

基于耦合特征空间下改进字典学习的 图像超分辨率重建

詹曙¹, 方琪¹, 杨福猛², 常乐乐¹, 闫婷¹

(1. 合肥工业大学计算机与信息学院, 安徽合肥 230009; 2. 三江学院电子信息工程学院, 江苏南京 210012)

摘要: 针对目前基于字典学习的图像超分辨率重建效果欠佳或字典训练时间过长的问题, 本文提出了一种耦合特征空间下改进字典学习的图像超分辨率重建算法. 该算法首先利用高斯混合模型聚类算法对训练图像块进行聚类, 然后使用更改字典更新方式的改进 KSVD 字典学习算法来快速获得高、低分辨率特征空间下字典对和映射矩阵. 重建时根据测试样本与各个类别的似然概率自适应地选择最匹配的字典对和映射矩阵进行高分辨率重建. 最后利用图像非局部相似性, 将其与迭代反向投影算法相结合对重建后的图像进行后处理获得最佳重建效果. 实验结果表明了本文方法的有效性.

关键词: 超分辨率; 字典学习; KSVD; 稀疏表示; 混合高斯模型

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2016)05-1189-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2016.05.025

Image Super-Resolution Reconstruction via Improved Dictionary Learning Based on Coupled Feature Space

ZHAN Shu¹, FANG Qi¹, YANG Fu-meng², CHANG Le-le¹, YAN Ting¹

(1. School of Computer & Information, Hefei University of Technology, Hefei, Anhui 230009, China;

2. School of Electronic Information Engineering, Sanjiang University, Nanjing, Jiangsu 210012, China)

Abstract: Image super-resolution reconstruction via Improved Dictionary Learning based on Coupled Feature Space is studied in the paper, in order to solve the following problems: 1 the dictionary training process is time-consuming, 2 the results are not satisfactory in the existing algorithms. In the proposed algorithm, at first, the Gaussian mixture model clustering algorithm is employed to cluster the training image blocks, secondly, quickly obtain high and low resolution feature space of dictionary and mapping matrix by using dictionary updating based on improved KSVD dictionary learning algorithm, and then, the Super-Resolution image is reconstructed according to the likelihood probability of test samples, in which each category adaptively selected the most matching dictionary and mapping matrix for high-resolution reconstruction, finally, the non-local similarity and iterative back-projection are exploited to furtherly improve the quality of the reconstruction image. The experimental results demonstrate the validity of the proposed algorithm.

Key words: super-resolution; dictionary - learning; ksvd; sparse representation; gaussian mixture model

1 引言

图像超分辨率 (Super-Resolution, SR) 重建, 一直是一个热门的研究领域, 在不需增加硬件成本的前提下显著地提高了图像的分辨率, 改善了视觉效果. 由于 SR 不需要过高的硬件要求, 只需通过软件的方法来实现图像的高分辨率, 因此该技术已广泛的应用在视

频监控、卫星遥感、军事侦查、医学影像处理等领域.

在不考虑噪声的前提下, 低分辨率 (Low resolution, LR) 图像 X 和高分辨率 (High resolution, HR) 图像 Y 二者关系可以表示为:

$$X = LY \quad (1)$$

其中, L 表示 HR、LR 图像之间的投影矩阵. 超分辨率重建就是根据已知的 LR 图像求解 HR 图像的过程, 这是

一个典型的病态问题. 要解决此类问题, 通常需要利用先验知识合理的设定某些约束条件来求最优解. 目前主流的 SR 重建算法大致可分为基于重建和基于学习两大类^[1]. 基于重建的 SR 方法在 SR 重建过程中引入一定的先验信息作为约束条件, 如迭代反投影^[2]、凸集投影法^[3]等. 基于学习的方法通过对 HR 训练样本的学习, 建立一种高低分辨率的对应关系. 目前基于学习的 SR 重建是近年来的研究热点^[4,5,8-12,17].

基于学习的重建算法中, 比较经典的算法是 Freeman^[4]提出的基于例子的重建算法, 该算法最先在重建算法中利用图像块间的约束, 通过马尔可夫网络建立高低分辨率图像块对应关系. 但这种算法需要大量的训练样本, 训练过程中也消耗大量时间, 同时对图像中的噪声极为敏感. Chang 等人^[5]提出了邻域嵌入的 SR 算法, 该算法需要较少的样本, 且对噪声具有较好的鲁棒性. 稀疏表示理论是近年来信号处理领域的研究热点, 已经在图像去噪^[6]、人脸识别^[7]等领域获得了广泛的应用, 2010 年 Yang. J 等人^[8]开创性的将稀疏表示用于图像的 SR 重建. 其假设, HR、LR 图像块在各自的空间下具有相同的稀疏表示系数, 从而用 LR 图像块的稀疏系数来重构对应的 HR 图像块, 有效地降低了算法的复杂度. Zeyde 等人^[9]在 Yang. J 基础上进行改进, 利用主成分分析对训练样本的特征进行降维, 并使用 K-SVD 的方法进行字典训练, 进一步地提高的字典训练的效率和 Dong. W 等人^[10]使用 K-均值对训练图像块进行聚类, 然后通过自适应地选择图像的稀疏域, 来重建 HR 图像块, 有效地提高了重建后图像的效果. Wang. S 等人^[11]提出训练 HR、LR 图像块及其的映射关系构造半耦合字典, 有效地改善了重建后图像的效果. Li. H 等人^[12]利用 beta 先验分布训练耦合特征空间的字典对, 也取得较好的效果, 但字典训练同样需要消耗大量时间.

针对目前基于字典学习的图像 SR 重建效果欠佳或字典训练时间过长的问题, 本文在文献[8]和[10]的基础上提出了一种耦合特征空间下改进字典学习的图像 SR 重建算法. 该算法首先利用高斯混合模型聚类算法对训练图像块进行聚类处理, 然后通过使用更改字典更新方式的改进 KSVD 字典学习算法来快速获得 HR、LR 特征空间下字典对和映射矩阵. 重建时根据测试样本与各个类别的似然概率自适应地选择最匹配的字典对和映射矩阵进行 SR 重建. 最后利用图像非局部相似性, 将其与迭代反向投影算法相结合对重建后的图像进行后处理以获得最佳的重建效果.

2 相关工作

2.1 基于字典学习的图像超分辨率重建

按照图像稀疏表示理论^[6], 图像在过完备字典下, 总存在稀疏的表示, 即大部分稀疏表示系数为零, 只有少数的非零系数. 假设 $D \in R^{n \times K}$ 是维数为 n 、原子数为 K 的过完备字典, $x \in R^n$ 为图像子块的向量表示, 则 x 的稀疏表示为:

$$\min \|\alpha\|_0, \quad \text{s. t. } x = D\alpha \quad (2)$$

式中, $\alpha \in R^K$ 为 x 的最稀疏表示. 式(2)是 NP 难问题, 通常只考虑其近似解法, 可通过匹配追踪以及其改进的正交匹配追踪算法 (OMP) 等贪婪算法来近似求解. Donoho 等人^[13]指出在信号的稀疏分解中, 对于足够稀疏的信号表示系数, 可以用 l_1 范数取代式(2)的 l_0 范数进行稀疏分解, 使上述问题转换为凸优化的问题, 从而式(2)可以转换为式(3)进行稀疏表示:

$$\min \|\alpha\|_1, \quad \text{s. t. } \|D\alpha - x\|_2 \leq \varepsilon \quad (3)$$

对于基于字典学习的图像 SR 重建, 通常需要两个过完备字典, 其中一个是在 LR 特征空间下训练得到的 LR 字典 D_l , 用于对 LR 图像进行稀疏分解, 另一个是在 HR 特征空间下训练得到的 HR 字典 D_h , 用于进行 HR 图像重建. 对于输入的 LR 图像块 x 利用式(2)或式(3)进行稀疏分解, 得到 x 的稀疏表示系数 α , 然后将稀疏系数 α 作用在 HR 字典 D_h , 得到对应 HR 图像块 y :

$$y = D_h \alpha \quad (4)$$

2.2 本文的超分辨率重建模型

由于自然图像中包含多重结构形态的复杂信号, 图像的不同部分其结构信息变化很大, 而高度冗余的通用字典 D_h 和 D_l 中存在大量的不相干原子, 当用这些不相干的原子来表示不同的图像块, 可能会存在潜在的不稳定性从而导致重构后图像产生视觉上的伪影. 而传统的字典学习 SR 重建是建立在 HR、LR 图像块在对应的 HR、LR 特征空间下具有相同稀疏系数为约束条件的, 然而 HR 图像块的稀疏系数并不是精确相等, 如何有效刻画稀疏系数在不同特征空间下的联系, 在图像重建中起着重要的作用. 综合以上多重考虑, 本文提出了基于耦合特征空间下改进字典学习的图像超分辨率重建. 图 1 是本文算法流程框图.




图1 本文提出算法流程

该算法主要思想: 首先利用高斯混合模型聚类算法对训练图像块进行聚类处理, 然后通过使用改进

KSV D字典学习算法来快速获得高、低分辨率特征空间下字典对. 为了刻画稀疏系数在不同特征空间的关系, 使用岭回归方法获得映射矩阵. 重建时根据测试样本与各个类别的似然概率自适应地选择最匹配的字典对和映射矩阵进行 SR 重建. 最后利用图像非局部相似性, 将其与迭代反向投影算法相结合对重建后的图像进行全局重建约束进一步提高重建效果.

3 耦合特征空间下改进字典学习算法

3.1 高斯混合模型图像块聚类

假设 $\{I_h\}$ 和 $\{I_l\}$ 分别表示 HR、LR 图像训练样本, 本文使用 Yang, J^[8] 的方法对高低分辨率图像训练样本进行特征提取、分块, 并向量化, 得到各自向量化的图像块集合, 分别记为 $\{y\}$ 和 $\{x\}$. 对低分辨率图像块 $\{x\}$ 进行聚类. 假设利用高斯混合模型对图像块 $\{x\}$ 进行聚类, 可得到 C 个子类. 则这组样本数据由混合分布 p 产生, 即有 C 个子高斯分布. 这组样本的分布未知, 但可由 C 个高斯密度函数的加权和来近似表示, 如式(5):

$$p(x|\theta) = \sum_{c=1}^C \pi_c f_c(x|\mu_c, \Sigma_c) \quad (5)$$

$\theta = (\mu_1, \dots, \mu_c, \Sigma_1, \dots, \Sigma_c)$ 代表高斯混合分布参数; π_c 为混合权重系数, 满足 $\sum_{c=1}^C \pi_c = 1, \pi_c \geq 0$; $f_c(x|\mu_c, \Sigma_c)$ 为第 c 类图像块的高斯概率密度分布, 表达式为:

$$f_c(x_i|\mu_c, \Sigma_c) = \frac{1}{(2\pi)^{\frac{d}{2}} |\Sigma_c|^{\frac{1}{2}}} e^{-\frac{1}{2}(x_i - \mu_c)^T \Sigma_c^{-1} (x_i - \mu_c)} \quad (6)$$

其中 μ_c 为该高斯分布的均值, Σ_c 为该高斯分布的协方差. 由式(6)可知, 高斯混合模型的每个高斯分布是由均值和协方差进行描述的, 因此必须对该模型的参数进行求解. 本文使用 EM (expectation maximization) 算法^[14]对高斯混合模型进行参数估计, 可得到每个类的似然分布参数 π_c, μ_c 和 Σ_c , 根据式(6)计算每个图像块对各个图像块类别的似然概率, 取得最大似然概率者即为该图像块所属的类别.

3.2 改进的 KSV D字典学习算法

字典学习的实质问题可表示为下式所示的优化问题:

$$\min \{ \|X - DA\|_F^2 \}, \quad \text{s. t. } \forall i, \|\alpha_i\|_0 < T_0 \quad (7)$$

式中 X 表示训练样本集 $\{x_i\}_{i=1}^N$, 且满足 $N \gg K$, D 表示字典尺寸为 K 的过完备字典, A 为稀疏矩阵, T_0 为稀疏矩阵 A 的稀疏度.

为了解决上式的优化问题, 本文使用文献[15]提出的一种改进 K-SVD 的字典学习算法, 与 K-SVD 字典学习算法相同, 该算法将式(7)优化问题分为两个步骤求解, 即稀疏编码阶段和字典更新阶段. 由于 K-SVD 算

法字典更新阶段不仅对字典中原子进行更新, 还对系数矩阵 A 中与原子相乘的非零系数进行更新, 根据 K-SVD 字典训练思想, 字典更新目标是寻找更新后的字典 D 和系数矩阵 A 中完备的非零支集. 那么式(7)的字典优化问题可以转化为:

$$\{D, A\} = \underset{D, A}{\operatorname{argmin}} \|X - DA\|_F^2, \quad \text{s. t. } A \odot M = 0 \quad (8)$$

式中 $A \odot M$ 是两个相同尺寸矩阵的 Schur 积, 其中掩膜矩阵 $M = \{|A| = 0\}$, M 是由元素 0 和 1 组成, 该式等效于如果 $A(i, j) = 0$ 则 $M(i, j) = 1$, 否则为 0. 因此 $A \odot M = 0$ 能使 A 中所有零项保持完备. 式(8)的优化问题相对于(7)式更简单, 但仍然是个非凸问题, 因此可以使用块坐标下降方法来求解此约束问题. 式(8)的求解过程也分为稀疏编码和字典更新这两个步骤.

首先, 假设字典 D 已经确定, 通过求解式(9)来修正系数矩阵 A :

$$A = \underset{A}{\operatorname{argmin}} \|X - DA\|_F^2, \quad \text{s. t. } A \odot M = 0 \quad (9)$$

由于稀疏系数矩阵 A 的最优问题存在封闭解, 因此分别对 A 的每一列进行处理, 只考虑 A 中各列的非零元素而使零元素项保持完备, 则式(9)转换为下式进行求解:

$$\alpha_i = \underset{\alpha_i}{\operatorname{argmin}} \|x_i - D_i \alpha_i\|_2^2 \quad (10)$$

其中, D_i 是 D 对应 A 的非零支集的子矩阵, α_i 是 A 第 i 列的非零部分. 式(10)的优化问题可以使用正交匹配追踪算法 (OMP)^[23]进行求解. 对每一列进行处理后可以得到更新后的稀疏系数矩阵 A .

其次, 利用得到稀疏系数矩阵对字典的原子依次进行更新. 假设系数矩阵 A 和字典 D 已知, 则式(8)补偿项可以写为如下形式:

$$\begin{aligned} \|X - DA\|_F^2 &= \|X - \sum_{j=1}^n d_j \alpha_j^T\|_F^2 \\ &= \|(X - \sum_{j \neq k} d_j \alpha_j^T) \odot (\mathbf{1}_d \cdot \mathbf{m}_j^T) - d_k \alpha_k^T\|_F^2 \\ &= \|E_j - d_k \alpha_k^T\|_F^2 \end{aligned} \quad (11)$$

式中 d_k 表示待修正字典 D 中的第 k 列, α_k^T 表示 A 第 k 行, \mathbf{m}_j^T 是 M 的第 j 行以确保 α_k^T 中的零元素项在正确的位置. 掩膜矩阵 $\mathbf{1}_d \cdot \mathbf{m}_j^T$ 是将列向量 \mathbf{m}_j^T 复制 d 次得到尺寸为 $d \times K$ 的一阶矩阵. 利用掩膜矩阵 $\mathbf{1}_d \cdot \mathbf{m}_j^T$ 可以有效地去除 $X - \sum_{j \neq k} d_j \alpha_j^T$ 中那些未用到第 j 列原子所对应样本的列. 对矩阵 E_j 进行奇异值分解 (SVD) 得到 $E_j = U \Delta V^T$, 利用矩阵 U 的第一列代替字典 D 中的原子 d_k , 利用矩阵 V 的第一列与 $\Delta(1, 1)$ 的乘积来修正系数矩阵 A 中的 α_k^T . 然后不断重复稀疏编码和字典更新这两步骤, 直至满足预设的收敛条件. 由于字典更新阶段中同时更新字典矩阵和稀疏系数矩阵中的非零元素项, 使得更新后的字典稀疏误差更小而且字典收敛速度非常快, 一般只需很少的迭代次数就能达到收敛条件, 字

典的学习效率高于 KSVD 字典学习算法.

3.3 耦合特征空间下的字典学习

假设 $\{Y_c\}_{c=1}^C$ 和 $\{X_c\}_{c=1}^C$ 分别表示 C 类 HR、LR 训练样本, $\{D_{hc}\}_{c=1}^C$ 和 $\{D_{lc}\}_{c=1}^C$ 分别表示 C 类样本训练后的 HR、LR 特征空间字典. 耦合特征空间下聚类字典训练过程可表示为:

$$D_{lc} = \underset{B_i, A_i}{\operatorname{argmin}} \|X_c - D_{lc}A_{lc}\|_2^2 + \lambda \|A_{lc}\|_1 \quad (12)$$

$$D_{hc} = \underset{B_i, A_i}{\operatorname{argmin}} \|Y_c - D_{hc}A_{hc}\|_2^2 + \lambda \|A_{hc}\|_1$$

$$M_c A_{lc} = A_{hc} \quad (13)$$

式中 A_{lc} 和 A_{hc} 分别表示每个子字典的稀疏系数矩阵, M_c 是高低分辨率特征空间的稀疏系数映射矩阵, 用来刻画稀疏系数在不同特征空间下的联系. 式(12)使用 3.2 节的改进 KSVD 字典训练算法获得 HR、LR 字典 D_{hc} 、 D_{lc} 以及对应的稀疏系数矩阵 A_{hc} 和 A_{lc} . 则式(13)可以转换为下式得到映射矩阵 M_c :

$$M_c = \underset{M}{\operatorname{argmin}} \|A_{hc} - M_c A_{lc}\|_2^2 \quad (14)$$

由于 A_{hc} 和 A_{lc} 是稀疏矩阵, 式(14)是个不适定问题, 如果直接使用传统的最小二乘法求解 M_c , 可能会使求解的结果误差较大. 为了将式(14)转换为适定问题, 在式(14)中引入一个正则项来控制模型的复杂度, 则目标函数变为:

$$M_c = \underset{M}{\operatorname{argmin}} \|A_{hc} - M_c A_{lc}\|_2^2 + \|\Gamma M_c\|_2^2 \quad (15)$$

其中, $\Gamma = \sigma I$, I 为单位矩阵, σ 为正则项平衡参数. 式(15)是个岭回归问题, 可以直接通过下式求解映射矩阵 M_c :

$$M_c = A_{hc} A_{lc}^T (A_{lc} A_{lc}^T + \Gamma)^{-1} \quad (16)$$

4 图像超分辨率重建

对耦合特征空间下训练样本进行字典训练后, 可得到 C 组 HR、LR 字典以及映射矩阵. 对于输入的 LR 测试图像的每个子块在进行超分辨率重建时需要自适应地选择合适的字典和映射矩阵进行稀疏分解和重建. 本文通过式(17)计算 LR 测试图像块 x 与各个低分辨率训练图像块类别的似然概率, 取得最大似然概率者即为该测试图像块 x 所属的类别:

$$c = \operatorname{argmax}_i f_i(x | \mu_i, \Sigma_i), i = 1, \dots, C \quad (17)$$

式(17)中的 $f(x | \mu, \Sigma)$ 表示训练样本的高斯混合模型的概率分布, μ_i 和 Σ_i 为该高斯混合模型的模型参数, 通过计算式(17)自适应的选择与测试图像块 x 最匹配的子字典 D_{hc} 、 D_{lc} 和映射矩阵 M_c 进行 SR 重建. 对测试图像块 x 进行 SR 重建, 首先需求出 x 在 LR 字典 D_{lc} 下的稀疏系数 α_l :

$$\alpha_l = \operatorname{argmin} \|D_{lc}\alpha_l - x\|_2^2 + \lambda \|\alpha_l\|_1 \quad (18)$$

式(18)的稀疏编码过程使用 Yang. J 的方法进行求解, 得到 LR 稀疏系数 α_l . 然后使用映射矩阵 M_c 将 LR 特征

空间的稀疏系数 α_l 映射到 HR 特征空间上, 求出 HR 稀疏系数, 即:

$$\alpha_h = M_c \alpha_l \quad (19)$$

将 HR 稀疏系数 α_h 结合 HR 字典 D_{hc} 重建出 HR 图像块 y :

$$y = D_{hc} \alpha_h \quad (20)$$

对 LR 测试图像的每个子块进行 SR 重建, 即可得到重建后的 HR 图像 Y_0 . 由于由式(18)局部模型求解的 α_l 并不能保证 LR 图像块 x 和 $D_{lc}\alpha_l$ 准确相等, 为了进一步提高重建后图像的效果, 本文利用图像中存在非局部冗余自相似性^[16], 并将其与迭代反投影算法^[2]相结合对重建后的 HR 图像进行全局约束, 能够进一步减少重建误差, 使得重建后图像在整体视觉效果上得到明显的提高, 该全局约束的目标函数如下式:

$$Y^* = \underset{Y}{\operatorname{argmin}} \|LY - X\|_2^2 + \gamma \|Y - Y_0\|_2^2,$$

$$\text{s. t. } \|y_i - \sum_{m=1}^M b^m y_{i(0)}^m\|_2^2 \leq \varepsilon \quad (21)$$

其中 y_i 和 $y_{i(0)}$ 分别是 Y 和 Y_0 中相同位置的图像块, $y_{i(0)}^m$ 是 $y_{i(0)}$ 周围第 m 个最相似的图像块, b^m 为非线性权值系数. 式(21)的目标函数本文分为两个阶段进行求解, 首先使用非局部自相似性对 Y_0 进行优化得到 Y_1 , 然后将 Y_1 做为反投影算法的初始输入, 经过迭代后得到最终输出的 HR 图像 Y^* .

5 实验结果与分析

本文算法程序采用 Matlab 语言编写, 软硬件运行环境为: 64 位 windows7 SP1 操作系统、Matlab R2012b、Intel i3 - 4130 3.4GHz 处理器、4GB 运行内存. 本文试验中图像训练集采用 Yang. J 算法^[8]以及 Zeyde 算法^[9]所使用的自然图像训练库, 随机选取 10 万个图像块作为训练样本, 分成 32 个子类, 子字典大小为 256. 将 LR 图像分成若干个 5×5 大小的图像块, 相应的 HR 图像块大小为 15×15 . 稀疏平衡因子 $\lambda = 0.1$, 正则项参数 $\alpha = 0.01$, 对输入的测试 LR 图像进行 3 倍重建. 由于人类视觉系统对亮度信息更为敏感, 对于彩色 RGB 测试图像先转化为 YCbCr 信号, 然后选择亮度通道 Y 进行 SR 重建, 对 Cb、Cr 通道直接进行插值放大.

为了验证本文所提方法的有效性, 本文将 HR 图像通过使用双三次插值进行 3 倍下采样得到低分辨率测试图像. 实验以 Bicubic 插值作为基准算法, 图 2~5 分别是 Monarch、Girl、Parrot、Zebra 重建后的局部图像, 并将本文重建结果与 Bicubic 插值、Yang. J 方法^[8]、SCDL 方法^[11]和原始图像做对比. 表 1 和表 2 分别是对本文算法重建的结果计算峰值信噪比 PSNR 和结构相似度 SSIM, 并与 Bicubic 插值、迭代反向投影 IBP^[2]、Yang. J 方法^[8]、Zeyde 方法^[9]、SCDL 方法^[11]和 BPJDL 方法^[12]

进行客观对比. 本文试验中 Yang. J 方法、Zeyde 方法和 BPJDL 方法的参数设置相同, 即训练图像块个数为 10 万个、图像块大小为 5×5 、字典尺寸为 1024、稀疏平衡

因子 $\lambda = 0.1$, SCDL 方法参数设置为: 训练图像块个数为 50 万个、大小 5×5 、分为 32 类、子字典尺寸为 256.



图1 低分辨率测试图




图2 各算法重建结果比较(Monarch图)




图3 各算法重建结果比较(Girl图)



图4 各算法重建结果比较(Parrot图)




图5 各算法重建结果比较(Zebra图)

通过观察图 2 ~ 5 局部图像可以发现, Yang. J 方法和 SCDL 方法相比 Bicubic 插值有较大提升, 但是 Yang. J 方法在边缘部分仍然比较模糊, SCDL 方法中的边缘部分出现锯齿效用、细节过于平滑, 而本文方法相比前三者更接近原图, 而且重建后图像基本消除锯齿效用, 边缘改进较明显, 可以恢复出更多的细节信息. 在图 3

中, 本文方法重建结果可以清晰看出女孩的双眼皮以及鼻尖部分的雀斑, 而前三者重建图像的细节部分比较模糊. 在图 5 中的斑马纹理部分, 本文方法的重建结果基本与原图一致, 白色条纹的边缘部分更清晰且没有出现锯齿效应, 而 Yang. J 方法纹理部分出现模糊现象, SCDL 方法出现了边缘锯齿效用以及细节过平滑的

不自然视觉效果.

表 1 和表 2 分别给出各种算法的 PSNR 和 SSIM 对比,表中的本文方法 1 为使用单一的全局字典的重建结果,本文方法 2 为使用高斯混合模型聚类后的多组字典的重建结果.从中可以看出本文方法 2 重建图像的 PSNR、SSIM 相比其它方法均有所提高,其中方法 2 的 PSNR 相比 Bicubic 插值、IBP 方法、Yang. J 方法、Zeyde 方法、SCDL 方法和 BPJDL 方法分别增加了

1.6dB、0.7dB、0.6dB、0.7dB、1.1dB 和 0.2dB.方法 2 重建图像的 SSIM 比 Bicubic 插值和 IBP 方法有较大的提升,相比 Yang. J 方法、Zeyde 方法和 SCDL 方法分别提高了 1、0.8 和 1.8 个百分点,与 BPJDL 方法基本相当.从表 1 和表 2 中可以看出本文方法 2 重建结果的 PSNR 和 SSIM 相比方法 1 均有所提高,由此可以得出使用高斯混合模型对训练图像块聚类后的多组字典在 SR 重建中优于单一的全局字典重建结果.

表 1 各种算法的 PSNR 对比

	Bicubic	IBP	Yang. J	Zeyde	SCDL	BPJDL	本文方法 1	本文方法 2
monarch	24.0670	24.9551	25.4667	25.2580	24.3656	25.9282	26.0404	26.2340
gril	33.7113	34.4369	34.4384	34.6490	34.0764	34.5149	34.5057	34.6836
Lena	30.9759	31.9301	31.9636	32.0215	31.9714	32.3417	32.3511	32.5349
Parrot	28.1036	29.0633	29.2845	28.9753	28.2516	29.5028	29.3753	29.7305
Pepper	30.5050	31.2299	31.2975	31.3236	30.7241	31.6047	31.7928	31.9797
hat	29.2103	29.8461	30.1623	30.0918	30.2192	30.3653	30.3711	30.4928
Zebra	23.5172	24.8243	24.8197	24.7036	24.1431	25.1770	25.2703	25.4054
均值	28.5843	29.4693	29.6332	29.5747	29.1073	29.9192	29.9581	30.1516

表 2 各种算法的 SSIM 对比

	Bicubic	IBP	Yang. J	Zeyde	SCDL	BPJDL	本文方法 1	本文方法 2
monarch	0.8160	0.8301	0.8489	0.8567	0.8616	0.8654	0.8642	0.8748
gril	0.8381	0.8597	0.8584	0.8690	0.8261	0.8602	0.8571	0.8631
Lena	0.9500	0.9632	0.9633	0.9629	0.9587	0.9653	0.9656	0.9667
Parrot	0.8781	0.8940	0.8967	0.8967	0.8835	0.9014	0.9004	0.9043
Pepper	0.9656	0.9729	0.9739	0.9754	0.9650	0.9756	0.9762	0.9774
hat	0.8248	0.8416	0.8487	0.8432	0.8376	0.8540	0.8543	0.8560
Zebra	0.7390	0.7953	0.7909	0.7894	0.7875	0.8074	0.8055	0.8087
均值	0.8588	0.8795	0.8830	0.8848	0.8743	0.8899	0.8890	0.8930

注:以上数据均为三次实验的平均值

表 3 记录了各算法在字典学习阶段所消耗的时间,下面对各算法的复杂度进行分析.假设对于尺寸为 $N \times N$ 的训练图像,取 N^2 个大小为 $\sqrt{n} \times \sqrt{n}$ 的训练图像块.其中 Zeyde 算法复杂度为 $O(N^2)$,字典学习效率最高. Yang. J 算法的复杂度为 $O(N^4)$,该算法的字典更新方式是在样本和稀疏系数已知的条件下,求解优化问题,但是由于训练样本和稀疏系数的维数很大,影响了字典训练的效率. SCDL 算法的时间复杂度为 $O(c \cdot t \cdot N^2)$,其中 c 为训练样本类数、 t 为迭代次数,由于 SCDL 算法在训练半耦合字典前需要对每一类的字典进行初始化,而且直接使用图像块的像素值进行训练,从而大大降低了字典训练效率. BPJDL 算法时间复杂度为 $O(k^2 \cdot N^2)$,其中 k 表示字典大小,该算法在训练字典过程中每次迭代只能更新一列原子,训练时间最长.本文

算法时间复杂度为 $O(c \cdot N^2)$,低于 Yang. J 算法、SCDL 算法和 BPJDL 算法,训练时间相对较少.

表 3 各种算法字典训练时间对比 (min)

算法	Yang. J	Zeyde	SCDL	BPJDL	本文算法
时间	325	5	846	2805	106

6 结论

针对目前基于字典学习的图像 SR 重建效果欠佳或字典训练时间过长的问题,考虑到高斯混合模型能简单地体现类内数据的分布特点,本文算法首先利用高斯混合模型聚类算法对训练图像块进行聚类处理,然后通过使用更改字典更新方式的改进 KSVD 字典学习算法来快速获得 HR、LR 特征空间下字典对和映射矩阵.重建时根据测试样本与各个类别的似然概率

选择最匹配的字典对和映射矩阵进行 HR 重建. 最后利用图像非局部相似性, 将其与迭代反向投影算法相结合对重建后的图像进行后处理以获得最佳重建效果. 实验结果表明, 本文算法不仅提高重建后图像的质量, 同时也有效地降低了字典训练时间.

参考文献

- [1] 史郡, 王晓华. 基于改进 K-SVD 字典学习的超分辨率重构[J]. 电子学报, 2013, 41(5): 997 - 1000.
Shi Jun, Wang Xiao-hua. Image super-resolution reconstruction based on improved K-SVD dictionary learning [J]. Acta Electronica Sinica, 2013, 41(5): 997 - 1000. (in Chinese)
- [2] Irani M, Peleg S. Improving resolution by image registration[J]. CVGIP: Graphical Models and Image Processing, 1991, 53(3): 231 - 239.
- [3] 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 and Vision, 1989, 6(11): 1715 - 1726.
- [4] Freeman T, Jones T R, Pasztor E. Example based super-resolution [J]. IEEE Computer Graphics and Applications, 2002, 22(2): 56 - 65.
- [5] Chang H, Yeung D, Xiong Y. Super-resolution through neighbor embedding [A]. IEEE International Conference on Computer Vision and Pattern Recognition [C]. Washington, DC, USA: IEEE, 2004. 275 - 282.
- [6] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Trans Signal Process, 2006, 54(11): 4311 - 4322.
- [7] 詹曙, 王俊, 等. 基于 Gabor 特征和字典学习的高斯混合稀疏表示图像识别[J]. 电子学报, 2015, 43(3): 523 - 528.
Zhan Shu, Wang Jun, et al. Gaussian mixture sparse representation for image recognition based on gabor features and dictionary learning [J]. Acta Electronica Sinica, 2015, 43(3): 523 - 528. (in Chinese)
- [8] 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.
- [9] Zeyde R, Elad M, Protter M. On single image scale-up using sparse representations [A]. Proceedings of the 7th International Conference on Curves and Surfaces [C]. Avignon, France: Springer, 2012. 6920: 711 - 730.
- [10] Dong W, Zhang L, Shi G, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization [J]. Image Processing, IEEE Transactions on, 2011, 20(7): 1838 - 1857.
- [11] Wang S, Zhang L, Liang Y, et al. Semi-coupled dictionary learning with applications to image super-resolution and photo-sketch synthesis [A]. IEEE International Conference on Computer Vision and Pattern Recognition [C]. Providence, RI, USA: IEEE, 2012. 2216 - 2223.
- [12] Li He, Hairong Qi, Zaretski R. Beta process joint dictionary learning for coupled feature spaces with application to single image super-resolution [A]. IEEE International Conference on Computer Vision and Pattern Recognition [C]. Portland, OR, USA: IEEE, 2013. 345 - 352.
- [13] Chen S, D Donoho, M Saunders. Atomic decomposition by basis pursuit [J]. SIAM Journal on Scientific Computing, 2001, 43(1): 129 - 159.
- [14] P Dempster, M Laird, B Rubin. Maximum likelihood from incomplete data via the EM algorithm [J]. Journal of the Royal Statistical Society. 1977, B(39): 1 - 38.
- [15] Smith LN, Elad M. Improving dictionary learning: multiple dictionary updates and coefficient reuse [J]. IEEE Signal Processing Letters, 2013, 20(1): 79 - 82.
- [16] Buades A, Coll B, Morel JM. A non-local algorithm for image denoising [A]. IEEE International Conference on Computer Vision and Pattern Recognition [C]. Anchorage, Alaska, USA: IEEE, 2005. 60 - 65.
- [17] 潘宗序, 禹晶, 等. 基于自适应多字典学习的单幅图像超分辨率算法 [J]. 电子学报, 2015, 43(2): 209 - 216.
Pan Zong-xu, Yu Jing, et al. Single image super resolution based on adaptive multi-dictionary learning [J]. Acta Electronica Sinica, 2015, 43(2): 209 - 216. (in Chinese)

作者简介



詹 曙 男, 1968 年生于安徽合肥. 副教授、硕士生导师, 合肥工业大学计算机与信息学院. 研究方向为三维人脸识别和医学图像处理.
E-mail: shu_zhan@hfut.edu.cn



方 琪 男, 1991 年生于安徽灵璧. 硕士研究生, 合肥工业大学计算机与信息学院. 研究方向为数字图像处理.
E-mail: fq9110@mail.hfut.edu.cn