

# 局部线性嵌入的快速单幅图像超分辨率技术

姜杰, 刘哲, 吕林涛

(西京学院 信息工程学院, 陕西 西安 710123)

**摘要:** 图像超分辨率的目的是在给定低分辨率图像的基础上产生超分辨率图像。单幅图像超分辨率是个病态和欠定的问题, 需要通过样本学习和图像先验约束来重构图像丢失的高频细节。本文提出了一种基于局部线性嵌入的快速单幅图像超分辨率技术。首先, 该方法利用大量的自然图像建立高低分辨率图像块样本训练库; 其次, 运用聚类算法将具有相似性质的高低分辨率样本块进行聚类; 再次, 基于局部线性嵌入技术, 通过样本训练来学习低分辨率图像与高分辨率图像之间的映射函数; 最后, 用过映射函数来重构高分辨率图像。实验结果表明, 本文算法不仅能高质量重构高分辨图像, 而且快速高效。

**关键词:** 超分辨率; 局部线性嵌入; 样本学习

中图分类号: TP391.41

文献标识码: A

文章编号: 1001-8891(2018)01-0039-08

## Fast Single-image Super Resolution Technique Based on Local Linear Embedding

JIANG Jie, LIU Zhe, LV Lintao

(Department of electronic and information engineering, Xijing University, Xi'an 710123, China)

**Abstract:** The goal of single-image super-resolution is to generate a super-resolution image based on a given low-resolution input. It is an ill-posed and under-determined problem that requires exemplars or priors to reconstruct the missing high-frequency details. In this paper, a fast single-image super-resolution technique based on local linear embedding is proposed. Firstly, this method uses a large number of natural images to establish a sample training library of high- and low-resolution image blocks. Secondly, the clustering algorithm is used to cluster the high- and low-resolution image blocks with similar properties. Thirdly, the mapping function between the low- and high-resolution images is studied by sample training based on local linear embedding techniques. Finally, the high-resolution image is reconstructed by using the mapping function. The experimental results show that such an algorithm can reconstruct high-resolution high-quality images fast and efficiently.

**Key words:** super resolution, local linear embedding, exemplars learning

### 0 引言

高分辨率意味着图像中的像素密度高, 能够提供更为丰富的图像细节, 而这些细节在许多实际应用中不可或缺, 所以图像超分辨率技术在医学诊断、模式识别、视频监控、生物鉴别、高清晰电视成像、遥感图像解译、高空对地观测等领域有着广泛的应用。超分辨率(SR, Super-Resolution)技术是指从单幅或多幅低分辨率(LR, Low-Resolution)图像恢复出相同场景的高分辨率(HR, High-Resolution)图像的方法<sup>[1-2]</sup>。超分辨率技术<sup>[3-4]</sup>可以增加现有图像的空间分辨率, 从

而克服传感器和光学成像的固有分辨率限制。与多幅图像超分辨率技术相比, 单幅图像只有少量信息, 病态重建问题更为复杂。单幅图像超分辨率技术的关键是建立从低分辨率图像到高分辨率图像的非线性映射, 由于低分辨率图像缺失信息, 因此超分辨率需要根据先验知识提供额外信息。

目前, 单幅图像超分辨率技术(SISR, Single Image Super-Resolution)较为前沿的方法是基于复杂的机器学习算法<sup>[4-5]</sup>来学习从低分辨率到高分辨率的映射函数, 其中应用最为广泛的算法之一是基于稀疏字典学习方法, 其假设可以使用字典原子的稀疏编码来表示

收稿日期: 2017-05-17; 修订日期: 2018-01-09.

作者简介: 姜杰(1984-), 女, 讲师, 硕士, 研究方向为图像处理、传感器网络应用。

基金项目: 国家自然科学基金项目(61473237); 西京学院科研基金项目(XJ150121)。

自然图像块。特别是耦合字典学习方法<sup>[6-8]</sup>实现了很好的单幅图像超分辨率的结果。Timofte<sup>[9]</sup>通过研究指出了该方法的计算瓶颈,并提出用许多较小的字典替换单个字典,从而避免在推理期间耗时的稀疏编码步骤,大大提高了计算速度,同时保持与以前方法相同的超分辨率结果精度。

稀疏字典学习技术<sup>[4, 10-11]</sup>,其主要思想是高低分辨率图像块对具有相同的稀疏字典表示。然而,该稀疏约束同时涉及在训练和推理阶段最小化 L1 范数函数,从而导致复杂的数学计算<sup>[12-14]</sup>。最近,随着学者对自然图像块流形结构的更深的理解,基于流行学习方法的单幅图像超分辨率技术<sup>[12-15, 16]</sup>有了很大进展。流形学习就是从高维采样数据中恢复低维流形结构,即找到高维空间中的低维流形,并求出相应的嵌入映射,以实现维数约简或者数据可视化。它是从观测到的现象中寻找事物的本质,找到产生数据的内在规律。近年来,耗时复杂的稀疏字典技术已经向更高效的流行学习模型转变。基于流行的学习,将耗时的推理阶段学习转为离线学习,大大降低了学习的复杂性,提高了算法的效率和精度。

在本文中,提出了一种基于局部线性嵌入的流行学习单幅图像超分辨率方法。首先,该方法通过大量的自然图像建立高低分辨率图像块样本训练库,并通过聚类算法将具有相似性质的高低分辨率样本块进行聚类;其次,将聚类中低分辨率图像块运用双三次插值算法插值到与之对应的聚类高分辨率图像块的大小,利用局部线性嵌入的流行学习算法学习进行样本训练,来离线学习聚类中低分辨率图像块与高分辨率图像块之间的映射函数,并且将映射函数进行存储;再次,将输入低分辨率图像进行重叠分块,并在样本库中搜索最近邻的高低分辨率样本聚类所对应的映射函数,通过映射函数用低分辨率图像块来重构高分辨率图像块;最后,将重构图像重叠部分进行平均。实验结果表明,本文算法不仅能很好重构图像的高频细节,还能很好的恢复图像的纹理特征,同时本文算法具有很高的执行效率。

### 1 传统的邻域嵌入超分辨算法框架

传统的邻域嵌入超分辨率重建算法<sup>[10-13, 16]</sup>给出了一种描述高分辨率图像块和低分辨率图像块之间关系的方法:高分辨率图像块和对应的低分辨率图像块在同一个流形上,并且具有相同的局部几何结构。在训练样本中寻找目标图像块的特征最相似的  $k$  个邻近块,通过极小化他们的重构误差获得一组最优权重。利用这一组最优权重和  $k$  个邻近块对应的高分

辨率图像块的线性组合合成重建高分辨率图像块。邻域嵌入算法的超分辨率重建主要分为 3 个步骤:

1) 利用低分辨率样本图像块像素的一阶、二阶梯度表示其特征,并利用特征间的欧式距离来描述图像块的局部几何结构,由此找到目标低分辨率图像块  $x_t^q$  的  $k$  个邻近块  $N_q = \{x_s^1, x_s^2, \dots, x_s^k\}$ ;

2) 通过极小化重构误差计算权重:

$$\varepsilon_q = \min \left\| x_t^q - \sum_{x_s^p \in N_q} w_{pq} x_s^p \right\|^2 \quad (1)$$

$w_{pq}$  满足  $\sum_{x_s^p \in N_q} w_{pq} = 1$ , 并且如果  $x_s^p \notin N_q$ ,  $w_{pq} = 0$ ;

3) 将式(1)所求的权重代入式(2)求解高分辨率图像块

$$y_t^q = \sum_{x_s^p \in N_q} w_{pq} y_s^p \quad (2)$$

式中:  $y_s^p$  是与低分辨率块  $x_s^p$  对应的高分辨率块,将求得的高分辨率块  $y_t^q$  加上均值  $D_t^q$  就可得到最终的高分辨率图像块  $Y_t^q$ :

$$Y_t^q = y_t^q + D_t^q \quad (3)$$

图 1 给出了传统邻域嵌入超分辨率重建算法框架图,从图中可以看出邻域嵌入超分辨率重建算法主要包含两部分:训练过程和重建过程。图中左半部分是训练过程,主要是提取低分辨率图像块特征和提取高分辨率样本图像的高频信息。右半部分为重建过程,主要是邻近块的选取、最优权重的估计和高分辨率图像的求取三部分。

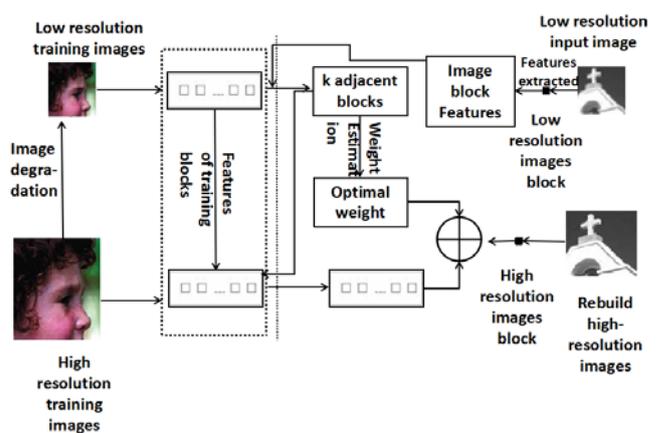


图 1 传统邻域嵌入超分辨率重建算法框架图

Fig.1 Block diagram of Traditional neighborhood embedded super-resolution reconstruction algorithm

由传统的邻域嵌入超分辨率算法可以看出,该算法的训练过程是在线学习,如果样本库很大这样会耗费大量的时间,导致算法的效率大大降低。为此本文提出了一种基于局部线性嵌入的流行学习单幅图像

超分辨率方法，该方法离线学习样本库中低分辨率图像块与高分辨率图像块之间的映射函数，并将映射函数事先进行存储，在进行超分辨率重建时只需要通过查表找到对应的映射函数，就可以快速完成低分辨率图像到高分辨率图像的映射，大大提高计算效率。

## 2 局部线性嵌入超分辨率算法

### 2.1 局部线性嵌入原理

对于局部线性嵌入算法，首先要确定邻域大小的选择，即需要多少个邻域样本来线性表示某个样本。假设这个值为  $k$ ，通过欧式距离来选择某样本的  $k$  个最近邻。在寻找某个样本  $x_i$  的  $k$  个最近邻之后，需要求解  $x_i$  和  $k$  个最近邻之间的线性关系，也就是要找到线性关系的权重系数，这显然是个回归问题。假设有  $m$  个  $n$  维样本  $\{x_1, x_2, \dots, x_m\}$ ，用均方差作为回归问题的损失函数，即：

$$J(w) = \sum_{i=1}^m \left\| x_i - \sum_{j=1}^k w_{ij} x_j \right\|_2^2 \quad (4)$$

对权重系数  $w_{ij}$  进行归一化的限制，即权重系数需要满足：

$$\sum_{j=1}^k w_{ij} = 1 \quad (5)$$

对于不在样本  $x_i$  邻域内的样本  $x_j$ ，令  $w_{ij}=0$ 。

需要通过上面两个式子求出权重系数。一般可以通过矩阵和拉格朗日乘子法来求解这个最优化问题。对于第一个式子，先将其矩阵化：

$$\begin{aligned} J(w) &= \sum_{i=1}^m \left\| x_i - \sum_{j=1}^k w_{ij} x_j \right\|_2^2 = \sum_{i=1}^m \left\| \sum_{j=1}^k w_{ij} x_i - \sum_{j=1}^k w_{ij} x_j \right\|_2^2 = \\ &= \sum_{i=1}^m \left\| \sum_{j=1}^k w_{ij} (x_i - x_j) \right\|_2^2 = \sum_{i=1}^m \left\| (x_i - x_j) W_i \right\|_2^2 = \\ &= \sum_{i=1}^m W_i^T (x_i - x_j)^T (x_i - x_j) W_i \end{aligned} \quad (6)$$

式中： $W_i = (w_{i1}, w_{i2}, \dots, w_{ik})$ 。

令：

$$Z_i = (x_i - x_j)^T (x_i - x_j)$$

则：

$$J(w) = \sum_{i=1}^m W_i^T Z W_i \quad (7)$$

则式(2)可以简化为，

$$\sum_{j=1}^k w_{ij} = W_i^T 1_k = 1$$

式中： $1_k$  为  $k$  维全 1 向量，现在将矩阵化的两个式子

用拉格朗日乘子法合为一个优化目标：

$$L(w) = \sum_{i=1}^m W_i^T Z W_i + \lambda (W_i^T 1_k - 1) \quad (8)$$

对  $W_i$  求导并令其值为 0，可以得到：

$$2Z W_i + \lambda 1_k = 0 \quad (9)$$

于是求得：

$$W_i = \lambda' Z_i^{-1} 1_k \quad (10)$$

式中： $\lambda' = -\frac{1}{2}\lambda$  为一个常数。利用  $W_i^T 1_k = 1$ ，对  $W_i$  归一化，那么最终的权重系数  $W_i$  为：

$$W_i = \frac{Z_i^{-1} 1_k}{1_k^T Z_i^{-1} 1_k} \quad (11)$$

### 2.2 样本训练库构建

基于局部线性嵌入超分辨率技术，首先构建训练样本库。构建样本训练库分两步完成，第一步，构建初始样本库；第二步，构建样本训练库。

通过搜集大量自然图像，建立了丰富的高分辨率 (HR) 样本库及其对应的低分辨率 (LR) 样本库。高分辨率 (HR) 图像  $I_h$  和低分辨率 (LR) 图像  $I_l$  存在以下关系：

$$I_l = (I_h \otimes G) \downarrow_s \quad (12)$$

式中： $\otimes$  代表卷积； $G$  是高斯卷积核； $\downarrow_s$  代表下采样， $s$  表示下采样尺度因子。分别从高分辨率图像  $I_h$  和低分辨率图像  $I_l$  中抽取图像块，形成高分辨率图像块  $P_h$  和低分辨率图像块  $P_l$  这样大量的高分辨率图像块  $P_h$  和低分辨率图像块  $P_l$  形成了初始样本库。

通过初始样本库求特征样本库。首先计算低分辨率图像块  $P_l$  的均值  $\mu$ ，则高分辨率图像块  $P_h$  和低分辨率图像块  $P_l$  的特征图像块是：

$$F_h = P_h - \mu \quad F_l = P_l - \mu \quad (13)$$

实际上  $F_h$  表示  $P_h$  的高频部分和  $F_l$  表示  $P_l$  的低频部分，于是  $F_h$  和  $F_l$  形成了特征样本库。对大量的低分辨率特征图像块  $F_l$  进行聚类，把相似度接近的特征图像块聚成一个类，类的相似度用欧式距离来表征。对于高分辨率特征图像块  $F_h$ ，依据其对应的低分辨率特征图像块  $F_l$  的聚类进行类别划分，于是就构建成功了样本训练库。图 2 表示样本训练库的部分样本。

通过搜集 200 多万张自然样本训练库，对样本库进行聚类，每个类有个聚类中心，给聚类中心按顺序给个编号，来表征该聚类。经过聚类，总共有 4000 多个聚类中心，每个聚类中心对应的样本数如图 3 所示。

### 2.3 低分辨率到高分辨率映射函数

在 2.1 节，对局部线性嵌入的原理进行了详细的

推导和介绍。本节利用局部线性嵌入来求取低分辨率图像到高分辨率映射函数。

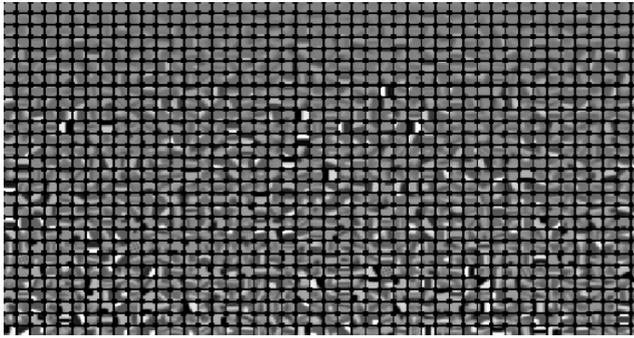


图2 部分样本库 Fig.2 Partial Sample Library

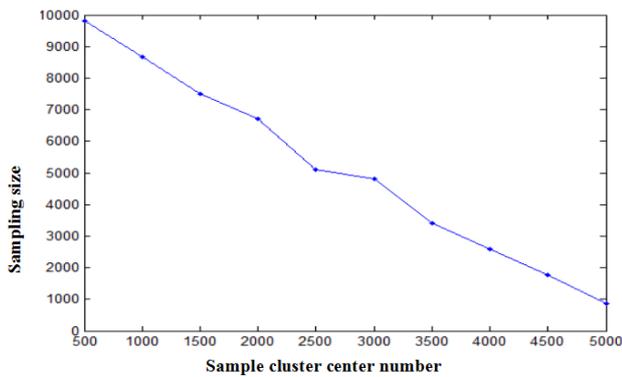


图3 样本训练库聚类

Fig.3 Sample training library clustering

假设有  $l$  个低分辨率特征图像块属于同一个聚类, 相对应的也有  $l$  个高分辨率特征图像块属于同一个聚类。设低分辨率特征图像块的大小为  $d \times d$ , 则高分辨率特征图像块的大小为  $ds \times ds$ ,  $s$  为尺度因子。对低分辨率图像进行双三次插值, 插值到与高分辨率图像相同的大小。

属于同一聚类的  $l$  个低分辨率图像块  $F_l$  表示为  $\{F_{l1}, F_{l2}, \dots, F_{ll}\}$ , 相对应的属于同一聚类的高分辨率图像块  $F_h$  表示为  $\{F_{h1}, F_{h2}, \dots, F_{hl}\}$ 。于是, 对于每一个高分辨率图像块  $F_{hl}$  都可以用同一聚类的低分辨率图像库  $\{F_{l1}, F_{l2}, \dots, F_{ll}\}$  来进行重构, 重构系数用  $W_i = (w_{i1}, w_{i2}, \dots, w_{ik})$  来表示:

$$F_{hi} = \sum_{j=1}^k w_{ij} F_{lj} \quad (14)$$

根据式(11), 运用局部线性嵌入原理求出相应的重构系统  $W_i$ :

$$W_i = \frac{Z_i^{-1} \mathbf{1}_k}{\mathbf{1}_k^T Z_i^{-1} \mathbf{1}_k} \quad (15)$$

于是, 对于属于同一聚类的高分辨率图像块库  $\{F_{h1}, F_{h2}, \dots, F_{hl}\}$  有  $l$  个重构系数  $\{W_1, W_2, \dots, W_l\}$ , 其中  $W_i = (w_{i1}, w_{i2}, \dots, w_{ik})$ 。最后, 通过求取重构系统的

均值得到最终的低分辨率图像到高分辨率图像的重构系数  $W = (w_1, w_2, \dots, w_l)$ , 即:

$$w_1 = \frac{w_{11} + w_{21} + \dots + w_{l1}}{l}, \quad w_2 = \frac{w_{12} + w_{22} + \dots + w_{l2}}{l}, \quad \dots, \quad w_l = \frac{w_{1l} + w_{2l} + \dots + w_{ll}}{l} \quad (16)$$

## 2.4 算法实现

基于局部线性嵌入超分辨率算法框架图如图4所示。

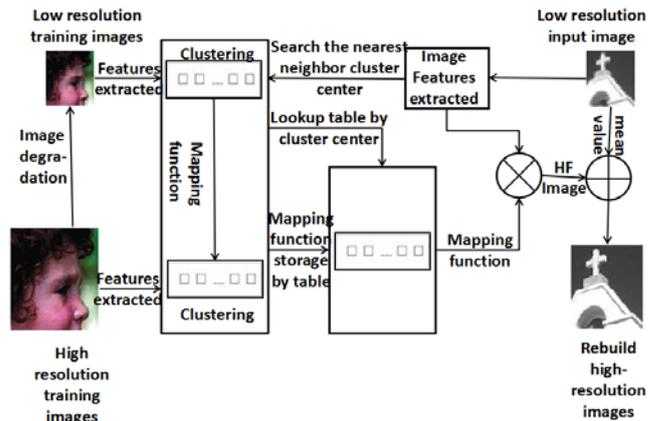


图4 本文超分辨率重建算法框架图

Fig.4 Frame diagram of super-resolution reconstruction algorithm proposed

基于局部线性嵌入超分辨率算法实现过程如下:

### 1) 构建样本训练库

对大量的低分辨率特征图像块  $F_l$  进行聚类, 把相似度接近的特征图像块聚成一个类, 类的相似度用欧式距离来表征。对于高分辨率特征图像块  $F_h$ , 依据其对应的低分辨率特征图像块  $F_l$  的聚类进行类别划分, 每个聚类用聚类中心来表征, 于是就构建成功了高低分辨率特征图像对样本训练库。

### 2) 通过样本训练库学习从低分辨率图像到高分辨率图像的映射函数。

假设有  $l$  个低分辨率特征图像块属于同一个聚类, 相应的也有  $l$  个高分辨率特征图像块属于同一个聚类。设低分辨率特征图像块的大小为  $d \times d$ , 则高分辨率特征图像块的大小为  $ds \times ds$ ,  $s$  为尺度因子。

首先, 对  $l$  个低分辨率特征图像块进行双三次插值, 使得图像的大小为  $ds \times ds$ 。根据 2.3 节, 利用公式(16)可以获得低分辨率图像到高分辨率图像的重构权重系数  $W = (w_1, w_2, \dots, w_l)$ , 将  $W$  按照聚类中心的编号进行存储, 可以按表进行查询。

### 3) 高分辨率图像重构

将输入的低分辨率图像 LR 划分成  $d \times d$  的子块, 相邻子块的重叠区域宽度为 2 个像素, 构成匹配图像

块  $q$ ，求  $q$  的均值  $\mu$ ，然后用  $q$  减去均值  $\mu$ ，得到  $q$  的特征图像块  $q'$ ，用  $q'$  在样本训练库中进行搜索，找到与之最近邻的聚类中心，于是查表找到与之对应的映射函数  $W$ 。运用双三次插值将  $q'$  插值放大到  $m=ds \times ds$ ，用  $Q$  来表示。

样本训练库中与  $q'$  相对应的最近邻的聚类经过双三次插值后的聚类为  $\{F_{11}, F_{12}, \dots, F_{1k}\}$ ，用  $Q$  代替这个聚类中与  $Q$  欧式距离最大的那个图像块  $F_{lm}$ ，于是构成新的聚类  $\{F_{11}, F_{12}, \dots, F_{lm-1}, Q, \dots, F_{1k}\}$ ，与之对应的重构权重系数  $W=(w_1, w_2, \dots, w_k)$ ，则重构的高分辨率图像块为：

$$P = \sum_{i=1}^k w_i F_{1i} \quad (17)$$

$$P = P + \mu \quad (18)$$

最后合并所有的重构高分辨率图像块，相邻图像块重叠区域的像素值平均得到，这样就求出了最终的超分辨率图像 HR。

### 3 实验和分析

在本文实验中，选择测试的硬件环境为：

- 1) 操作系统 Windows XP SP3;
- 2) 应用程序开发环境 Matlab 2012a;
- 3) 计算机配置 Intel Core i5-Y430p, 8.0GB 内存。

#### 3.1 样本训练库的大小对超分辨率重构结果影响

首先，讨论样本训练库大小对图像超分辨率结果的影响。将本文提的算法分别与 Kim 算法<sup>[17]</sup>、Wang 算法<sup>[18]</sup>、Sun 算法<sup>[19]</sup>进行比较分析，Kim 算法基于稀疏回归和自然图像先验、Wang 算法基于半耦合字典学习、Sun 算法主要基于梯度分布先验。本文用图像峰值信噪比 (PSNR, Peak of the Signal-to-Noise Ratio) 来对不同算法性能进行评价。接下来对 20 幅低分辨率图像分别用 4 种不同算法进行 3 倍放大，然后对每种算法计算出的 PSNR 求均值，其结果如图 5 所示。由图 5 可以看出，随着样本训练库数量的增大，PSNR 增大，图像超分辨率的效果也越好。由图也可以看出，本文算法的性能也优于其他算法。

#### 3.2 算法运行时间比较分析

为了分析比较 4 种不同算法的运行时间，对图像大小为  $64 \times 32$  个像素的原始图像分别放大 2 倍、3 倍、4 倍、5 倍，不同算法在不同放大倍数的情况下，其运行时间如图 6 所示。由图 6 可以看出，本文所提算法的运行时间大大低于其他 3 种算法，随着放大倍数的增加，其他 3 种算法的运行时间快速增加，而本文算法运行时间增加比较缓慢。当图像超分辨率放大 5 倍时，本文算法的执行效率几乎是 Sun 算法执行效率

的 100 倍。之所以本文算法效率很高，其主要原因是本文算法将最耗时的学习训练改为了离线学习，在进行本文算法超分辨计算时，只需通过查表，找到对应的映射函数，从而大大提高了算法的运行效率。

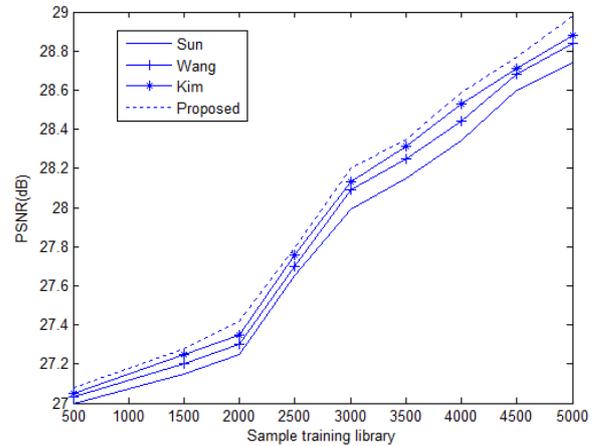


图 5 样本训练库大小对超分辨率结果影响

Fig.5 Influence from the sample training library size to the results of super-resolution

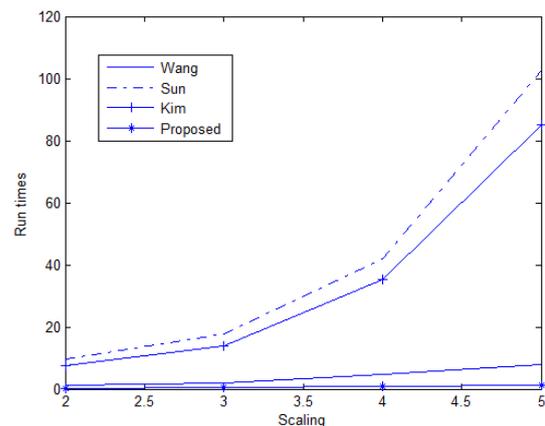


图 6 图像不同放大倍数运行时间

Fig.6 The run time of different magnification of image

#### 3.3 主观对比分析

将本文提的算法分别与 Kim 算法<sup>[17]</sup>、Wang 算法<sup>[18]</sup>、Sun 算法<sup>[19]</sup>进行比较分析。同一算法对不同图像选取相同的参数，放大 3 倍进行分析比较。主观效果如图 7、图 8 和图 9 所示，选择超分辨率图像的局部图像进行局部对比分析。对图 7 的处理中，Sun 算法和 Wang 算法在图像的边缘处会产生锯齿、锐度不够；Kim 算法在图像的边缘处产生了轻微振铃效应，边缘比较模糊；本文算法边缘保持的很好，没有伪影等不良现象产生，边缘锐度较好。对图 8 的处理中，Sun 算法纹理边缘没有很好的清晰度和锐度，图像整体显得有些模糊；Wang 算法从图像整体处理效果看清晰度和锐度都比较好，在图像的边缘有轻微的锯齿，图

像部分的纹理不是很清晰；Kim 算法从图像整体处理效果看清晰度和锐度都比较好，在图像的边缘有轻微的振铃效应，图像部分的纹理不是很清晰；本文算法的整体清晰度和图像边缘锐度明显好于其他 3 种方法，图像部分的纹理也比较清晰，但是本文算法在图像边缘也会产生的锯齿效应。在对图 9 的处理中，Sun 算法在边缘没有很好的清晰度和锐度，图像整体显得有些模糊，部分图像有些模糊；Wang 算法从图像整体处理效果看清晰度和锐度都比较好，在图像的边缘有轻微的锯齿，图像部分的纹理不是很清晰；Kim 算法从图像整体处理效果看清晰度和锐度都比较好，在图像的边缘有轻微的锯齿，图像部分的纹理不是很清晰；

本文算法的整体清晰度和图像边缘锐度明显好于其它 3 种方法，图像部分的纹理也比较清晰，但是本文算法在图像边缘也会产生的锯齿效应。

### 3.4 客观指标对比分析

对客观效果评估，用可量化的技术指标来进行评价。本文用图像峰值信噪比（PSNR）和图像结构的相似性（SSIM, Structural Similarity）评价不同算法的性能。表 1 是测试图像在 2 倍超分辨率放大情况下的客观评价结果。本文所测试的 3 幅测试图像来源于加州大学伯克利分校图像分割数据库。从表 1 的分析数据可以看出，本文提出的方法在所有情况下都比其他 3 种方法获得的结果要好，表现最优。

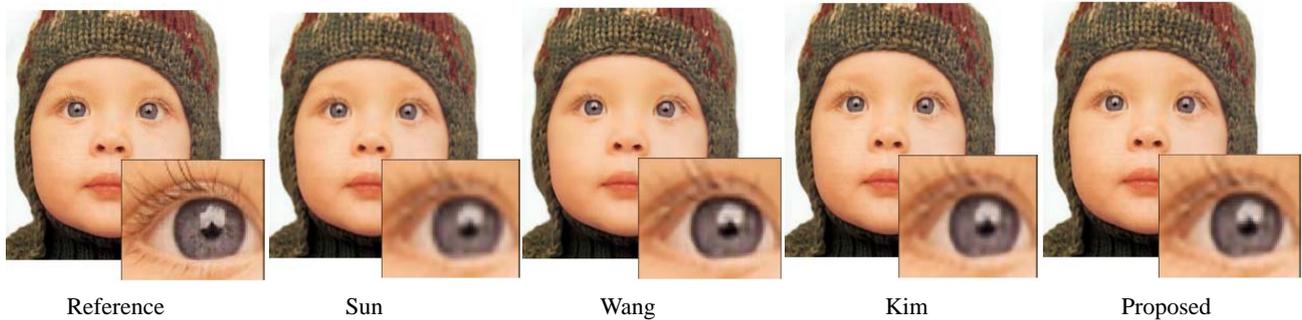


图 7 4 种算法对“baby”图像超分辨放大 3 倍效果对比图

Fig.7 Comparison diagram of magnification 3 times on image “baby” super-resolution by four methods mentioned

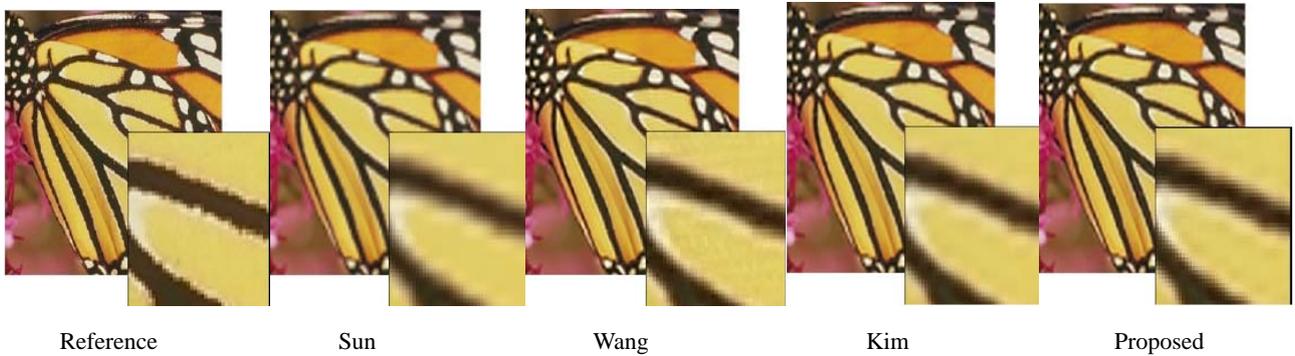


图 8 4 种算法对“butterfly”图像超分辨放大 3 倍效果对比图

Fig.8 Comparison diagram of magnification 3 times on image “butterfly” super-resolution by four methods mentioned



图 9 4 种算法对“bird”图像超分辨放大 3 倍效果对比图

Fig.9 Comparison diagram of magnification 3 times on image “bird” super-resolution by four methods mentioned

为进一步评价不同算法超分辨性能，图7、图8、图9分别比较了使用4种不同算法重建的结果。可以看出，Sun算法不能有效恢复图像的高频信息，生成的图像有些模糊。与Sun算法结果相比较，经典的Wang算法通过学习HR与LR图像间的字典表示，在一定程度上能有效恢复出LR图像中丢失的高频细节，得到的结果比较清晰。Kim算法的效果从整体上看与Wang算法效果相当。从视觉质量上看，Wang算法能够得到比Sun算法更多的高频细节，与上述3种方法得到的结果相比，本文提出的基于多引导滤波器单幅图像超分辨率算法在保持图像边缘和恢复纹理细节方面都有不同程度的改善，得到的结果不仅边缘更清晰更真实，而且纹理更加丰富。这是由于图像的局部流形结构在局部范围可以保持良好的一致性，在学习过程中，结合最近邻域自相似特性，使得参与重建的图像块均与目标图像块具有相似的结构，因而能获得较好的重建质量。

表1 不同算法PSNR和SSIM比较

Table 1 Comparison of PSNR and SSIM by Algorithms Mentioned

Image	Index	Sun	Wang	Kim	Proposed
Fig.7	PSNR	33.95	34.31	35.14	35.43
	SSIM	0.9139	0.9246	0.9337	0.9416
Fig.8	PSNR	32.62	33.91	34.15	34.91
	SSIM	0.8931	0.9015	0.9058	0.9121
Fig.9	PSNR	24.01	24.81	25.02	25.35
	SSIM	0.9125	0.9211	0.9363	0.9451

## 4 结论

在本文中，提出了一种基于局部线性嵌入的流行学习单幅图像超分辨率方法。首先，该方法通过大量的自然图像建立高低分辨率图像块样本训练库，并通过聚类算法将具有相似性质的高低分辨率样本块进行聚类；其次，将聚类中低分辨率图像块运用双三次插值算法插值到与之对应的聚类高分辨率图像块的大小，利用局部线性嵌入的流行学习算法学习进行样本训练，来离线学习聚类中低分辨率图像块与高分辨率图像块之间的映射函数，并且将映射函数进行存储；再次，将输入低分辨率图像进行重叠分块，并在样本库中搜索最近邻的高低分辨率样本聚类所对应的映射函数，通过映射函数用低分辨率图像块来重构高分辨率图像块；最后，将重构图像重叠部分进行平均。该算法使用领域较为广泛：①用于遥感图像的超分辨率；②用于医学图像超分辨率。

实验结果表明，本文算法不仅能很好重构图像的高频细节，还能很好地恢复图像的纹理特征，同时本文算法具有很高的执行效率，但是本文算法存在一些不足：①计算效率比较慢；②要构建大量的样本数据库。不足之处将在进一步的研究中分析改进并解决。

## 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.
- [5] Yang C Y, Yang M H. Fast Direct Super-Resolution by Simple Functions[C]//*IEEE International Conference on Computer Vision, IEEE Computer Society*, 2013: 561-568.
- [6] Pan Q, Liang Y, Zhang L, et al. Semi-coupled dictionary learning with applications to image super-resolution and photo-sketch synthesis[C]//*IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society*, 2012: 2216-2223.
- [7] Yang J, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2010, **19**(11): 2861.
- [8] Roman Zeyde, Michael Elad, Matan Protter. On single image scale-up using sparse- representations[C]//*International Conference on Curves and Surfaces, Springer-Verlag*, 2010: 711-730.
- [9] Timofte R, De V, Gool L V. Anchored Neighborhood Regression for Fast Example-Based Super-Resolution[C]//*IEEE International Conference on Computer Vision, IEEE*, 2014: 1920-1927.
- [10] Yang J, Wright J, Huang T S, et al. Image super-resolution via sparse representation[J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2010, **19**(11): 2861-2873.
- [11] Roman Zeyde, Michael Elad, Matan Protter. On Single Image Scale-Up Using Sparse-Representations[C]//*International Conference on Curves and Surfaces. Springer-Verlag*, 2010: 711-730.
- [12] Timofte R, Smet V D, Gool L V. A+: Adjusted Anchored Neighborhood Regression for Fast Super-Resolution[M]//*Computer Vision-ACCV 2014. Springer International Publishing*, 2014: 111-126.

- [13] Yang C Y, Yang M H. Fast Direct Super-Resolution by Simple Functions[C]//*IEEE International Conference on Computer Vision, IEEE Computer Society*, 2013: 561-568.
- [14] Yang J, Lin Z, Cohen S. Fast Image Super-Resolution Based on In-Place Example Regression[C]//*IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society*, 2013: 1059-1066.
- [15] Cui Z, Chang H, Shan S, et al. *Deep Network Cascade for Image Super-resolution*[M]//*Computer Vision – ECCV 2014*. Springer International Publishing, 2014: 49-64.
- [16] Timofte R, Smet V D, Gool L V. A+: Adjusted Anchored Neighborhood Regression for Fast Super-Resolution[C]//*Asian Conference on Computer Vision. Springer, Cham*, 2014: 111-126.
- [17] Kim K I, Kwon Y. Single-image super-resolution using sparse regression and natural image prior[J]. *PAMI*, 2010, **32**(6): 1127 - 1133.
- [18] WANG S, ZHANG L, LIANG Y, et al. Semi-coupled dictionary learning with applications to image super-resolution and photosketch synthesis[C]//*CVPR*, 2012.
- [19] Sun J, Shum H Y. Image super-resolution using gradient profile prior: IEEE, US9064476[P]. 2015.
- [20] Nasrollahi K, Moeslund T B. Super-resolution: a comprehensive survey[J]. *Machine Vision & Applications*, 2014, **25**(6):1423-1468.
- [21] Mairal J, Bach F, Ponce J, et al. Non-local sparse models for image restoration[C]//*IEEE, International Conference on Computer Vision. IEEE*, 2010: 2272-2279.
- [22] Glasner D, Bagon S, Irani M. Super-resolution from a single image[C]//*IEEE, International Conference on Computer Vision. IEEE Xplore*, 2009: 349-356.
- [23] Freedman G, Fattal R. Image and video upscaling from local self-examples[J]. *ACM Transactions on Graphics*, 2011, **30**(2):1-11.
- [24] Kawano H, Suetake N, Cha B, et al. Sharpness preserving image enlargement by using self-decomposed codebook and Mahalanobis distance[J]. *Image & Vision Computing*, 2009, **27**(6): 684-693.
- [25] Zhang Y Q, Liu J Y, Yang W H, et al. Image super-resolution based on structure-modulated sparse representation[J]. *IEEE Transactions on Image Processing*, 2015, **24**(9): 2797-2810.
- [26] Zhang Y Q, Xiao J S, Li S H, et al. Learning block-structured incoherent dictionaries for sparse representation[J]. *Science China Information Sciences*, 2015, **58**(10): 1-15.
- [27] Yang C Y, Huang J B, Yang M H. Exploiting self-similarities for single frame super-resolution[C]// *Asian Conference on Computer Vision. Springer-Verlag*, 2010: 497-510.

(上接第19页)

- [13] 宋长文, 颜红侠, 李朋博, 等. 树脂基透波复合材料研究进展[J]. *塑料工业*, 2007, **35**(10): 1-4.  
SONG Changwen, YAN Hongxia, LI Pengbo, et al. Progress in research of electro-magnetic wave penetrating polymer-matrix composite[J]. *China Plastics Industry*, 2007, **35**(10): 1-4.
- [14] 周思宁. 基于周期电阻表面结构的宽带吸波材料优化设计[D]. 南京: 南京大学, 2012.  
ZHOU Sining. Optimal design of wideband radar absorber based on periodic resistance surface[D]. Nanjing: Nanjing University, 2012.
- [15] 张辉彬. 基于电磁谐振的宽频周期吸波结构设计[D]. 成都: 电子科技大学, 2013.  
ZHANG Huibin. Design of broadband periodic absorbing structure based on electromagnetic resonances[D]. Chengdu: University of Electronic Science and Technology of China, 2013.
- [16] WANG Yongjuan, ZHOU Yuming, ZHANG Tao, et al. Acetate- intercalated Ni-In layered double hydroxides with low infrared emissivity: Synthesis, delamination and restacked to form the multilayer films[J]. *Applied Surface Science*, 2014, **288**: 710-717.
- [17] 陈珂, 纪箴, 张一帆, 等. 低发射率  $\text{SiO}_2/\text{Al}_2\text{O}_3$  纳米复合粉体的制备和红外隐身性能[J]. *工程科学学报*, 2016, **38**(9): 1296-1299.  
CHEN Ke, JI Zhen, ZHANG Yifan, et al. Preparation and infrared stealth properties of  $\text{SiO}_2/\text{Al}_2\text{O}_3$  nanocomposite powders with low emissivity[J]. *Chinese Journal of Engineering*, 2016, **38**(9): 1296-1299.
- [18] 郭硕鸿. *电动力学*[M]. 3版, 北京: 高等教育出版社, 2008: 121 -127.  
GUO Shuhong. *Electrodynamics*[M]. third edition, Beijing: Higher Education Press, 2008: 121-127.
- [19] 石东平, 唐祖义, 陈武. 趋肤效应的理论研究与解析计算[J]. *重庆文理学院学报: 自然科学版*, 2009, **28**(5): 18-21.  
SHI Dongping, TANG Zuyi, CHEN Wu. Theoretical study and numerical calculation on skin effect[J]. *Journal of Chongqing University of Arts and Sciences: Natural Science Edition*, 2009, **28**(5): 18-21.
- [20] 沈熙宁. *电磁场与电磁波*[M]. 北京: 科学出版社, 2006: 289-297.  
SHEN Xining. *Electromagnetic fields and waves*[M]. Beijing: Science Press, 2006: 289-297.
- [21] 丁士轩, 陆明, 郑桂凯, 等. 双层复合材料结构对吸波性能的影响研究[J]. *兵器材料科学与工程*, 2016, **39**(2): 88-92.  
DING Shixuan, LU Ming, ZHENG Guikai, et al. Electromagnetic wave absorbing property of two layer composite material[J]. *Ordnance Material Science and Engineering*, 2016, **39**(2): 88-92.
- [22] CHEN Shuwen, TAN Guoguo, GU Xingchen, et al. Microwave absorbing properties of FeCrMoNiPBCSi amorphous powders composite[J]. *Journal of Alloys and Compounds*, 2017, **705**: 309-313.