

## 基于卷积稀疏自编码的图像超分辨率重建

张 秀,周 巍,段哲民,魏恒璐

(西北工业大学 电子信息学院,陕西 西安 710129)

**摘 要:** 针对卷积稀疏编码算法中特征映射的准确性的问题, 为了进一步提高图像超分辨率重建的质量, 文中提出一种基于卷积稀疏自编码的图像超分辨率重建算法。该算法首先在预训练阶段利用稀疏自编码器对输入高低分辨率图像分别进行训练, 得到对应的图像稀疏特征表示; 然后再由卷积神经网络根据得到的稀疏系数共同训练相应的滤波器及特征映射函数并更新到最优解; 最后由高分辨率滤波器和对应的稀疏表示系数卷积求和, 得到高分辨率重建图像估计。实验结果显示, 改进算法的峰值信噪比(PSNR)结果较卷积稀疏编码算法提高了近 0.1 dB, 有效提高了重建图像的质量。

**关键词:** 稀疏编码; 卷积神经网络; 自编码器; 深度学习; 超分辨率重建

**中图分类号:** TP391 **文献标志码:** A **DOI:** 10.3788/IRLA201948.0126005

## Convolutional sparse auto-encoder for image super-resolution reconstruction

Zhang Xiu, Zhou Wei, Duan Zhemin, Wei Henglu

(School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710129, China)

**Abstract:** For the accuracy of feature maps in convolutional sparse coding algorithm, in order to further improve the quality of image super-resolution reconstruction, an image super-resolution(SR) reconstruction algorithm based on convolutional sparse auto-encoder was proposed in this paper. In this algorithm, firstly, the input images were pre-trained with sparse auto-encoder for obtaining the feature of LR and HR image; after that, the convolutional neural network trained the corresponding filters and feature mapping function and updated to the optimal solution according to the obtained sparse coefficients; finally, the summation of the convolutions of high-resolution (HR) filters and the corresponding feature maps could reconstruct the HR image. The experimental results show that the peak signal-to-noise ratio (PSNR) of the proposed algorithm is nearly 0.1 dB higher than the CSC algorithm, which improves the quality of reconstructed images.

**Key words:** sparse coding; convolutional neural network; auto-encoder; deep learning; super-resolution reconstruction

收稿日期: 2018-08-12; 修订日期: 2018-09-15

基金项目: 国家自然科学基金(61602383); 陕西省自然科学基金(2017JQ6019)

作者简介: 张秀(1987-), 女, 博士生, 主要从事图像处理方面的研究。Email: zhangxiu\_03@163.com

导师简介: 段哲民(1953-), 男, 教授, 博士生导师, 主要从事图像处理, 电气电子系统测试和航空电源监测等方面的研究。

Email: zhemin@nwpu.edu.cn

## 0 引言

超分辨率(Super-Resolution, SR)重建是利用数字图像处理技术从输入低分辨(Low-Resolution, LR)图像中获取有效信息,来重建高分辨(High-Resolution, HR)图像的过程<sup>[1-2]</sup>。一般将图像的SR重建算法分为基于插值的<sup>[3]</sup>,基于重建的<sup>[4-5]</sup>和基于学习的<sup>[6-7]</sup>三大类。

在基于学习的SR算法中,稀疏编码重建算法应用非常广泛<sup>[8-9]</sup>。稀疏编码模型简单描述为图像 $x$ 可由字典 $D$ 的少量原子线性表示,即 $x=D\alpha$ , $\alpha$ 是稀疏编码向量。在重建过程中,这个简单模型缺乏观测图像的足够信息,于是Yang等提出分别由高、低分辨率字典 $D^h$ 和 $D^l$ 编码图像的稀疏向量<sup>[10]</sup>,输入LR图像 $y=D^l\alpha$ ,假设高低分辨率图像的稀疏编码是相同的,则HR图像 $x=D^h\alpha$ 。但是这个假设过于严格,Wang等假设HR和LR图像块的稀疏表示之间存在一种线性映射关系,利用特征映射函数可以由LR图像稀疏编码线性地转换出HR图像稀疏系数<sup>[11]</sup>。

参考文献[10]和[11]中的SR稀疏编码算法能够较好地重建原始图像并且简化求解过程,但都只是独立地处理图像的重叠块,忽略了图像之间的一致性约束,并不能最优化整幅图像。于是Zeiler等用滤波器组及其对应的特征映射代替字典矩阵和编码向量稀疏编码整幅图像<sup>[12]</sup>,这样可以学习到更丰富的特征集并用于图像的分析 and 合成。在参考文献[12]的基础上,Gu等结合字典对学习提出卷积稀疏编码(Convolutional Sparse Coding, CSC)方法,该方法利用LR和HR滤波器组对HR和LR图像进行分解和重建<sup>[13]</sup>,可以减少LR图像分解的运算复杂度,同时提高HR滤波器的编码能力,进而提高SR重建图像的质量。

2006年,Hinton提出基于人工神经网络的贪婪无监督逐层学习方法<sup>[14]</sup>,于是各种基于深度学习理论的训练算法被用于SR重建,尤其是卷积神经网络(Convolutional Neural Network, CNN)<sup>[13]</sup>和受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)<sup>[15]</sup>。但是RBM的随机性使得稀疏编码通常不易被训练,于是Lee等结合深度置信网(Deep Belief Network, DBN)理论<sup>[16]</sup>提出自动编码器(Auto-Encoder, AE)<sup>[17]</sup>,该算

法可以快速直接地进行稀疏编码。

自动编码器是一种无监督的逐层特征学习算法,它的内部层可以作为图像特征的通用提取器,多层感知器提供的双层结构有效地将输入数据映射为适当的输出特征,而且这种深度学习方式可以利用并行图形处理单元提高运算速度。于是文中提出一种卷积稀疏自编码(Convolution Sparse Auto-Encoder, CSAE)算法,利用自动编码器的优势,在CSC[13]之前对输入图像进行预训练,得到输入图像更准确的特征映射用于滤波器学习,实验结果验证CSAE算法在CSC算法的基础上进一步提高了图像重建的质量。

## 1 稀疏自编码器

### 1.1 自动编码器

自动编码器是一种利用反向传播(Backpropagation, BP)算法学习恒等函数 $h_{w,b}(x) \approx x$ ,使得目标输出逼近输入,进而对数据进行有效编码的学习算法<sup>[17]</sup>,其网络结构如图1所示。将输入向量 $x$ 由映射函数 $f$ 映射到隐层 $y$ ,即

$$y = h_{w,b}(x) = f(W^T x) = f(\sum_{i=1}^{n_1} W_i x_i + b) \quad (1)$$

式中: $n_1$ 为自动编码器层数; $W$ 为一个 $d' \times d$ 的权值矩阵; $b$ 为偏置向量; $f(z) = 1 / (1 + \exp(-z))$ 为sigmoid激活函数。




图1 自编码神经网络结构

Fig.1 Auto-encoder neural network structure

样本集 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ 的目标函数可以表示为:

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m L(x^{(i)}, z^{(i)}) \quad (2)$$

根据数据的不同形式，损失函数  $L$  由二次误差

$L(x, z) = \frac{1}{2} \|x - z\|^2$  和交叉熵  $L(x, z) = - \sum_{j=1}^d [x_j \log(z_j) + (1 - x_j) \log(1 - z_j)]$  表示，文中采用二次误差。同时为防止自动编码器过拟合，在目标函数中加入权值衰减项，则公式(2)变为：

$$J(W, b) = \frac{1}{m} \sum_{i=1}^m \left( \frac{1}{2} \|y^{(i)} - h_{W,b}(x^{(i)})\|^2 \right) + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{i=1}^{s_l} \sum_{j=1}^{s_{l+1}} (W_{ji}^{(l)})^2 \quad (3)$$

式中：权值衰减参数  $\lambda$  反映权值衰减项与重建损失的相关性； $s_l$  是第  $l$  层的节点。

在神经网络中，偏置项  $b$  对权值衰减的影响通常很小，因此在权值衰减计算时不考虑偏置项。

## 1.2 稀疏自编码器

为了保证自动编码器提取的输入数据特征表示的有效性和稀疏性，要使自编码神经网络隐层神经元  $j$  的平均活跃度  $p_j = \frac{1}{m} \sum_{i=1}^m [a_j^{(i)} x^{(i)}]$  尽可能地接近指定稀疏性参数  $p \ll 1$ ， $a_j^{(i)}$  表示第  $l$  层的第  $j$  个节点的输出值。于是在自动编码器的目标函数中加入基于 KL(Kullback-Leibler) 散度的稀疏约束项<sup>[18]</sup>，即

$$J_{\text{sparse}}(W, b) = J(W, b) + \beta \sum_{j=1}^{s_2} \text{KL}(p \| p_j) = J(W, b) + \beta \sum_{j=1}^{s_2} \left( p \log \frac{p}{p_j} + (1-p) \log \frac{1-p}{1-p_j} \right) \quad (4)$$

式中： $\beta$  表示稀疏约束项的权重。

## 2 卷积稀疏自编码超分辨率重建

稀疏自编码器将输入数据由输入层非线性编码到隐层神经元，然后再经由输出层解码出有效地特征映射。由于隐层神经元的数目少于输入输出层神经元的数目，因此经由隐层神经元得到输入数据的低维稀疏表示。稀疏自编码器的特征提取方法避免了人工提取的麻烦，可以直接训练得到输入图像的特征映射。文中基于 Gu 的卷积稀疏编码模型<sup>[13]</sup>，提出一种改进的卷积稀疏自编码模型，该算法首先由稀疏自动编码器预训练输入图像，再用训练得到的特征映射训练 LR 和 HR 滤波器及映射函数，然后在重建 HR 图像，其算法原理如图 2 所示。

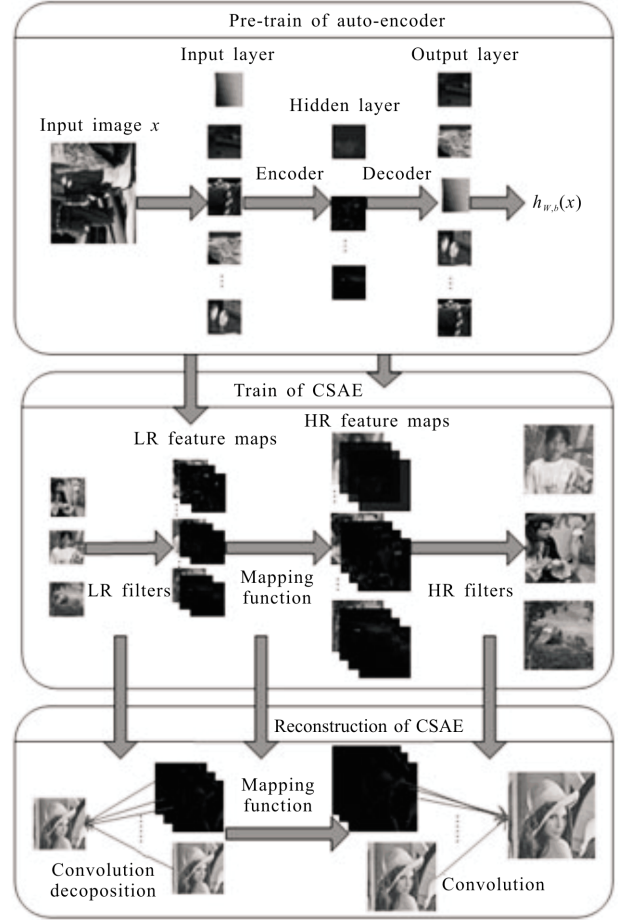


图 2 卷积稀疏自编码算法示意图

Fig.2 Schematic diagram of the convolution sparse auto-encoder algorithm

### 2.1 稀疏自编码器预训练

在 SR 重建算法中，先由稀疏自动编码器对输入数据进行训练，分别得到 LR 和 HR 图像的特征映射。在预训练过程中，将参数  $W_{ij}^{(0)}$  和  $b_i^{(0)}$  进行随机初始化，设置为一个接近于零的随机值，然后迭代计算参数，即

$$W_{ij}^{(0)} = W_{ij}^{(0)} - \alpha \frac{\partial}{\partial W_{ij}^{(0)}} J(W, b) \quad (5)$$

$$b_i^{(0)} = b_i^{(0)} - \alpha \frac{\partial}{\partial b_i^{(0)}} J(W, b) \quad (6)$$

式中： $\alpha$  为学习速率。

利用 BP 算法计算公式(5)和(6)中的偏导数，有

$$\frac{\partial}{\partial W_{ij}^{(0)}} J(W, b) = \left[ \frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial W_{ij}^{(0)}} J(W, b; x^{(i)}, y^{(i)}) \right] + \lambda W_{ij}^{(0)} \quad (7)$$

由于权值衰减项只关于  $W$ ，则

$$\frac{\partial}{\partial \mathbf{b}_i^{(l)}} J(\mathbf{W}, \mathbf{b}) = \frac{1}{m} \sum_{i=1}^m \frac{\partial}{\partial \mathbf{b}_i^{(l)}} J(\mathbf{W}, \mathbf{b}; \mathbf{x}^{(i)}, \mathbf{y}^{(i)}) \quad (8)$$

在偏导数计算过程中, 定义神经网络中第  $n_l$  层的每  $i$  个神经元的输出值  $\mathbf{a}_i^{(n_l)}$  与实际值之间的差距为残差  $\delta_i^{(n_l)}$ , 即

$$\begin{aligned} \delta_i^{(n_l)} &= \frac{\partial}{\partial z_i^{(n_l)}} J(\mathbf{W}, \mathbf{b}; \mathbf{x}, \mathbf{y}) = \frac{\partial}{\partial z_i^{(n_l)}} \frac{1}{2} \|\mathbf{y} - \mathbf{h}_{\mathbf{W}, \mathbf{b}}(\mathbf{x})\|^2 = \\ &= \frac{\partial}{\partial z_i^{(n_l)}} \frac{1}{2} \sum_{j=1}^{s_{n_l}} (\mathbf{y}_j - \mathbf{f}(z_j^{(n_l)}))^2 = -(\mathbf{y}_j - \mathbf{f}(z_j^{(n_l)})) \cdot \mathbf{f}'(z_j^{(n_l)}) = \\ &= -(\mathbf{y}_j - \mathbf{a}_i^{(n_l)}) \cdot \mathbf{f}'(z_j^{(n_l)}) \end{aligned} \quad (9)$$

设  $l = n_l - 1, n_l - 2, n_l - 3, \dots, 2$ , 则第  $l$  层的第  $i$  个节点的残差为:

$$\delta_i^{(n_l-1)} = (\sum_{j=1}^{s_{n_l-1}} \mathbf{W}_{ji}^{n_l-1} \delta_j^{(n_l)}) \mathbf{f}'(z_i^{n_l-1}) \quad (10)$$

用  $l$  和  $l+1$  替换  $n_l-1$  和  $n_l$ , 则有

$$\delta_i^{(l)} = (\sum_{j=1}^{s_{l+1}} \mathbf{W}_{ji}^{(l)} \delta_j^{(l+1)}) \mathbf{f}'(z_i^{(l)}) \quad (11)$$

结合公式(4)和(11), 稀疏自编码网络的残差可以表示为:

$$\delta_i^{(l)} = \left( (\sum_{j=1}^{s_{l+1}} \mathbf{W}_{ji}^{(l)} \delta_j^{(l+1)}) + \beta \left( -\frac{\mathbf{p}}{\mathbf{p}_i} + \frac{1-\mathbf{p}}{1-\mathbf{p}_i} \right) \right) \mathbf{f}'(z_i^{(l)}) \quad (12)$$

于是, 可以得到以下偏导数

$$\frac{\partial}{\partial \mathbf{W}_{ij}^{(l)}} J_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = \mathbf{a}_j^{(l)} \delta_i^{(l+1)} \quad (13)$$

$$\frac{\partial}{\partial \mathbf{b}_{ij}^{(l)}} J_{\text{sparse}}(\mathbf{W}, \mathbf{b}) = \delta_i^{(l+1)} \quad (14)$$

然后由梯度下降(Gradient Descent, GD)法<sup>[19]</sup>迭代更新权重参数, 求解目标函数的最优解。稀疏自编码器算法首先初始化权值参数, 然后迭代更新到最优值, 其算法步骤如下:

- (1) 初始化: 对所有  $l$ , 设  $\Delta \mathbf{W}^{(0)} = \mathbf{0}, \Delta \mathbf{b}^{(0)} = \mathbf{0}$ ;
- (2) 迭代: 从  $i=1 \sim m$ ;

- (a) 使用 BP 算法计算  $\nabla_{\mathbf{W}} J(\mathbf{W}, \mathbf{b})$  和  $\nabla_{\mathbf{b}} J(\mathbf{W}, \mathbf{b})$ ;
- (b) 计算  $\Delta \mathbf{W}^{(0)} = \Delta \mathbf{W}^{(0)} + \nabla_{\mathbf{W}^{(0)}} J(\mathbf{W}, \mathbf{b})$ ;
- (c) 计算  $\Delta \mathbf{b}^{(0)} = \Delta \mathbf{b}^{(0)} + \nabla_{\mathbf{b}^{(0)}} J(\mathbf{W}, \mathbf{b})$ 。

- (3) 更新权重参数:  $\mathbf{W}^{(0)} = \mathbf{W}^{(0)} - \alpha \left[ \left( \frac{1}{m} \Delta \mathbf{W}^{(0)} \right) + \lambda \Delta \mathbf{W}^{(0)} \right]$ ;

$$\mathbf{b}^{(0)} = \mathbf{b}^{(0)} - \alpha \left[ \frac{1}{m} \Delta \mathbf{b}^{(0)} \right]$$

## 2.2 卷积稀疏编码 SR 重建

卷积稀疏表示 SR 算法是将图像表示为特征映

射和其对滤波器矩阵的卷积和, 其数学表达式为:

$$\min_{\mathbf{z}} \|\mathbf{X} - \sum_{i=1}^N \mathbf{f}_i \otimes \mathbf{z}_i\|_F^2 + \tau \sum_{i=1}^N \|\mathbf{z}_i\|_1 \quad (15)$$

式中:  $\mathbf{X}$  为一个  $m \times n$  的输入图像;  $\tau$  为正则化参数;  $\{\mathbf{f}_i\}_{i=1,2,\dots,N}$  为滤波器组, 每个滤波器大小为  $s \times s$ ;  $\mathbf{z}_i$  是  $\mathbf{f}_i$  对应的特征映射。

在 CSAE 算法中, 首先由稀疏自编码器训练一组 HR 图像  $\{\mathbf{x}_1, \mathbf{x}_k, \dots, \mathbf{x}_K\}$  及其对应的 LR 图像  $\{\mathbf{y}_1, \mathbf{y}_k, \dots, \mathbf{y}_K\}$  得到有效地稀疏特征映射, 即  $\mathbf{z}_i^l = \mathbf{h}_{\mathbf{W}_l}(\mathbf{y}_i), \mathbf{z}_i^h = \mathbf{h}_{\mathbf{W}_h}(\mathbf{x}_i)$ , 然后再由公式(16)的最优化问题训练 LR 滤波器,

$$\min_{\mathbf{z}_i^l} \|\mathbf{Y} - \sum_{i=1}^N \mathbf{f}_i^l \otimes \mathbf{z}_i^l\|_F^2 + \tau \sum_{i=1}^N \|\mathbf{z}_i^l\|_1 \quad (16)$$

式中:  $\{\mathbf{f}_i^l\}_{i=1 \sim N}$  是  $N$  个 LR 滤波器;  $\mathbf{z}_i^l$  是第  $i$  个滤波器对应的稀疏特征映射。

在训练阶段, 运用交替方向乘法器(Alternating Direction Method of Multipliers, ADMM)算法<sup>[20]</sup>迭代求解  $\{\mathbf{f}^l\}$  的最优解, 即

$$\mathbf{f}^l = \underset{\mathbf{f}}{\text{argmin}} \|\mathbf{Y} - \sum_{i=1}^N \mathbf{f}_i^l \otimes \mathbf{z}_i^l\|_F^2, \text{ s.t. } \|\mathbf{f}_i^l\|_1 \leq 1 \quad (17)$$

同时, 在 LR 和 HR 特征映射之间训练一个映射函数  $\mathbf{W}_M$  来提高 LR 特征映射的空间尺寸和数目, 即

$$\mathbf{z}_j^h(\mathbf{kx}, \mathbf{ky}) = \mathbf{g}(\mathbf{z}_1^l(\mathbf{x}, \mathbf{y}), \mathbf{z}_2^l(\mathbf{x}, \mathbf{y}), \dots, \mathbf{z}_N^l(\mathbf{x}, \mathbf{y}); \mathbf{W}_M) \quad (18)$$

式中:  $\mathbf{k}$  为放大因子;  $\mathbf{z}_j^h(\mathbf{kx}, \mathbf{ky})$  为  $(\mathbf{kx}, \mathbf{ky})$  的特征映射;  $\mathbf{z}_i^h(\mathbf{kx}, \mathbf{ky})$  为  $(\mathbf{x}, \mathbf{y})$  的特征映射,  $\mathbf{W}_M$  是映射函数  $\mathbf{g}(\cdot)$  的参数。函数  $\mathbf{g}(\cdot)$  是一个稀疏线性变换矩阵, 它可由输入 LR 图像稀疏系数估计 HR 图像稀疏系数, 即

$$\begin{aligned} \mathbf{z}_j^h(\mathbf{kx}, \mathbf{ky}) &= \mathbf{g}(\mathbf{z}^l(\mathbf{x}, \mathbf{y}); \mathbf{W}_M) = \mathbf{W}_M^T \mathbf{z}^l(\mathbf{x}, \mathbf{y}) \\ \text{s.t. } \mathbf{W}_M &\geq \mathbf{0}, |\mathbf{W}_M|_1 = 1 \end{aligned} \quad (19)$$

式中:  $\mathbf{z}^l(\mathbf{x}, \mathbf{y})$  表示一个包含  $N$  个 LR 特征映射的向量;  $\mathbf{W}_M$  表示稀疏转换向量。为了确保  $\mathbf{W}_M$  的稀疏性, 令  $\mathbf{W}_M \geq \mathbf{0}, |\mathbf{W}_M|_1 = 1$ 。

HR 滤波器和映射函数的最优化问题可以表示为:

$$\begin{aligned} \{\mathbf{f}^h, \mathbf{W}_M\} &= \min_{\mathbf{f}, \mathbf{W}_M} \|\mathbf{X} - \sum_{j=1}^M \mathbf{f}_j^h \otimes \mathbf{g}(\mathbf{z}_j^l; \mathbf{W}_M)\|_F^2 \\ \text{s.t. } \|\mathbf{f}_i^h\|_1 &\leq \mathbf{e}; \mathbf{W}_M \geq \mathbf{0}, |\mathbf{W}_M|_1 = 1 \end{aligned} \quad (20)$$

式中:  $\mathbf{e}$  为一个约束 HR 滤波器能量的标量。

交替更新公式(20)可以得到滤波器  $\mathbf{f}^h$  和映射函数参数  $\mathbf{W}_M$  的最优解。首先固定  $\mathbf{W}_M$ , 运用随机平均(Stochastic Average, SA)-ADMM 算法<sup>[21]</sup>结合公式(17)

求解 HR 滤波器更新。然后固定  $\mathbf{f}$ , 求解下式最优化问题更新  $\mathbf{W}_M$ , 即

$$\begin{aligned} \{\mathbf{W}_M\} = \underset{\mathbf{W}_M}{\operatorname{argmin}} \|\mathbf{X} - \sum_{j=1}^M \mathbf{f}_j^h \otimes \mathbf{g}(z_j^l; \mathbf{W}_M)\|_F^2 \\ \text{s.t. } \mathbf{W}_M \geq 0, |\mathbf{W}_M|_1 = 1 \end{aligned} \quad (21)$$

利用公式(18)和(21), HR 特征映射表示为  $\{z^h\} = \mathbf{g}(z^l; \mathbf{W}_M)$ 。

在重建阶段, 对 HR 特征映射及其对应的滤波器卷积求和得到 HR 图像, 即

$$\hat{\mathbf{X}} = \sum_{j=1}^M \mathbf{f}_j^h \otimes z_j^h \quad (22)$$

最后将  $\hat{\mathbf{X}}$  与平滑分量合成生成最终的 HR 估计。CSAE 算法首先初始化权值参数, 再由稀疏自编码器训练出 LR 和 HR 特征映射最优值, 然后在卷积神经网络中训练得到滤波器与映射函数, 用于重建 HR 图像, 其算法步骤如下:

- (1) 输入低分辨率图像  $\mathbf{Y}$ ;
- (2) 在稀疏自编码训练阶段, 首先, 初始化  $\Delta \mathbf{W}^{(0)} = 0$ ,  $\Delta \mathbf{b}^{(0)} = 0$ ; 然后, 更新  $z_i^l = \mathbf{h}_{\mathbf{W}_b}(y_i) = \mathbf{f}(\mathbf{W}_l y_i + \mathbf{b}_l)$ ; 及  $z_i^h = \mathbf{h}_{\mathbf{W}_b}(x_i) = \mathbf{f}(\mathbf{W}_h x_i + \mathbf{b}_h)$  最优解。
- (3) 在卷积神经网络训练阶段, 将稀疏自编码训练得到的特征映射作为初始输入, (a) 由公式(17)学习 LR 滤波器; (b) 由公式(20)交替更新训练 HR 滤波器及特征映射函数。
- (4) 在 SR 重建阶段, 由公式(22)估计 HR 图像。
- (5) 输出高分辨率图像估计  $\hat{\mathbf{X}}$ 。

### 3 实验与结果分析


文中采用峰值信噪比 (Peak Signal to Noise Ratio, PSNR)<sup>[22]</sup> 客观对比 CSAE 算法和 CSC 算法<sup>[13]</sup> 并对 8 幅图像进行 SR 重建对比视觉效果。

实验采用一个 3 层的稀疏自编码器网络, 各层节点数为  $s_1=512, s_2=256, s_3=512$ , 迭代次数为 50, 实验设定  $\mathbf{p}=0.1, \alpha=2$ 。在卷积稀疏编码中, LR 图像块的大小为  $3 \times 3$ , 邻近像素间有 1 个像素重叠, HR 图像块的大小为  $9 \times 9$ , 3 个像素重叠, LR 滤波器数目为 800, 大小为  $5 \times 5$ , HR 滤波器数目为 1 200, 放大因子  $k$  分别设置为 2、3 和 4。正则化参数  $\tau=0.02$ , 迭代次数为 1 000。表 1 是在不同放大因子下, 8 幅重建图像的 PSNR 结果对比。从表 1 可以看出, 在不同放大因子的情况下, CSAE 算法的 PSNR 结果比 CSC 算法平均提高近 0.1 dB, 可见客观上 CSAE 算法的重建结果更好。图 3 是 Parrots 图像在不同放大因子情况下的 CSAE 和 CSC 算法的重建图像, CSAE 算法的主观视觉效果更好。

表 1 CSAE 与 CSC 算法的 PSNR 结果对比

Tab.1 PSNR results of CSC and CSAE algorithms

Image	k=2		k=3		k=4	
	CSC	CSAE	CSC	CSAE	CSC	CSAE
Barbara	25.761 6	25.876 2	24.900 7	24.982 3	24.373 8	24.422 9
Boat	29.174 0	29.232 5	26.561 2	26.627 1	25.143 1	25.295 8
Butterfly	30.478 5	30.566 9	27.400 5	27.512 6	25.263 0	25.344 6
Camera-man	27.570 6	27.631 8	25.174 4	25.263 9	24.000 3	24.108 9
Finger-print	27.110 0	27.215 3	22.720 4	22.864 5	18.832 8	18.912 7
House	36.189 9	36.249 5	33.426 9	33.530 3	31.131 1	31.217 9
Lena	32.754 5	32.816 7	29.999 4	30.084 6	28.274 8	28.323 4
Parrots	28.719 8	28.602 7	25.766 6	25.879 1	23.813 9	23.910 6
Mean	29.719 8	29.773 9	26.993 8	27.093 0	25.104 1	25.192 1



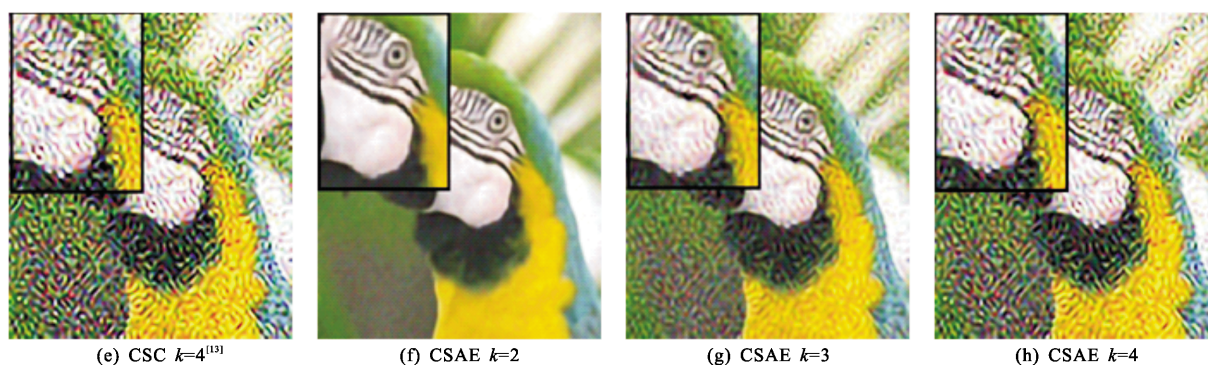


图 3 Parrots 图像重建结果比较  
Fig.3 Reconstructed images of parrots

## 4 结 论

文中针对 CSC 重建算法中,输入图像缺乏足够准确的特征映射的问题,提出一种 CSAE 算法。该算法首先将稀疏自动编码器对输入图像训练得到的特征映射作为输入,然后在卷积神经网络中训练得到 LR 和 HR 滤波器及特征映射函数,最后再由学习到的 HR 滤波器及其相应的特征映射的卷积和重建 HR 图像。文中算法在图像 SR 训练之前利用稀疏自动编码器预训练输入图像得到比人工特征提取更为准确的特征映射,在此基础上学习到更为合适的滤波器字典来重建 HR 图像。实验结果验证文中算法较 CSC 算法进一步提高了图像的重建质量。

### 参考文献:

- [1] Irani M, Peleg S. Improving resolution by image registration [J]. *Cvqip Graphical Models & Image Processing*, 1991, 53 (3): 231-239.
- [2] Lu X, Li X. Multiresolution imaging [J]. *IEEE Trans Cybern*, 2014, 44(1): 149-160.
- [3] Hou H S, Andrews H C. Cubic spline for image interpolation and digital filtering [J]. *IEEE Transaction on Signal Pressing*, 1978, 26(6): 508-517.
- [4] Tai Y W, Liu S, Brown M S, et al. Super resolution using edge prior and single image detail synthesis [C]//*Computer Vision and Pattern Recognition*. IEEE, 2010: 2400-2407.
- [5] Sun J, Sun J, Xu Z, et al. Image super-resolution using gradient profile prior [C]//*IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2008: 1-8.
- [6] You X, Li Q, Tao D, et al. Local metric learning for exemplar-based object detection [J]. *IEEE Transactions on Circuits & Systems for Video Technology*, 2014, 24 (8): 1265-1276.
- [7] Yu J, Gao X, Tao D, et al. A unified learning framework for single image super-resolution [J]. *IEEE Trans Neural Netw Learn Syst*, 2014, 25(4): 780-792.
- [8] Ren J, Liu J, Guo Z. Context-aware sparse decomposition for image denoising and super-resolution [J]. *IEEE Transactions on Image Processing*, 2013, 22(4): 1454-1467.
- [9] Romano Y, Protter M, Elad M. Single image interpolation via adaptive nonlocal sparsity-based modeling [J]. *IEEE Transactions on Image Processing*, 2014, 23(7): 3085.
- [10] Yang J, Wright J, Huang T, et al. Image super-resolution as sparse representation of raw image patches [C]//*Computer Vision and Pattern Recognition*, 2008, IEEE Conference on. IEEE, 2008: 1-8.
- [11] Wang S, Zhang D, Liang Y, et al. Semi-coupled dictionary learning with applications to image super-resolution and photo-sketch synthesis [C]//*Computer Vision and Pattern Recognition*. IEEE, 2012: 2216-2223.
- [12] Zeiler M D, Krishnan D, Taylor G W, et al. Deconvolutional networks [C]//*Computer Vision and Pattern Recognition*. IEEE, 2010: 2528-2535.
- [13] Gu S, Zuo W, Xie Q, et al. Convolutional sparse coding for image super-resolution [C]//*IEEE International Conference on Computer Vision*. IEEE, 2015: 1823-1831.
- [14] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *American Association for the Advancement of Science*, 2006, 313(5786): 504-507.
- [15] Hinton G E, S. Osindero Y W. A fast learning algorithm for

- deep belief nets [J]. *Neural Computation*, 2006, 18 (7): 1527-1554.
- [16] Lee H, Ekanadham C, Ng A Y. Sparse deep belief net model for visual area V2 [C]//International Conference on Neural Information Processing Systems. Curran Associates Inc, 2007: 873-880.
- [17] Schölkopf B, Platt J, Hofmann T. Greedy layer-wise training of deep networks [C]//Advances in Neural Information Processing Systems 19, Proceedings of the Twentieth Conference on Neural Information Processing Systems, 2007: 153-160.
- [18] Lee Q V, Ngiam J, Coates A, et al. On optimization methods for deep learning [C]//Proceedings of the 28th International Methods for Deep Learning, 2011: 265-272.
- [19] Kivinen J, Warmuth M K. Exponentiated gradient versus gradient descent for linear predictors [J]. *Information and Computation*, 1997, 132(1): 1-63.
- [20] Wohlberg B. Efficient convolutional sparse coding [C]//IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2014: 7173-7177.
- [21] Zhong L W, Kwok J T. Fast stochastic alternating direction method of multipliers [C]//International Conference on International Conference on Machine Learning, 2014: 1-46.
- [22] Kwang In Kim, Younghee Kwon. Single-image super-resolution using sparse regression and natural image prior [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(6): 1127.