免了耗时的高分辨率图像集的训练。

## 1 图像超分辨率模型

基于学习的图像超分辨率重建方法通过对图像内容和空间结构信息进行学习,提取出低分辨率图像块和高分辨率图像块之间的映射关系。鉴于稀疏表示方法能够有效地学习低分辨率图像和高分辨率图像之间的共生关系,因此本文采用字典学习技术学习该共生关系。现有基于稀疏表示的超分辨率技术大多通过不同的滤波器(如高斯滤波器组、Gabor 滤波器组)来提取低分辨率图像的特征,虽然这些滤波器能够提取出

图像的边缘信息和轮廓信息,但经常忽略复杂度高的图像局部结构,容易引起模糊效应、混叠效应和振铃效应,进而降低重建图像的质量。

本文通过卷积神经网络提取图像每一块的深度视觉特征,其特征表示能力优于传统的一维滤波器或多维滤波器。然后,采用 LLC 编码对特征进行稀疏化处理,再通过字典学习技术学习 LLC 编码的稀疏表示。通过学习的每对字典和稀疏表示系数,能够识别出低分辨率图像和高分辨率图像在特征空间的准确映射关系,进而高质量地还原出图像细节和结构的缺失信息,同时抑制振铃效应、混叠效应和模糊效应。

### 1.1 超分辨率问题模型

典型的超分辨率问题模型为  $Y = DHX + n$ , 其中:  $Y \in \mathbf{R}^{N \times 1}$  表示给定的低分辨率图像;  $X \in \mathbf{R}^{N \times 1}$  为待估计的高分辨率图像; 矩阵  $H$  为模糊矩阵, 包含高分辨率图像的模糊核;  $D$  为下采样矩阵;  $n$  是均值为 0 的加性噪声。将低分辨率图像和高分辨率图像组成一个图像块集合, 记为  $y_m \in \mathbf{R}^{l \times 1}$ ,  $x_m \in \mathbf{R}^{h \times 1}$ ,  $m = 1, 2, \dots, N$ 。

### 1.2 基于稀疏表示的超分辨率模型

设  $Y$  为一个低分辨率图像,  $X$  表示  $Y$  的高分辨率图像, 图像超分辨率的目标是重建包含更多细节信息的高分辨率图像。高、低分辨率图像之间的关系定义为:

$$Y = DHX + n \quad (1)$$

式中:  $H$  表示模糊矩阵;  $D$  表示下采样;  $n$  为加性噪声。假设图像无噪声, 那么可将模糊矩阵  $H$  建模为单位矩阵, 直接通过下采样从高分辨率图像获得低分辨率图像, 那么可将图像超分辨率问题建模为图像插值问题。

假设  $X \in \mathbf{R}^{m \times N}$  包含  $N$  列数据向量  $x_j \in \mathbf{R}^m$ ,  $D \in \mathbf{R}^{m \times k}$  表示一个字典, 字典的列为  $d_k \in \mathbf{R}^m$ , 字典的原子数量为  $K$ 。向量  $x_j$  表示在图像位置  $j$  处提取的图像块, 计算为  $x_j = R_j X$ ,  $R_j$  表示矩形采样窗口。每个数据向量  $x_j$  对应一个稀疏表示向量  $a_j \in \mathbf{R}^K$ , 稀疏表示向量构成稀疏表示矩阵, 记为  $A = [a_1, a_2, \dots, a_N] \in \mathbf{R}^{K \times N}$ , 其中  $K \ll N$ 。

稀疏表示的目标是通过字典  $D$  近似  $X$ , 即  $X \approx DA$ , 对于数据样本  $x_j$ , 系数  $a_j$  的非零元素较少。针对  $A$  的计算过程称为稀疏编码, 因此稀疏编码问题可建模为:

$$\begin{aligned} A = \min_A (\|A\|_0) \\ \text{s. t. } X \approx DA \end{aligned} \quad (2)$$

式中:  $\|\cdot\|_0$  为  $l_0$  伪范数, 将其设为  $A$  的非零元素数量。将约束条件  $X \approx DA$  替换为容错的约束形式

$(\|X - DA\|_2)^2 \leq \epsilon$ , 其中  $\epsilon$  表示误码率阈值。 $l_0$  优化属于 NP-hard 问题,但在表示系数稀疏的情况下,通过最小化  $l_1$  范数能够还原出稀疏表示系数。因此将模型重写为:

$$\begin{aligned} A = \min_A (\|A\|_1) \\ \text{s. t. } (\|X - DA\|_2)^2 \leq \epsilon \end{aligned} \quad (3)$$

可通过以下的成本函数估计出稀疏表示系数矩阵  $A$  和字典  $D$ :

$$(A', D') = \arg \min_{A, D} (\|X - DA\|_2)^2 + \lambda \|A\|_1 \quad (4)$$

式中:成本函数包含一个数据拟合项和一个正则项; $\lambda$  为惩罚参数,用于平衡数据保真度和稀疏性。

## 2 图像重建技术

基于深度学习和稀疏编码的超分辨率技术包含 3 个步骤:(1) 基于 CNN 网络提取深度视觉特征,使用 LLC 编码对特征进行降维处理;(2) 采用字典学习方法学习低分辨率图像和高分辨率图像的判别字典;(3) 估计稀疏表示系数,还原出高分辨率图像。

### 2.1 基于 CNN 的特征提取

本文提取视觉特征的流程框图如图 1 所示。首先,从输入图像提取大小为  $224 \times 224$  的图像块  $I(l_i)$ , 其中: $I$  表示输入图像; $l_i$  表示第  $i$  块的空间位置。然后,将所有图像块送入深度卷积神经网络提取每一块的特征向量  $f_i$ 。最终,采用 LLC 编码将特征向量编码为视觉词  $\hat{f}_i, \hat{f}_i$  的第  $j$  个元素表示码书第  $j$  个词的权重。

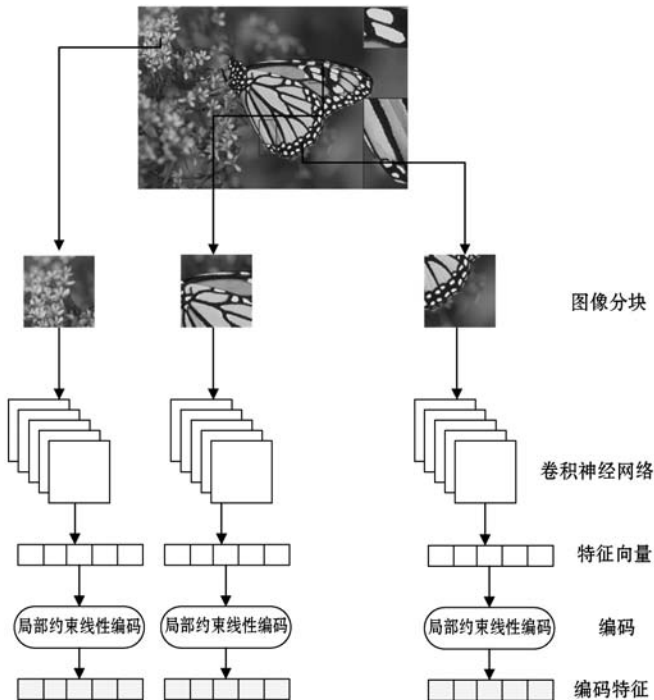


图 1 提取深度视觉特征的流程

1) 特征提取。采用 VGG16 深度卷积神经网络模型<sup>[13]</sup>作为特征提取器,该模型基于 ILSVRC-2012 数据集<sup>[14]</sup>训练而来。该模型提取的深度特征维度低于其他的复杂神经网络结构,并且所提取的特征已在多个超分辨率问题<sup>[15]</sup>中得到了应用,因此本文选择该模型学习图像每一块的深度特征。假设图像块大小为  $224 \times 224$ , VGG16 产生的特征向量  $f_i$  的维度为 4 096。

2) 局部约束线性编码 (Locality-constrained Linear Coding, LLC)。上文通过 CNN 生成了  $D$  维的特征向量,使用 LLC 编码方法对特征向量进行编码。LLC 编码包括两个步骤:

(1) 通过无监督学习训练数据,建立一个码书。CNN 提取了图像每一块的特征向量,使用 K-means 聚类算法将特征向量集分为  $M$  个簇。基于聚类结构建立码书:  $B = [b_1^T, b_2^T, \dots, b_M^T]$ , 其中  $b_i$  为第  $i$  个簇的质心。

(2) 基于码书编码每个特征向量。设  $F$  表示 CNN 网络从输入图像  $I$  提取的  $N$  个  $D$  维特征向量,记为  $F = [f_1^T, f_2^T, \dots, f_M^T]$ , 通过以下条件搜索  $F$  相应的码字集合  $\hat{F} = [\hat{f}_1^T, \hat{f}_2^T, \dots, \hat{f}_M^T]$ :

$$\min_B \sum_{i=1}^N \|f_i - B\hat{f}_i\|^2 + \lambda \|d_i * \hat{f}_i\|^2 \quad (5)$$

式中:“ $*$ ”表示元素级的乘法运算; $B$  为码书; $\lambda$  为正则项的系数; $d_i$  为局部调节变量。 $d_i$  定义为:

$$d_i = \exp\left(\frac{\text{dist}(f_i, B)}{\sigma}\right) \quad (6)$$

式中:  $\text{dist}(f_i, B) = [\text{dist}(f_i, b_1), \text{dist}(f_i, b_2), \dots, \text{dist}(f_i, b_M)]^T$ ,  $\text{dist}(f_i, b_j)$  为  $f_i$  和  $b_j$  之间的欧氏距离; $\sigma$  参数用于控制权重下降速度。

### 2.2 字典学习方法

设  $y_h^i = \{y_h^1, y_h^2, \dots, y_h^i, \dots, y_h^N\}$  为高分辨率训练图像集,其中: $y_h^i$  表示第  $i$  个高分辨率图像; $N$  为高分辨率图像的数量。假设估计的高分辨率图像  $y_h^i$  和实际高分辨率图像  $y_h^i$  的维度相同,且  $y_h^i$  和  $y_h^i$  两者高度相似。直接对高分辨率图像进行下采样获得低分辨率的数据,然后把低分辨率数据放大到原尺寸即可获得低分辨率图像  $y_l^i$ ,采用该图像  $y_l^i$  建立低分辨率字典,而  $y_h^i$  和  $y_l^i$  之间的差分图像  $e_h^i$  被用来建立高分辨率字典。

设一对高分辨率块和低分辨率块为  $P = \{p_h^k, p_l^k\}_k$ , 字典学习的目标是学习字典,使得高分辨和 low-resolution 图像块稀疏表示的字典系数相同。低分辨率特征的稀疏表示模型为:

$$p_l = D_l A \quad (7)$$

式中: $p_l$  为低分辨率图像的块; $D_l$  为低分辨率字典; $A$

为稀疏表示系数。采用 K-SVD 字典训练方法<sup>[16]</sup>计算  $D_l$ , 计算方法为:

$$D_l = \arg \min_{D_l, A^k} \sum_k \|p_l^k - D_l A^k\|^2 \quad (8)$$

s. t.  $\|A^k\|_0 \leq L$

式中:  $L$  表示最大稀疏度。K-SVD 训练方法基于当前数据的稀疏编码迭代更新字典的原子, 不断提高数据拟合的准确性, 最终生成稀疏表示系数  $A$ 。

假设高分辨率和低分辨率图像块的稀疏表示系数相同, 那么高分辨率图像块的稀疏表示为:

$$D_h = \arg \min_{D_h} \sum_k \|p_h^k - D_h A^k\|_2^2 \quad (9)$$

通过以下的伪逆矩阵求解出式(9):

$$D_h = p_h A^T (A A^T)^{-1} \quad (10)$$

图 2 所示是本文单图像字典学习的流程, 基于深度视觉特征生成高分辨率字典和低分辨率字典。

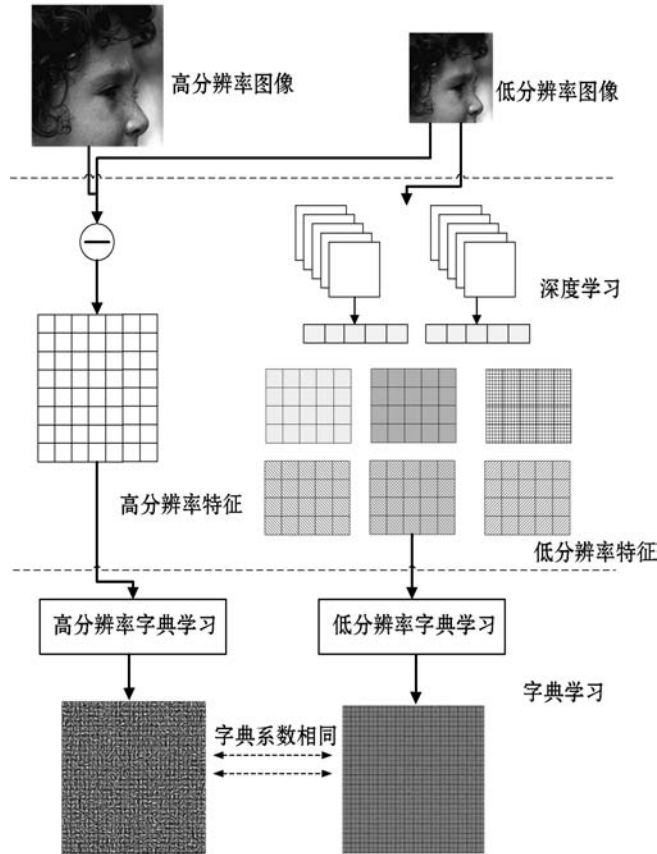


图 2 字典学习方法

### 2.3 高分辨率图像重建

高分辨率图像重建的思想是基于上文学习的字典和低分辨率图像估计出高分辨率图像。采用和字典学习阶段相同的深度特征提取方法获得低分辨率图像的特征, 然后将特征和字典学习获得的投影相乘获得  $p_l^k$ 。

随之使用正交匹配追踪算法 (Orthogonal Matching Pursuit, OMP)<sup>[17]</sup> 将低分辨率特征  $p_l^k$  编码成低分辨率稀疏表示系数:

$$A^k = \arg \min_{A^k} \sum_k \|p_l^k - D_l A^k\|^2 \quad (11)$$

$$\text{s. t. } \|A^k\|_0 \leq L$$

将稀疏表示系数和高分辨率字典  $D_h$  相乘, 还原出近似的高分辨率图像块;

$$p_h^k = D_h A^k \quad (12)$$

图 3 所示是单图像超分辨率重建的流程, 重建过程仅需要提取一次低分辨率图像的特征, 保证了较低的计算复杂度。

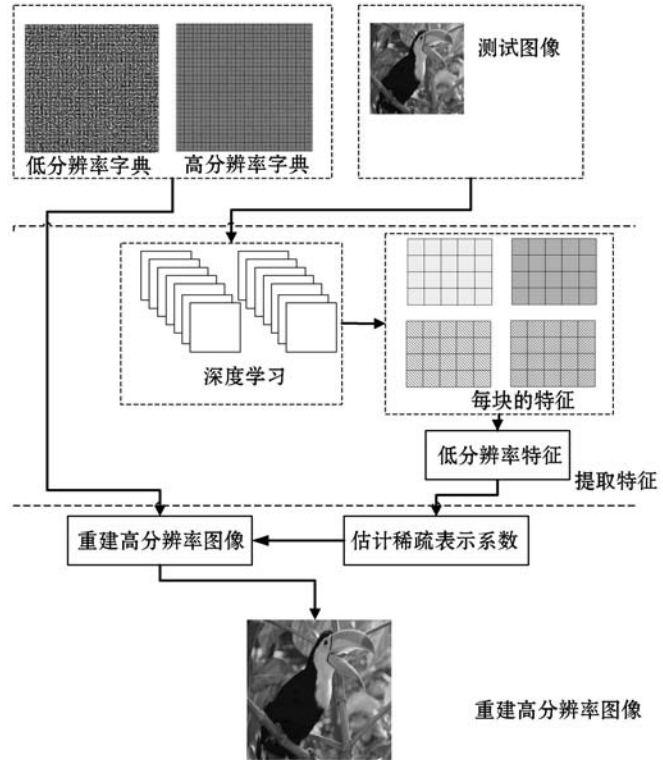


图 3 图像重建方法

## 3 仿真实验和结果分析

本文实验环境为 PC 机, CPU 为 Intel i5-8265U, 内存容量为 8 GB, 操作系统为 Windows 10 系统。编程环境为 MATLAB 仿真平台。

### 3.1 实验数据集

采用在超分辨率领域被广泛使用的两个公开数据集 Set5 和 Set14, 数据集的每幅图像均包含 2 倍、3 倍、4 倍的放大因子。为了简化描述, 将 Set5 和 Set14 的图像分别进行编号: (1) Set5 的 Baby、Bird、Butterfly、Head 和 Woman 图像依次编号为 1-5; (2) Set14 的 Baboon、Barbara、Bridge、Coastguard、Comic、Face、Flowers、Foreman、Lenna、Man、Monarch、Pepper、PPT3、Zebra 图像依次编号为 1-14。

### 3.2 性能评价标准和对比方法

通过 PSNR 和 SSIM 两个指标定量评估超分辨率

图像的质量。PSNR 的计算式为:

$$PSNR = 10 \lg \frac{MN}{\|f - g\|^2} \quad (13)$$

式中:  $M$  和  $N$  分别为图像的长和宽;  $f$  和  $g$  分别为实际和重建的高分辨率图像。

$$SSIM = \frac{(2\mu_f\mu_g + C_1)(\sigma_{fg} + C_2)}{(\mu_f^2 + \mu_g^2 + C_1)(\sigma_f^2 + \sigma_g^2 + C_2)} \quad (14)$$

式中:  $\mu_f$  和  $\mu_g$  分别为  $f$  和  $g$  的平均灰度;  $\sigma_f$  和  $\sigma_g$  分别为  $f$  和  $g$  的方差;  $\sigma_{fg}$  表示  $f$  和  $g$  的协方差;  $C_1$  和  $C_2$  为两个常量。

为了客观比较算法的性能,选择了基于信息蒸馏网络(Information Distillation Network, IDN)的超分辨率方法 IDNSR<sup>[18]</sup>、基于流形约束稀疏编码的超分辨率方法 MCSCSR<sup>[19]</sup>、基于耦合字典学习算法的 CDLSR<sup>[20]</sup>、基于卷积神经网络的超分辨率方法 DeepSUM<sup>[21]</sup> 和本文算法进行比较。IDNSR 是继 SRCNN 之后又一个新的超分辨率网络模型,通过该模型评估本文算法的先进性。MCSCSR 和 CDLSR 均为基于稀疏编码的增强类超分辨率方法,这两个方法均基于传统的图像几何特征,通过它们评估本文算法的深度视觉特征效果。DeepSUM 是一种基于卷积神经网络的超分辨率方法,该方法的训练过程在 GPU 上需要两天以上的时间。

### 3.3 参数设置

图像块的大小设为  $224 \times 224$ ,本文使用的 VGG16 模型已在 ILSVRC-2012 数据集进行预训练。网络生成的特征向量大小为  $1 \times 4096$ 。在 LLC 编码处理中,每个训练块随机选择 20 个  $8 \times 8$  的子块用以生成码书,码字的数量设为 240,LLC 编码的邻居参数  $K$  设为 5。

字典大小是影响字典学习性能的关键指标,因此通过一组实验观察字典大小对本文算法性能的影响情况。图 4 所示是 Set14 数据集上不同字典大小的重建性能统计结果,观察曲线,随着字典规模的提高,重建效果得以提升,最终考虑计算效率和性能之间的平衡,将字典大小设为 4096。




图 4 字典大小的参数实验

### 3.4 实验结果和分析

(1) 视觉效果评价。在临床医疗等应用场景中通过超分辨率重建技术补充医学图像的细节信息,以满足临床诊断的需求,因此视觉效果是衡量图像重建质量的首要因素。图 5 所示是 Set5 数据集 Bird 图像的重建实例,其中:(a)为 3 倍放大的原图像,(b)(c)(d)(e)(f)分别为 IDNSR、MCSCSR、CDLSR、DeepSUM 和本文算法的重建结果。可以看出 MCSCSR 和 CDLSR 对嘴部放大 3 倍后清晰度较低,这两种算法均采用传统的几何特征,受到了模糊效应和振铃效应的影响。IDNSR 和 DeepSUM 重建的视觉质量优于 MCSCSR 和 CDLSR,放大 3 倍的图像中包含了锐利的边缘信息。本文算法的高分辨率图像也包含了丰富的细节和锐利的边缘信息,并且边缘的锐利效果好于其他算法。



(a) 原图像 (b) IDNSR 重建 (c) MCSCSR 重建



(d) CDLSR 重建 (e) DeepSUM 重建 (f) 本文算法重建

图 5 Set5 数据集的重建实例

图 6 所示是 Set14 数据集 Monarch 图像的重建实例,其中:(a)为 3 倍放大的原图像,(b)(c)(d)(e)(f)分别为 IDNSR、MCSCSR、CDLSR、DeepSUM 和本文算法的重建结果。可以看出 MCSCSR 和 CDLSR 对蝴蝶花纹放大 3 倍后清晰度较低,这两种算法均采用传统的几何特征,也受到了模糊效应和振铃效应的影响。IDNSR 和 DeepSUM 重建的视觉质量优于 MCSCSR 和 CDLSR,蝴蝶花纹处的清晰度更高。本文算法的高分辨率图像则好于 4 个对比算法,蝴蝶花纹处的清晰度更高,并且边缘的锐利程度也更好。



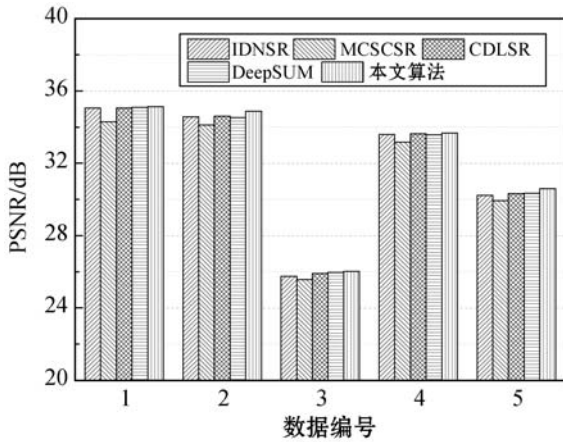
(a) 原图像 (b) IDNSR 重建 (c) MCSCSR 重建



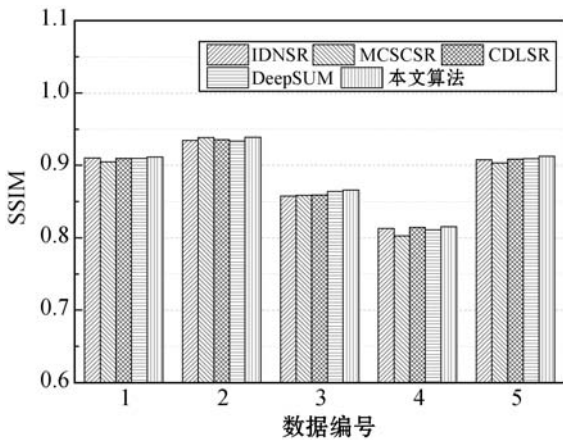
(d) CDLSR 重建 (e) DeepSUM 重建 (f) 本文算法重

图 6 Set14 数据集的重建实例

(2) 性能定量评价。图 7(a)、图 7(b) 所示分别是在 Set5 数据集上进行超分辨率重建(3 倍放大)的 PSNR 结果和 SSIM 结果。可以看出基于深度学习的方法也优于传统基于图像几何特征的方法, DeepSUM 在 Baby、Butterfly 和 Woman 三幅图像上优于 IDNSR, 但在 Bird 和 Head 两幅图像上差于 IDNSR, 可见信息蒸馏网络和卷积神经网络各有优劣。由于本文算法利用 LLC 编码技术良好的特征重构性与局部平滑稀疏性, 有效地增强了卷积神经网络的深度视觉特征, 因此本文算法对 5 幅图像均实现了更好的 PSNR 结果和 SSIM 结果。



(a) PNSR 结果



(b) SSIM 结果

图 7 Set5 数据集的实验结果

表 1、表 2 分别是在 Set14 数据集上进行超分辨率重建(3 倍放大)的 PSNR 结果和 SSIM 结果。另外可发现基于深度学习的方法也优于传统基于图像几何特征的方法, DeepSUM 在 Baboon、Barbara、Coastguard、

Face、Foreman 和 Man 六幅图像上优于 IDNSR, 但在 Bridge、Comic、Flowers、Lenna、Monarch、Pepper、Zebra 和 PPT3 图像上差于 IDNSR, 由此也再次证明信息蒸馏网络和卷积神经网络各有优劣。可以看出本文算法对 Set14 的大多数图像均实现了更好的 PSNR 结果和 SSIM 结果。本文算法利用 LLC 编码技术良好的特征重构性与局部平滑稀疏性, 有效地增强了卷积神经网络的深度视觉特征。


表 1 Set14 数据集的 PSNR 结果 单位: dB

数据编号	IDNSR	MCSCSR	CDLSR	DeepSUM	本文算法
1	23.55	23.47	23.56	23.52	23.59
2	26.74	26.39	26.69	26.79	26.70
3	24.98	24.82	25.01	25.01	25.05
4	27.07	27.02	27.08	27.12	27.15
5	23.98	23.90	24.04	23.97	24.01
6	33.56	33.11	33.62	33.54	33.62
7	28.38	28.25	28.49	28.43	28.63
8	33.21	32.04	33.23	33.18	33.58
9	33.01	32.64	33.08	33.02	33.26
10	27.87	27.76	27.92	27.91	28.05
11	30.95	30.71	31.09	31.12	31.58
12	33.80	33.32	33.82	34.05	34.18
13	24.94	24.98	25.03	25.21	25.03
14	28.31	27.95	28.43	28.51	28.58

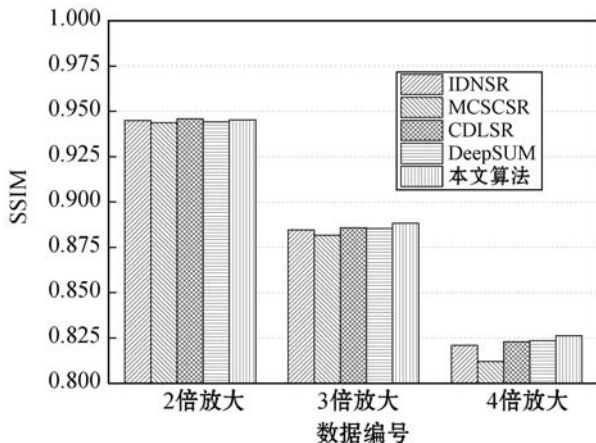
表 2 Set14 数据集的 SSIM 结果

数据编号	IDNSR	MCSCSR	CDLSR	DeepSUM	本文算法
1	0.592 5	0.586 8	0.594 6	0.586 2	0.603 8
2	0.780 5	0.764 8	0.780 3	0.781 2	0.784 0
3	0.694 2	0.690 8	0.696 3	0.692 2	0.697 1
4	0.651 3	0.642 3	0.653 1	0.650 9	0.657 0
5	0.749 9	0.758 3	0.753 5	0.748 6	0.750 1
6	0.811 6	0.801 3	0.813 3	0.809 7	0.814 4
7	0.830 7	0.830 8	0.833 2	0.830 2	0.835 5
8	0.914 9	0.909 5	0.915 7	0.914 5	0.918 2
9	0.869 4	0.865 3	0.870 9	0.868 4	0.872 7
10	0.782 2	0.775 1	0.783 9	0.781 0	0.787 3
11	0.928 3	0.929 5	0.929 8	0.929 5	0.932 7
12	0.874 8	0.866 0	0.875 4	0.875 9	0.877 5
13	0.889 3	0.893 8	0.889 8	0.899 2	0.895 5
14	0.829 4	0.825 0	0.831 3	0.830 3	0.829 2

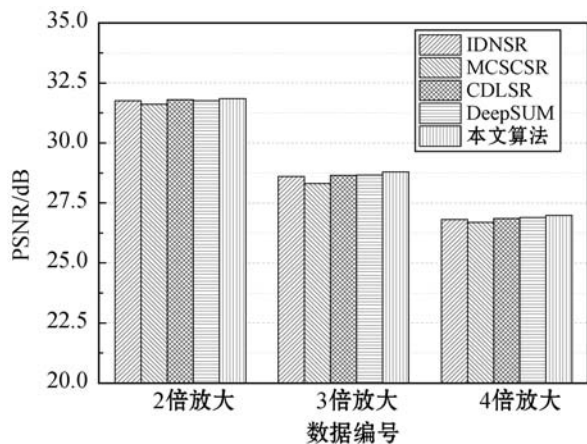
随之分析了超分辨率重建算法在不同放大因子下的重建性能,结果如图 8 所示。图 8(a) - 图 8(d) 分别为 Set5 的 PSNR 结果、Set5 的 SSIM 结果、Set14 的 PSNR 结果和 Set14 的 SSIM 结果。虽然对不同的图像进行了实验,但是 4 幅结果图表现出一致性,随着放大因子的提高,重建质量逐渐降低。并且在放大因子较低时,不同重建算法的结果较为接近,而随着放大因子的增加,不同重建算法的性能差异增大。总体而言,本文算法在不同放大因子下均获得了更好的结果。



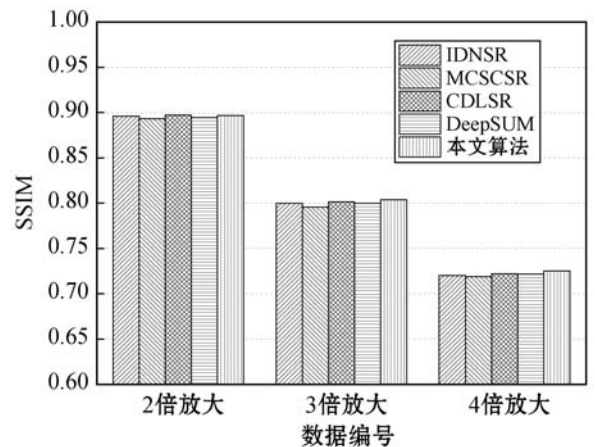
(a) Set5 数据集的 PSNR 结果



(b) Set5 数据集的 SSIM 结果



(c) Set14 数据集的 PSNR 结果



(d) Set14 数据集的 SSIM 结果

图 8 不同放大因子的实验结果

(3) 算法时间效率。最终统计了在图像重建过程中每个算法所需的响应时间,如表 3 所示。可以看出随着放大因子的提高,处理时间降低,其原因主要是放大倍数越大,特征的稀疏性越高,处理的速度越快。而 CDLSR 算法在重建过程中需要提取输入图像的 Gabor 特征组和高斯特征组,并且每块大小仅为  $3 \times 3$ ,因此处理时间远高于其他算法。本文算法在重建过程中仅需要提取一次低分辨率图像的特征,然后结合低分辨率字典系数估计出高分辨率图像,因此计算效率较高,最终本文算法和 MCSCSR 算法的计算效率优于其他算法。

表 3 超分辨率算法的平均响应时间 单位:s

数据	放大	IDNSR	MCSCSR	CDLSR	DeepSUM	本文算法
Set5	2 倍	5.3	0.9	25.4	3.1	0.3
	3 倍	1.9	0.5	29.5	1.3	0.2
	4 倍	1.3	0.4	30.4	0.9	0.2
Set14	2 倍	9.2	1.7	50.6	5.9	0.4
	3 倍	4.1	1.2	60.7	2.8	0.4
	4 倍	2.5	0.8	63.0	1.7	0.3

## 4 结 语

本文通过卷积神经网络提取图像每一块的深度视觉特征,然后采用 LLC 编码对特征进行稀疏化处理,通过学习的每对字典和稀疏表示系数,能够识别出低分辨率图像和高分辨率图像在特征空间的准确映射关系,进而高质量地还原图像细节和结构的缺失信息,同时抑制振铃效应、混叠效应和模糊效应。实验结果表明,算法在视觉效果和评价指标上均获得了较好的超分辨率效果,并且速度较快。本文的深度视觉特征主要基于 VGG16 网络实现,未来将在 AlexNet、Inception



和 ResNet 等模型上进行研究,观察不同 CNN 网络模型对超分辨率重建性能的影响。

## 参 考 文 献

- [ 1 ] 黄凤,王晓明.增强的单幅图像自学习超分辨率方法[J].计算机应用,2017,37(9):2636-2642,2699.
- [ 2 ] 吴洋洋,杨丰,黄靖,等.生成对抗网络的血管内超声图像超分辨率重建[J].南方医科大学学报,2019,39(1):82-87.
- [ 3 ] 苏健民,杨岚心.基于生成对抗网络的单帧遥感图像超分辨率[J].计算机工程与应用,2019,55(12):202-207,214.
- [ 4 ] Ding N, Liu Y P, Fan L W, et al. Single image super-resolution via dynamic lightweight database with local-feature based interpolation [J]. Journal of Computer Science and Technology, 2019, 34(3): 537-549.
- [ 5 ] Lei J, Wang H, Zhu L, et al. Image super-resolution reconstruction algorithm based on fractional calculus [J]. Systems Engineering & Electronics, 2017, 39(12): 2849-2856.
- [ 6 ] Nazren A R A, Yaakob S N, Ngadiran R, et al. Improving iterative back projection super resolution model via anisotropic diffusion edge enhancement [C]//2016 International Conference on Robotics, Automation and Sciences (ICORAS), 2016:1-4.
- [ 7 ] Wang Y, Liu F, Zhang K, et al. LFNet: A novel bidirectional recurrent convolutional neural network for light-field image super-resolution [J]. IEEE Transactions on Image Processing, 2018, 27(9): 4274-4286.
- [ 8 ] 赵小强,宋昭漾.多级跳线连接的深度残差网络超分辨率重建[J].电子与信息学报,2019,41(10):2501-2508.
- [ 9 ] 华臻,张海程,李晋江.基于残差的端对端图像超分辨率[J].计算机科学,2019,46(6):246-255.
- [ 10 ] 张顺岚,曾儿孟,高宇,等.基于卷积神经网络的超分辨率重建[J].计算机工程与设计,2017,38(11):3080-3086.
- [ 11 ] Timofte R, Agustsson E, Van G L, et al. Ntire 2017 challenge on single image super-resolution: Methods and results [C]//IEEE Conference on Computer Vision and Pattern Recognition Workshops, 2017:114-125.
- [ 12 ] Chen H, Xie K, Wang H, et al. Scene image classification using locality-constrained linear coding based on histogram intersection [J]. Multimedia Tools & Applications, 2017, 77(11):1-12.
- [ 13 ] Hussam Q, Abhishek V, David F. Compressed residual-VGG16 CNN model for big data places image recognition [C]//2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC), 2018: 169-175.
- [ 14 ] Feinberg B, Wang S, Ipek E. Making memristive neural network accelerators reliable [C]//2018 IEEE International Symposium on High Performance Computer Architecture (HPCA), 2018:52-65.
- [ 15 ] Alvarez-Ramos V, Ponomaryov V, Reyes-Reyes R. Image super-resolution via two coupled dictionaries and sparse representation [J]. Multimedia Tools and Applications, 2018, 77:13487-13511.
- [ 16 ] Zhang X, Zhou W, Duan Z. Image super-resolution reconstruction based on fusion of K-SVD and semi-coupled dictionary learning [C]//2016 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA), 2016:1-5.
- [ 17 ] 王丽,王威,陈博.改进的粒子群优化正交匹配追踪重构算法[J].小型微型计算机系统,2019,40(8):1755-1759.
- [ 18 ] Hui Z, Wang X, Gao X. Fast and accurate single image super-resolution via information distillation network [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018.
- [ 19 ] Zhu H, Xie K, Ye J, et al. Manifold inconsistency constrained sparse coding for image super-resolution reconstruction [C]//2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2017.
- [ 20 ] Ahmed J, Memon R A, Waqas M, et al. Selective sparse coding based coupled dictionary learning algorithm for single image super-resolution [C]//2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET), 2018:1-5.
- [ 21 ] Molini A B, Valsesia D, Fracastoro G, et al. DeepSUM: Deep neural network for super-resolution of unregistered multitemporal images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(5): 3644-3656.

## (上接第 151 页)

- [ 15 ] 赵春蕾.高分辨率航空视频 HEVC 码率控制技术[D].长春:中国科学院大学,2016.
- [ 16 ] 郭红伟,刘帅.一种 HEVC 低延时编码码率控制算法[J].计算机应用与软件,2019,36(3):162-167,191.
- [ 17 ] 詹亘,肖晶,陈宇静,等.面向自适应码率视频直播的码率控制算法[J].计算机工程,2019,45(3):268-272.
- [ 18 ] Li B, Li H Q, Li L, et al.  $\lambda$  domain rate control algorithm for high efficiency video coding [J]. IEEE Transactions on Image Processing, 2014, 23(9): 3841-3854.
- [ 19 ] Liang X C, Wang Q, Zhou Y H, et al. A novel R-Q model based rate control scheme in HEVC [C]//Visual Communications and Image Processing, 2013:1-6.
- [ 20 ] Feng Z Q, Liu P Y, Jia K B, et al. An adaptive model parameters prediction mechanism for LCU-Level rate control [C]//International Conference on Genetic and Evolutionary Computing, 2018:275-283.