

自外而内的单幅图像超分辨率复原算法

郑向涛^{1,2}, 袁媛¹, 卢孝强^{1*}

¹中国科学院西安光学精密机械研究所瞬态光学与光子技术国家重点实验室

光学影像分析与学习中心, 陕西 西安 710119;

²中国科学院大学, 北京 100049

摘要 单幅图像超分辨率(SR)复原是一个病态逆问题,需要利用图像的先验知识进行正则化约束。提出了一种同时考虑外在样例和内在自相似性的单幅图像 SR 复原算法,其中外在先验知识是通过卷积神经网络从外在低分辨率-高分辨率图像对学习得到的,而内在先验约束由聚类 and 低秩近似实现。实验结果表明,本方法在复原效果和稳健性方面优于已有方法。

关键词 图像处理; 超分辨率; 样例学习; 深度卷积网络; 自相似

中图分类号 TP391.4 **文献标识码** A

doi: 10.3788/AOS201737.0318006

Single Image Super-Resolution Restoration Algorithm from External Example to Internal Self-Similarity

Zheng Xiangtao^{1,2}, Yuan Yuan¹, Lu Xiaoqiang¹

¹Center for Optical Imagery Analysis and Learning (OPTIMAL), State Key Laboratory of Transient Optics and Photonics, Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Sciences, Xi'an, Shaanxi 710119, China;

²University of the Chinese Academy of Sciences, Beijing 100049, China

Abstract Single image super-resolution (SR) restoration is an ill-posed inverse problem, in which regularization restriction is done with image priori knowledge. One single image SR method is proposed which simultaneously taking external example and internal self-similarity into account. Here the external knowledge is learned by convolutional neural network from external low-resolution-high-resolution image pairs, while the internal prior is utilized by cluster and low-rank approximation. The experimental results show that the proposed method outperforms many other existing super-resolution methods in recovery effect and robustness.

Key words image processing; super resolution; example-based methods; convolutional neural network; self-similarity

OCIS codes 100.6640; 100.2000; 110.3010

1 引 言

超分辨率(SR)技术是指从单幅或多幅低分辨率(LR)图像恢复出相同场景的高分辨率(HR)图像的方法^[1-2]。SR 技术^[3-4]可以增加现有图像的空间分辨率,从而打破传感器和光学成像的固有分辨率限制。与多幅图像相比,单幅图像只有少量信息,其病态重建问题更为复杂。单幅图像 SR 技术的关键是建立从 LR 图像到 HR 图像的非线性映射,由于 LR 图像信息不充足,因此需要根据先验知识提供额外信息。

近几年来,学者们提出许多优秀的单幅图像 SR 算法,其中最有效的算法大都基于样例学习技术。根据

收稿日期: 2016-10-08; **收到修改稿日期:** 2016-11-22

基金项目: 国家 973 计划(2013CB336500,2012CB719905)、国家自然科学基金(61232010,61472413)、中国科学院重点部署项目(KGZD-EW-T03)、中国科学院光谱成像技术重点实验室开放基金(LSIT201408)

作者简介: 郑向涛(1988—),男,博士研究生,主要从事计算机视觉机器学习方面的研究。E-mail: zhengxiangtao@opt.cn

导师简介: 袁媛(1980—),女,教授,博士生导师,主要从事计算机视觉机器学习方面的研究。E-mail: yuanyu@opt.ac.cn

* **通信联系人.** E-mail: luxq66666@gmail.com

训练数据来源不同,现有的 SR 方法可以分为外在样例学习方法和内在先验学习方法。外在样例学习方法通过学习和利用数据库中成对的 LR 和 HR 图像之间的非线性映射关系,来对测试图像进行 SR 重建。现有的学习算法有最近邻法^[5]、流形学习^[6]、词典学习^[7]、局部线性回归^[8-10]及卷积网络^[11]等。内在先验学习方法根据图像中的自相似特性^[12],从输入图像自身搜索样例图像块,利用内在图像块的冗余性进行图像 SR 重建。Ebrahimi 等^[13]结合分形编码和非局部均值滤波^[14]提出基于自相似性的 SR 方法。Freedman 等^[15]指出在局部空间邻域内存在大量自相似的图像块。Michaeli 等^[16]利用自相似性进行模糊核和 HR 图像的联合估计。Singh 等^[17]利用自相似原则进行噪声图像的 SR 复原。

外在样例学习方法可以从训练集中提取所需的高频信息,但是训练集是有限的,不能保证任意图像块都能找到相应的匹配,易产生干扰噪声或过平滑问题。内在先验学习方法利用图像自身的冗余,不需要额外的训练样本,但是不能有效处理没有重复结构的不规则纹理图像块。利用内在自相似图像块进行 SR 重建时,图像块间的错误匹配会带来很多虚假纹理。针对这些不足,本文提出了自外而内的单幅图像 SR 复原方法,同时考虑了外在样例学习方法和内在先验学习方法,在保持图像内在自相似先验约束的基础上,利用数据库中成对的 LR 和 HR 图像训练端到端的深度卷积网络,通过迭代优化得到估计 HR 图像的高频信息,建立了外在训练学习和内在先验约束的联合优化模型。实验结果显示,本方法的重建结果在主观视觉效果和客观评价上均令人满意。

2 理论建模基础

2.1 观测模型

假设 \mathbf{X} 是需要估计的 HR 图像的矩阵表示, \mathbf{Y} 是观察到的 LR 图像的矩阵表示。其中, LR 图像由 HR 图像退化得到:

$$\mathbf{Y} = \mathbf{H}\mathbf{S}\mathbf{X} + \mathbf{n}, \quad (1)$$

式中 \mathbf{n} 是噪声污染矩阵, \mathbf{S} 是模糊算子, \mathbf{H} 是下采样操作。SR 问题就是已知给定的单幅 LR 图像矩阵 \mathbf{Y} , 重建出相同场景的 HR 图像矩阵 \mathbf{X} 。为了准确估计出 HR 图像矩阵 \mathbf{X} , 需要引入图像的一些先验或正则约束项:

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \|\mathbf{Y} - \mathbf{H}\mathbf{S}\mathbf{X}\|_F^2 + \lambda \mathbf{g}(\mathbf{X}), \quad (2)$$

式中 $\hat{\mathbf{X}}$ 是估计得到的 HR 图像矩阵, $\|\mathbf{Y} - \mathbf{H}\mathbf{S}\mathbf{X}\|_F^2$ 是观测误差项(其中 $\|\cdot\|_F$ 表示 Frobenius 范数), $\mathbf{g}(\mathbf{X})$ 代表 HR 图像的内在正则约束项, λ 为加权平衡参数。当 $\lambda = 0$ 时, 正则项将不起作用, (2) 式转化为最简单的最小二乘法。

2.2 基于深度卷积网络的超分辨率方法

近年来,深度学习在许多计算机视觉问题上都取得了很大的成功,展现了学习数据集本质特征的强大能力。研究学者提出了基于深度卷积网络的图像 SR 方法,利用深度学习在数据库中成对的 LR 和 HR 图像上进行训练学习。1)对 LR 图像进行双三次插值,得到尺寸大小与 HR 图像矩阵 \mathbf{X} 相同的插值图 \mathbf{Y}^B ; 2)将插值图作为深度卷积网络的输入图像,建立端到端的 SR 学习架构。该方法的深度网络结构包括三个卷积层:

$$\begin{cases} \mathbf{F}_1(\mathbf{Y}^B) = \varphi(0, \mathbf{W}_1 * \mathbf{Y}^B + \mathbf{B}_1) \\ \mathbf{F}_2(\mathbf{Y}^B) = \varphi[0, \mathbf{W}_2 * \mathbf{F}_1(\mathbf{Y}^B) + \mathbf{B}_2], \\ \mathbf{F}_3(\mathbf{Y}^B) = \mathbf{W}_3 * \mathbf{F}_2(\mathbf{Y}^B) + \mathbf{B}_3 \end{cases} \quad (3)$$

式中 $\{\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3\}$ 是每一层的加权矩阵, $\{\mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3\}$ 是每一层的偏移参数, $*$ 代表卷积操作。 φ 是非线性激活函数,这里选取修正线性单元。第三个卷积层的输出 $\mathbf{F}_3(\mathbf{Y}^B)$ 即待估计的 HR 图像。在训练过程,该神经网络需要学习参数 $\Theta = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3, \mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3\}$ 。该参数可以通过最小化神经网络输出和 HR 图像之间的误差损失进行训练估计。假设训练数据库包括 LR 和 HR 图像对 $\{\mathbf{Y}_i, \mathbf{X}_i | i = 1, 2, \dots, m\}$, 其中 m 是数据库中训练数据对的数目。在训练过程,以该卷积网络的输出与对应 HR 图像矩阵 \mathbf{X} 之间的均方误差作为驱

动损失函数:

$$L(\Theta) = \frac{1}{m} \sum_{i=1}^m [\|F_3(\mathbf{Y}_i^B) - \mathbf{X}_i\|_F^2]. \quad (4)$$

(4)式可通过随机梯度下降(SGD)和反向传播算法进行训练求解。

3 自外而内的单幅图像超分辨率方法

3.1 方法介绍

同时考虑外在样例学习和内在先验约束,提出自外而内的 SR 方法。首先引入(4)式的外在样例学习,将(2)式中的观测误差项 $\|\mathbf{Y} - \mathbf{H}\mathbf{S}\mathbf{X}\|_F^2$ 替换为外在样例学习方法的估计误差项 $\|\mathbf{X} - \mathbf{f}(\mathbf{Y})\|_F^2$,目标公式可以表示为

$$\hat{\mathbf{X}} = \arg \min_{\mathbf{X}} \alpha \|\mathbf{X} - \mathbf{f}(\mathbf{Y})\|_F^2 + \mathbf{g}(\mathbf{X}), \quad (5)$$

式中 α 是平衡参数,用于调节第一项和第二项权重。第一项主要保证 HR 图像矩阵 \mathbf{X} 与外在训练模型 $\mathbf{f}(\mathbf{Y})$ 的估计误差最小,第二项主要保证复原的 HR 图像尽可能保持图像内在的自相似特性。如果 α 趋于0,只有图像内在先验约束起作用;反之 α 趋于 ∞ ,只有外在样例学习起作用。

在本方法中,第一项选取深度卷积网络作为外在样例学习,第二项选取聚类自相似作为图像内在先验约束项。在(5)式中,定义 LR 图像到 HR 图像的映射函数为

$$\mathbf{f}(\mathbf{Y}) = \mathbf{F}_3[\mathbf{f}_B(\mathbf{Y})], \quad (6)$$

式中 $\mathbf{f}_B(\cdot)$ 表示双三次插值操作, $\mathbf{F}_3(\cdot)$ 为(3)式的深度卷积网络。

对于第二项图像的内在先验约束,1)对图像进行重叠分块,得到大小相等的若干小图像块,相邻图像块有一定的重叠;2)对图像块进行聚类分析,把图像块分成多个类;3)对每类图像块进行自相似约束。选取高斯混合模型进行图像块的聚类。对于 HR 图像矩阵 \mathbf{X} 的所有重叠图像块 $\{\mathbf{x}_i | i = 1, 2, \dots, N\}$,假设图像块 \mathbf{x}_i 服从 K 个高斯混合分布:

$$p(\mathbf{x}_i | \Delta) = \sum_{k=1}^K \omega_k p_k(\mathbf{x}_i | \delta_k), \quad (7)$$

式中 $\Delta = (\omega_1, \dots, \omega_K, \delta_1, \dots, \delta_K)$ 是参数集, $\sum_{k=1}^K \omega_k = 1$; δ_k 表示第 k 个高斯密度函数的参数; $p_k(\mathbf{x}_i | \delta_k) = \exp\left[-\frac{1}{2}(\mathbf{x}_i - \boldsymbol{\mu}_k)^\top \Sigma_k^{-1}(\mathbf{x}_i - \boldsymbol{\mu}_k)\right]$ 表示 \mathbf{x}_i 是第 k 类的密度函数,其中 $\boldsymbol{\mu}_k$ 表示均值, Σ_k 表示协方差矩阵。该模型参数通过期望最大(EM)算法进行极大化似然估计。对于每一个图像块, \mathbf{x}_i 属于类别 k 的似然概率为

$$p(k | \mathbf{x}_i) = \frac{\omega_k p_k(\mathbf{x}_i | \delta_k)}{\sum_{k=1}^K \omega_k p_k(\mathbf{x}_i | \delta_k)}, \quad k = 1, 2, \dots, K, \quad (8)$$

选取使得(8)式概率最大的类别作为 \mathbf{x}_i 的聚类类别。定义 $\mathbf{R}_k \mathbf{X}$ 是选取第 k 类图像块向量集合组成的矩阵。很显然,同一类的图像块存在高度相似性,故可以认为每一类向量化图像块集合组成的矩阵近似为低秩矩阵: $\mathbf{R}_k \mathbf{X} = \mathbf{Z}_k + \mathbf{V}_k$, \mathbf{Z}_k 是低秩矩阵, \mathbf{V}_k 是误差矩阵。这个秩最小化问题可以近似表示成

$$\mathbf{X} = \arg \min_{\mathbf{X}} \|\mathbf{R}_k \mathbf{X} - \mathbf{Z}_k\|_F^2 + \beta \|\mathbf{Z}_k\|_*, \quad (9)$$

式中 $\|\cdot\|_*$ 表示核范数,是矩阵奇异值的和。(9)式表示第 k 类向量化图像块集合高度相关,将其推广到所有类别的图像块集合,并结合外在样例学习得到最终目标公式:

$$\{\mathbf{X}, \{\mathbf{Z}_k\}\} = \arg \min_{\mathbf{X}, \{\mathbf{Z}_k\}} \alpha \|\mathbf{X} - \mathbf{F}_3[\mathbf{f}_B(\mathbf{Y})]\|_F^2 + \sum_{k=1}^K (\|\mathbf{R}_k \mathbf{X} - \mathbf{Z}_k\|_F^2 + \beta \|\mathbf{Z}_k\|_*). \quad (10)$$

(10)式结合了外在样例学习和内在先验约束,同时考虑了外在数据库提供的学习知识和图像内本身的聚类自相似特性。定义 $\tilde{\mathbf{X}}_k = \mathbf{R}_k \mathbf{X}$ 为第 k 类图像块集合组成的矩阵,对应的卷积神经网络输出是

$\tilde{\mathbf{Y}}_k = \mathbf{R}_k \mathbf{F}_3[\mathbf{f}_B(\mathbf{Y})]$, 则(10)式重新写作

$$\{\{\tilde{\mathbf{X}}_k\}, \{\mathbf{Z}_k\}\} = \arg \min_{\{\tilde{\mathbf{X}}_k\}, \{\mathbf{Z}_k\}} \sum_{k=1}^K \alpha \|\tilde{\mathbf{X}}_k - \tilde{\mathbf{Y}}_k\|_F^2 + (\|\tilde{\mathbf{X}}_k - \mathbf{Z}_k\|_F^2 + \beta \|\mathbf{Z}_k\|_*). \quad (11)$$

从(11)式可以看出, 该优化问题可以分解为 K 个子问题:

$$\{\tilde{\mathbf{X}}_k, \mathbf{Z}_k\} = \arg \min_{\tilde{\mathbf{X}}_k, \mathbf{Z}_k} \alpha \|\tilde{\mathbf{X}}_k - \tilde{\mathbf{Y}}_k\|_F^2 + (\|\tilde{\mathbf{X}}_k - \mathbf{Z}_k\|_F^2 + \beta \|\mathbf{Z}_k\|_*). \quad (12)$$

(12)式是第 k 个子问题, 可以通过交替迭代求解。

固定 $\{\tilde{\mathbf{X}}_k\}$, 求解 \mathbf{Z}_k , (12)式简化为

$$\mathbf{Z}_k = \arg \min_{\mathbf{Z}_k} \|\tilde{\mathbf{X}}_k - \mathbf{Z}_k\|_F^2 + \beta \|\mathbf{Z}_k\|_* . \quad (13)$$

(13)式通过加权奇异值阈值法求解。

固定 $\{\mathbf{Z}_k\}$, 求解 $\tilde{\mathbf{X}}_k$, (12)式可简化为

$$\tilde{\mathbf{X}}_k = \arg \min_{\tilde{\mathbf{X}}_k} \alpha \|\tilde{\mathbf{X}}_k - \tilde{\mathbf{Y}}_k\|_F^2 + \|\tilde{\mathbf{X}}_k - \mathbf{Z}_k\|_F^2 . \quad (14)$$

(14)式是二次优化问题, 其最优解为

$$\tilde{\mathbf{X}}_k = (\alpha + 1)^{-1} (\alpha \tilde{\mathbf{Y}}_k + \mathbf{Z}_k) . \quad (15)$$

3.2 算法流程

自外而内的 SR 方法分成两个阶段: 训练阶段和测试阶段。具体的步骤如下:

1) 训练过程

步骤 1: 输入 LR 和 HR 图像对的训练数据库;

步骤 2: 利用双三次插值将 LR 图像插值放大到与 HR 图像尺寸大小一致;

步骤 3: 应用(4)式, 学习从插值 LR 图像到 HR 图像的映射函数, 得到训练神经网络的参数集

$$\Theta = \{\mathbf{W}_1, \mathbf{W}_2, \mathbf{W}_3, \mathbf{B}_1, \mathbf{B}_2, \mathbf{B}_3\} .$$

2) 测试过程

步骤 4: 对于测试图像 \mathbf{Y} , 应用(6)式得到外在样例学习结果, 作为重建图像 \mathbf{X} 的初始值;

步骤 5: 把重建图像 \mathbf{X} 进行分块处理, 应用(8)式对图像块进行聚类分析, 得到聚类结果 $\tilde{\mathbf{X}}_k = \mathbf{R}_k \mathbf{X}$;

步骤 6: 应用(11)式, 利用(13)~(15)式对每一类图像块集合 $\{\tilde{\mathbf{X}}_k\}$ 进行优化求解;

步骤 7: 利用得到的 K 个图像块集合 $\{\tilde{\mathbf{X}}_k\}$, 还原重建 HR 图像 $\hat{\mathbf{X}}$ 。

4 实验结果分析

4.1 实验设置

为了验证所提方法的有效性, 选取三个国际公开的 SR 数据库: Set5、Set14 和 B100。并在三种常用放大因子(2、3 和 4) 情况下进行实验验证。实验中以双三次插值(Bicubic)方法作为基准对比方法, 并选择 Zeyde^[18]、全局回归(GR)^[8]、锚点邻域回归(ANR)^[8]、最近邻域最小二乘分解嵌入方法(NE+LS)^[8]、最近邻域非负最小二乘分解嵌入方法(NE+NNLS)^[8]、最近邻局部线性嵌入方法(NE+LLE)^[8]、卷积神经网络(CNN)^[11]和调整锚点邻域回归(A+)^[9]作为对比实验, 以检验本方法的性能。利用峰值信噪比(PSNR)评价不同图像 SR 方法的性能。

从(10)式可以看出, 本方法含有两个参数: α 和 β 。为了选择出最优参数, 选取数据库 Set5 中的蝴蝶图像, 在放大 2 倍情况下, 计算不同参数对峰值信噪比的影响。由图 1(a)可以看出, PSNR 随着 α 的变化先升高再降低, 当 $\alpha=0.7$ 时峰值信噪比最高。当 α 过小时, (10)式的第一项不起作用, 只有内在约束项起作用。当 α 过大时, (10)式的第二项近似不起作用, 只有外在样例学习起作用。由图 1(b)看出, β 越大, 低秩约束越强, PSNR 越好。但是当 β 过大时, PSNR 减小。因此在实验过程, 本方法的参数设定为: $\alpha=0.7, \beta=100$ 。




图 1 不同参数对放大两倍的蝴蝶图像重建的影响。(a) α ; (b) β

Fig. 1 Influence of different parameters on reconstruction of butterfly image with double upscaling. (a) α ; (b) β

4.2 实验结果对比

通过实验结果来验证本方法的有效性。为了评价图像重建的质量,同时从主观视觉和客观评价两个方面衡量对比结果。以数据库 Set5 中的蝴蝶图像为例,图 2 为放大 2 倍情况下,不同方法的主观视觉图和相应峰值信噪比。主观上,可以看出本方法的视觉效果最好,优于现有方法中最好的 CNN 和 A+方法。其他对比方法,在重构的图像边缘处容易产生伪影和振铃效应,一些细节没有较好地恢复出来。本方法恢复的局部细节信息清晰细腻,整体效果更接近原始图像。由于本方法考虑了内在图像块自相似特性,因此恢复的视觉效果最好,产生的纹理也最丰富。客观指标评价上,双三次插值方法的峰值信噪比最低,只有 27.43 dB,大部分对比算法只能达到 30 dB 左右,只有 CNN、A+和本方法能够达到 32 dB 以上。其中本方法在峰值信噪比上是最好的,能够达到 32.77 dB。




图 2 放大 2 倍的蝴蝶图像的超分辨率重建结果。(a) 双三次插值方法(27.43 dB); (b) Zeyde 的方法(30.65 dB); (c) 全局回归(29.06 dB); (d) 锚点邻域回归(30.48 dB); (e) 最近邻域最小二乘分解嵌入方法(30.41 dB); (f) 最近邻域非负最小二乘分解嵌入方法(30.03 dB); (g) 最近邻局部线性嵌入方法(30.38 dB); (h) 卷积神经网络(32.20 dB); (i) A+(32.00 dB); (j) 本方法(32.77 dB)

Fig. 2 Super-resolution reconstruction results of butterfly image with double upscaling. (a) Bicubic (27.43 dB); (b) Zeyde (30.65 dB); (c) GR (29.06 dB); (d) ANR (30.48 dB); (e) NE+LS (30.41 dB); (f) NE+NNLS (30.03 dB); (g) NE+LLE (30.38 dB); (h) CNN (32.20 dB); (i) A+ (32.00 dB); (j) proposed method (32.77 dB)

为了测试本方法的稳健性,在三个数据库(Set5、Set14 和 B100)和三种不同放大因子(2、3 和 4)情况下做了 SR 实验。表 1 显示了 10 种不同的方法在三个数据库、三种放大因子下测试时的平均峰值信噪比 (APSNR)。从表 1 可知,本方法的峰值信噪比高于其他 9 种方法。相对传统的双三次插值方法平均提高了 1 dB~3 dB,比起前沿最好的 CNN 和 A+方法提高了 0.3 dB。

表 1 不同 SR 方法的平均峰值信噪比对比结果
Table 1 Comparison of APSNR of different SR methods

| Dataset | Amplification factor | APSNR /dB | | | | | | | | | |
|---------|----------------------|-----------|-------|-------|-------|-------|---------|--------|-------|-------|-----------------|
| | | Bicubic | Zeyde | GR | ANR | NE+LS | NE+NNLS | NE+LLE | CNN | A+ | Proposed method |
| Set5 | 2 | 33.66 | 35.78 | 35.13 | 35.83 | 35.66 | 35.43 | 35.77 | 36.34 | 36.55 | 36.68 |
| | 3 | 30.40 | 31.90 | 31.41 | 31.92 | 31.78 | 31.60 | 31.84 | 32.39 | 32.59 | 32.77 |
| | 4 | 28.42 | 29.69 | 29.34 | 29.69 | 29.55 | 29.47 | 29.61 | 30.09 | 30.28 | 30.50 |
| Set14 | 2 | 30.23 | 31.81 | 31.36 | 31.80 | 31.69 | 31.55 | 31.76 | 32.18 | 32.28 | 32.46 |
| | 3 | 27.54 | 28.67 | 28.31 | 28.65 | 28.59 | 28.44 | 28.60 | 29.00 | 29.13 | 29.31 |
| | 4 | 26.00 | 26.88 | 26.60 | 26.85 | 26.81 | 26.72 | 26.81 | 27.20 | 27.32 | 27.51 |
| B100 | 2 | 29.32 | 30.40 | 30.23 | 30.44 | 30.36 | 30.27 | 30.41 | 30.71 | 30.77 | 30.88 |
| | 3 | 27.15 | 27.87 | 27.70 | 27.89 | 27.83 | 27.73 | 27.85 | 28.10 | 28.18 | 28.28 |
| | 4 | 25.92 | 26.51 | 26.37 | 26.51 | 26.45 | 26.41 | 26.47 | 26.66 | 26.77 | 26.85 |

5 结 论

提出了一种新的自外而内图像 SR 复原方法,该算法充分考虑了外在数据库训练得到的先验知识和图像内在的自相似特性。通过引入深度卷积网络进行了外在数据的训练学习,对重建图像进行了内在分块聚类分析,拓展了图像本身的自相似特性以重新学习图像块之间的内在自相似联系。实验结果表明,提出的 SR 算法的复原效果超过了现有大部分 SR 方法的复原效果。

参 考 文 献

- [1] Lu X, Huang Z, Yuan Y. MR image super-resolution via manifold regularized sparse learning[J]. Neurocomputing, 2015, 162: 96-104.
- [2] Hu Y, Wnag 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.
- [3] Lu X, Yuan Y, Yan P. Alternatively constrained dictionary learning for image superresolution[J]. IEEE Transactions on Cybernetics, 2014, 44(3): 366-377.
- [4] Zhou Jinghong, Zhou Cui, Zhu Jianjun, *et al.* A method of super-resolution reconstruction for remote sensing image based on non-subsampled contourlet transform[J]. Acta Optica Sinica, 2015, 35(1): 0110001.
周靖鸿, 周 璇, 朱建军, 等. 基于非下采样轮廓波变换遥感影像超分辨重建方法[J]. 光学学报, 2015, 35(1): 0110001.
- [5] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution[J]. IEEE Computer Graphics and Applications, 2002, 22(2): 56-65.
- [6] Chang H, Yeung D Y, Xiong Y M. Super-resolution through neighbor embedding[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2004, 1: 275-282.
- [7] Yang J, Wright J, Huang T, *et al.* Image super-resolution via sparse representation[J]. IEEE Transactions on Image Processing, 2010, 19(11): 2861-2873.
- [8] Timofte R, Smet V, Gool L. Anchored neighborhood regression for fast example-based super-resolution[C]. IEEE International Conference on Computer Vision, 2013: 1920-1927.
- [9] Timofte R, Smet V, Gool L. A+: Adjusted anchored neighborhood regression for fast super-resolution[C]. Asian Conference on Computer Vision, 2014, 9006: 111-126.
- [10] Yang C Y, Yang M H. Fast direct super-resolution by simple functions[C]. IEEE International Conference on Computer Vision, 2013: 561-568.
- [11] Dong C, Loy C L, He K, *et al.* Learning a deep convolutional network for image super-resolution[C]. European Conference on Computer Vision, 2014, 8692: 184-199.
- [12] Yang C Y, Huang J B, Yang M H. Exploiting self-similarities for single frame super-resolution[C]. Asian Conference on Computer Vision, 2010, 6494: 497-510.
- [13] Ebrahimi M, Vrscay E. Solving the inverse problem of image zooming using self-examples[C]. International

-
- Conference on Image Analysis and Recognition, 2007, 4633: 117-130.
- [14] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2005: 8624018.
- [15] Freedman G, Fattal R. Image and video upscaling from local self-examples[J]. ACM Translation on Graphics, 2011, 30(2): 12.
- [16] Michaeli T, Irani M. Nonparametric blind super-resolution[C]. IEEE International Conference on Computer Vision, 2013: 945-952.
- [17] Singh A, Porikli F, Ahuja N. Super-resolving noisy images[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 2846-2853.
- [18] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations[C]. International Conference on Curves and Surfaces, 2010, 6920: 711-730.