

基于贝塔过程联合字典学习的图像超分辨重建^①

朱福珍^{②*} 邹丹妮^{**} 巫 红^{*} 白鸿一^{*}

(^{*} 黑龙江大学电子工程学院 哈尔滨 150080)

(^{**} 东北大学计算机科学与工程学院 沈阳 110819)

摘要 为了提高图像超分辨效果,针对以往稀疏字典超分辨算法仅适用于单特征空间的问题,提出基于贝塔过程联合字典学习(BPJDL)的图像超分辨重建(SRR)方法。首先,根据图像退化模型生成训练样本图像,分别对高、低分辨率图像进行 7×7 分块,并利用吉布斯采样对图像块进行采样,生成字典训练样本。然后,依据贝塔过程先验模型,建立连接高、低分辨率图像空间的双参数联合稀疏字典,将字典稀疏系数分解为系数权值和字典原子的乘积,通过训练和更新字典,得到同时适用于两个特征空间的字典映射矩阵。最后,进行图像超分辨稀疏重构。实验结果表明:本文方法能以更小尺寸的稀疏字典重建超分辨图像,与当前最先进的稀疏表示超分辨算法相比,结果图像主观视觉上纹理细节信息更丰富,客观评价参数峰值信噪比(PSNR)提高约 1.5 dB,结构相似性(SSIM)提高约 0.02,超分辨重建时间降低约 50 s。

关键词 图像超分辨重建(SRR), 稀疏表示, 字典学习, 贝塔过程, 吉布斯采样

0 引言

图像超分辨重建(super-resolution reconstruction, SRR)是一种利用软件处理的方法对同一场景的单帧或多帧低分辨率图像(low-resolution images, LRIs)进行处理得到一帧高分辨率图像(high-resolution images, HRIs)的技术^[1-3]。SRR 技术可以在不改变现有硬件成像设备及工艺水平条件下改善图像视觉质量,提高图像空间分辨率,已成为图像处理领域的热门研究方向之一。

图像超分辨重建方法主要包括基于重建的超分辨和基于学习的超分辨方法两类,近年基于学习的图像超分辨方法已成为研究热点^[4-6]。图像超分辨本质上是一种欠定(或病态)问题,是因为其解不唯

一,即给定一组低分辨率图像,超分辨结果图像会有多个。这种欠定问题常通过强先验信息来限定解空间,而先验信息的获取有些方法利用同类图像的自身相似性^[7,8],通过训练和学习获取高、低分辨率图像对之间的学习映射函数^[9,10]。稀疏编码的方法是典型的基于学习的超分辨方法,这种方法采用字典学习技术获取高、低分辨率图像块间的共同先验信息,高分辨率图像块采用高分辨率字典和稀疏系数来恢复,而稀疏系数采用低分辨率特征块和低分辨率特征字典计算得到。在过去 10 年里,采用过完备字典进行稀疏表示一直是研究热点,很多关于字典学习的算法被提出,如在线字典学习^[11],有效稀疏编码^[12]等等。由于过完备字典的学习是一个 NP-hard 问题,这些算法都可以生成过完备字典和稀疏系数,但是其中的稀疏系数都是高、低分辨率字典共

^① 国家自然科学基金(61601174),黑龙江省博士后科研启动金项目(LBH-Q17150),黑龙江省普通高等学校电子工程重点实验室(黑龙江大学)开放课题,省高校科技创新团队课题(2012TD007),黑龙江省省属高等学校基本科研业务费基础研究项目(KJCXZD201703)和黑龙江省自然科学基金(F2018026)资助项目。

^② 女,1978 年生,博士,副教授;研究方向:图像超分辨,压缩感知、遥感图像处理、神经网络,深度学习等;联系人,E-mail: zhufuzhen@hlju.edu.cn

(收稿日期:2018-08-24)

享的,因此,算法很难拟合两个特征空间的字典和系数。Zeyde 等人^[13]提出了一个两步学习算法,其中低分辨率字典由 K-SVD 算法学习,高分辨率字典通过最小二乘法生成,尽管这种方法可以大大降低计算量,但在高分辨率图像空间仍然不准确。因此,字典学习算法应该兼顾两个特征空间的学习误差。Yang 等人^[14-16]提出了该问题的双层优化解决方案,用一种映射函数代表两个特征空间的关系,但这种方法依然是共享两个特征空间的系数。

在此利用贝塔过程先验模型,提出适用于两个特征空间的字典学习算法,将字典学习过程中的稀疏系数分解为系数权值和字典原子的乘积,得到自适应大小的字典,能以更小的字典重建高质量的超分辨效果。

1 基于贝塔过程的联合字典训练

1.1 信号的稀疏表示

信号的稀疏表示(sparse representation)是压缩感知理论应用的基础,是指根据信号自身特点选择适宜的基函数进行信号分解,得到信号最简洁的表达。经过稀疏表示的信号一定程度上更贴近其本质特征。

具体而言,假设 $\mathbf{D} \in R^{n \times k}$ 表示一个拥有 k 个原子的过完备字典,存在一个信号 $\mathbf{x} \in R^n$,可以被表示为关于 \mathbf{D} 的一个稀疏性的线性组合。也就是说, \mathbf{x} 可以近似描述为 $\mathbf{x} = \mathbf{D}\boldsymbol{\alpha}_0$, 这里的 $\boldsymbol{\alpha}_0 \in R^k$ 表示一个向量,且向量是稀疏的,则该问题可以描述为

$$\operatorname{argmin} \|\boldsymbol{\alpha}\|_0 \text{ s. t. } \|\mathbf{x} - \mathbf{D}\boldsymbol{\alpha}\|_2^2 \leq \varepsilon \quad (1)$$

其中, $\|\boldsymbol{\alpha}\|_0$ 是 ℓ^0 范数。但是,Dmoho 指出,最小 ℓ^0 范数问题是一个 NP-hard 问题,在求解计算时非常麻烦。尽管如此,在满足约束等距性条件下可以用 ℓ^1 范数来代替,则问题(1)变为

$$\operatorname{argmin} \|\boldsymbol{\alpha}\|_1 \text{ s. t. } \|\mathbf{x} - \mathbf{D}\boldsymbol{\alpha}\|_2^2 \leq \varepsilon \quad (2)$$

范数优化问题是一个凸优化问题,存在唯一解。因此,应用稀疏表示理论,可以更精准或高概率精确地恢复高分辨率图像。

1.2 耦合特征空间的贝塔过程联合字典学习

贝塔(Beta)过程^[17,18]可以将系数分解为字典

原子和系数值元素依次相乘的结果,为更好地拟合各个特征空间提供了非常必要的灵活性,同时仍保持两个字典之间的对应关系。在此,设计一种新的基于双参数贝塔过程的联合字典学习(Beta process joint dictionary learning, BPJDL)方法。具体而言,假设有两个耦合特征空间 $X \in R^{P_x}$ 和 $Y \in R^{P_y}$,这两个特征空间中的特征就对应的字典而言是稀疏的。存在一个映射函数 $F: Y \rightarrow X$,它将 Y 中的特征与相对应的 X 中的特征关联起来。因此,字典和被测信号的关系以及两个特征空间的关系可以表示为

$$\mathbf{x}_i = \mathbf{D}^{(x)} \boldsymbol{\alpha}_i^{(x)} + \boldsymbol{\varepsilon}_i^{(x)} \quad (3)$$

$$\mathbf{y}_i = \mathbf{D}^{(y)} \boldsymbol{\alpha}_i^{(y)} + \boldsymbol{\varepsilon}_i^{(y)} \quad (4)$$

$$\mathbf{M} \boldsymbol{\alpha}_i^{(y)} = \boldsymbol{\alpha}_i^{(x)} \quad (5)$$

其中, $\mathbf{x}_i, \mathbf{y}_i, i=1, 2, \dots, N$ 分别表示维数为 P_x 和 P_y 的训练样本图像块。 $\mathbf{D}^{(x)} = (\mathbf{d}_1^{(x)}, \mathbf{d}_2^{(x)}, \dots, \mathbf{d}_K^{(x)})$ 和 $\mathbf{D}^{(y)} = (\mathbf{d}_1^{(y)}, \mathbf{d}_2^{(y)}, \dots, \mathbf{d}_K^{(y)})$ 分别为每个空间中学习得到的含有 K 个原子的字典。 $\boldsymbol{\alpha}_i^{(x)}, \boldsymbol{\alpha}_i^{(y)}$ 是每个字典的稀疏系数。 $\boldsymbol{\varepsilon}_i^{(x)}, \boldsymbol{\varepsilon}_i^{(y)}$ 是重建误差。 \mathbf{M} 是从 \mathbf{y}_i 的稀疏系数 $\boldsymbol{\alpha}_i^{(y)}$ 到 \mathbf{x}_i 的稀疏系数 $\boldsymbol{\alpha}_i^{(x)}$ 的映射矩阵。为了同时学习两个字典,以前的算法^[14,15]是对两个字典采用相同的系数,也就是说 $\boldsymbol{\alpha}_i^{(y)} = \boldsymbol{\alpha}_i^{(x)}$ 。通过这种方式,可以连接两个特征空间,并将耦合特征空间的字典学习问题转换为单个特征空间的字典学习问题。但是,在两个特征空间中使用不同的系数可保证学习过程中更好的拟合度,同时得到的字典更适合特定的特征空间。

本文在文献[17]伯努利-贝塔过程基础上,设计了一个新的双参数贝塔过程来处理耦合特征空间中的字典学习问题。具体可表示为 $BP(a, b, H_0)$, 其中参数 $a, b > 0, H_0$ 是基础测度,写成和函数的形式为

$$H = \sum_{k=1}^K \pi_k \delta_{\mathbf{d}_k^{(x)}} = \sum_{k=1}^K \pi_k \delta_{\mathbf{d}_k^{(y)}} \quad (6)$$

其中,

$$\pi_k \sim Beta(a/k, b(k-1)/k), \mathbf{d}_k^{(x)}, \mathbf{d}_k^{(y)} \sim H_0 \quad (7)$$

这里, $\delta_{\mathbf{d}_k^{(x)}}, \delta_{\mathbf{d}_k^{(y)}}$ 是 $\mathbf{d}_k^{(x)}, \mathbf{d}_k^{(y)}$ 的原子。用一个单独的贝塔过程先验模型和同一个字典原子来连接两个特征空间。基于贝塔过程的一般结构,用于耦合特征

空间的贝塔过程联合字典学习模型可以表示为

$$\mathbf{x}_i = \mathbf{D}^{(x)} \alpha_i^{(x)} + \varepsilon_i^{(x)}, \mathbf{y}_i = \mathbf{D}^{(y)} \alpha_i^{(y)} + \varepsilon_i^{(y)} \quad (8)$$

$$\alpha_i^{(x)} = \mathbf{z}_i \circ \mathbf{s}_i^{(x)}, \alpha_i^{(y)} = \mathbf{z}_i \circ \mathbf{s}_i^{(y)} \quad (9)$$

其中,“。”表示元素依次相乘。

并且,字典原子服从正态高斯分布:

$$\mathbf{d}_k^{(x)} \sim N(0, P_x^{-1} I_{P_x}), \mathbf{d}_k^{(y)} \sim N(0, P_y^{-1} I_{P_y}) \quad (10)$$

稀疏系数权值服从正态高斯分布:

$$\mathbf{s}_i^{(x)} \sim N(0, \gamma_{s^{(x)}}^{-1} I_K), \mathbf{s}_i^{(y)} \sim N(0, \gamma_{s^{(y)}}^{-1} I_K) \quad (11)$$

字典原子服从伯努利分布:

$$\mathbf{z}_i \sim \prod_{k=1}^K \text{Bernoulli}(\boldsymbol{\pi}_k), \quad (12)$$

$$\boldsymbol{\pi}_k \sim \text{Beta}(a/K, b(K-1)/K)$$

重建误差服从正态分布:

$$\varepsilon_i^{(x)} \sim N(0, \gamma_{\varepsilon^{(x)}}^{-1} I_{P_x}), \varepsilon_i^{(y)} \sim N(0, \gamma_{\varepsilon^{(y)}}^{-1} I_{P_y}) \quad (13)$$

$$\gamma_{s^{(x)}}, \gamma_{s^{(y)}} \sim \Gamma(c, d), \gamma_{\varepsilon^{(x)}}, \gamma_{\varepsilon^{(y)}} \sim \Gamma(e, f) \quad (14)$$

以上设计双参数贝塔过程中,选择相同的 \mathbf{z}_i 为 \mathbf{x}_i 和 \mathbf{y}_i 中相对应的字典原子,但稀疏系数不同,构成稀疏系数的权重 $\mathbf{s}_i^{(x)}, \mathbf{s}_i^{(y)}$ 分别从不同的分布中采样得到。最终得到稀疏系数为

$$\alpha_i^{(x)} = \mathbf{z}_i \circ \mathbf{s}_i^{(x)}, \alpha_i^{(y)} = \mathbf{z}_i \circ \mathbf{s}_i^{(y)} \quad (15)$$

其中,“。”表示元素依次相乘。由于 $\alpha_i^{(x)}$ 和 $\alpha_i^{(y)}$ 使用相同的字典原子,非零元素个数相同,因此,两个特征空间中字典原子的对应关系会在训练和学习的过程中得到加强。学习得到稀疏矩阵系数 $\alpha^{(x)}$ 和 $\alpha^{(y)}$ 之后,映射矩阵 \mathbf{M} 可以通过最小二乘法计算得到:

$$\mathbf{M} = [(\alpha^{(y)} \alpha^{(y)T})^{-1} \alpha^{(y)} \alpha^{(x)T}]^T \quad (16)$$

式(9)~(14)是一系列的共轭指数,因此后验推断可以通过吉布斯采样方法来实现。

2 图像超分辨率重建

图像超分辨率重建是一个融合多帧低分辨率图像(LRIs)中的互补信息模拟生成一帧高分辨率图像(HRI)的过程,其数学模型可以表述为^[2,3]

$$Y_k = H_k X + n_k \quad 1 \leq k \leq p \quad (17)$$

其中, p 为可得到的 LRI 的帧数, Y_k 是第 k 帧 LRI, X 是 HRI, n_k 是附加噪声, H_k 表示图像质量退化过程,是一个表示包含相对参考帧运动、模糊化、欠采样等因素在内的一个系数矩阵。

由稀疏表示理论,高分辨率图像 X 可以表示为 $X = \mathbf{D}^{(x)} \alpha^{(x)}$, 低分辨率图像 Y 可以表示为 $Y = \mathbf{D}^{(y)} \alpha^{(y)}$, 又有 $\alpha^{(x)} = \mathbf{M} \alpha^{(y)}$, 可以得到:

$$X = \mathbf{D}^{(x)} \mathbf{M} \alpha^{(y)} \quad (18)$$

其中, \mathbf{M} 为高、低分辨率特征空间的映射矩阵。本文研究的超分辨算法利用 BPJDL 算法学习得到的高、低分辨率字典 $\mathbf{D}^{(x)}, \mathbf{D}^{(y)}$ 和两个特征空间之间的映射矩阵 \mathbf{M} , 以及待恢复图像的稀疏系数 $\alpha^{(y)}$, 通过解决稀疏表示优化类问题实现高分辨率图像重建任务。

2.1 联合字典的训练与学习

为了训练本文提出的耦合空间联合学习字典,首先生成模拟训练样本图像,选定 10 帧不同类别、纹理丰富的图像作为 HRI, 分别将 HRI 进行模糊和下采样的降质操作, 得到尺寸为原 HRI 尺寸 1/4 的 LRI; 再对此 LRI 上采样, 得到与 HRI 相同的尺寸。然后, 分别对得到的高、低分辨率训练样本图像进行 7×7 分块, 相邻块之间有 1 个像素重叠, 并进行吉布斯采样(Gibbs sampling), 得到字典训练样本。设定初始字典大小 K 为 1 024, 选取由 10 帧 HRI 分块并吉布斯采样后的 20 000 个样本作为字典训练样本, 其中老化样本 19 500 个, 剩余的 500 个样本对字典进行平均。训练步骤如下:

- 输入: 成对的高、低分辨率训练图像
- 输出: 学习得到的字典 $\mathbf{D}^{(x)}, \mathbf{D}^{(y)}$ 和矩阵 \mathbf{M}

步骤 1 以 ω 像素重叠从高、低分辨率训练图像中提取训练图像块集合 \mathbf{y}, \mathbf{x} 。

步骤 2 初始化字典 $\mathbf{D}^{(x)}, \mathbf{D}^{(y)}$ 和 $\boldsymbol{\pi}_k, \mathbf{z}_i, \mathbf{s}_i^{(x)}, \mathbf{s}_i^{(y)}$ 。

步骤 3 设定迭代次数或稀疏度或误差。

步骤 4 由吉布斯采样根据式(7)更新 $\boldsymbol{\pi}_k$; 根据式(10)更新 $\mathbf{d}_k^{(x)}, \mathbf{d}_k^{(y)}$; 根据式(12)更新 \mathbf{z}_i ; 根据式(11)更新 $\mathbf{s}_i^{(x)}, \mathbf{s}_i^{(y)}$; 根据式(13)更新 $\varepsilon_i^{(x)}, \varepsilon_i^{(y)}$;

步骤 5 平均样本得到最终的 $\mathbf{D}^{(x)}, \mathbf{D}^{(y)}$, 由式(16)计算映射矩阵 \mathbf{M} 。

2.2 图像超分辨率重建

具体图像超分辨实验中,设定超分辨倍数为 2,稀疏参数 λ 设为 0.15,图像分块尺寸 7×7 ,重叠像素值设置为其最大值 6。具体 SRR 重建步骤如下:

- 输入:低分辨率图像 L 、学习得到的字典 $D^{(x)}$ 、 $D^{(y)}$ 和映射矩阵 M

- 输出:高分辨率图像 H^*

步骤 1 以 ω 像素重叠从 L 中提取低分辨率图像块 l_i ,用 4 个特征提取算子 $F1 = [-1, 0, 1], F2 = F1, F3 = [1, 0, -2, 0, 1], F4 = F3$ 构造 y_i ,构造依据 $x_i = h; y_i = [F_1 l; F_2 l; F_3 l; F_4 l]$, 最后,用稀疏编码计算得到 $\alpha_i^{(y)}$:

$$\alpha_i^{(y)} = \arg \min_{\alpha_i^{(y)}} \| D^{(y)} \alpha_i^{(y)} - y_i \|_2^2 + \lambda \| \alpha_i^{(y)} \|_1 \quad (19)$$

步骤 2 用 M 将稀疏系数 $\alpha_i^{(y)}$ 投影到 $\alpha_i^{(x)}$:

$$\alpha_i^{(x)} = z_i M \alpha_i^{(y)} \quad (20)$$

这里 z_i 是字典原子。

步骤 3 用 $\alpha_i^{(x)}$ 和 $D^{(x)}$ 恢复高分辨率图像块 h_i :

$$h_i = D^{(x)} \alpha_i^{(x)} \quad (21)$$

恢复所有高分辨率图像块之后,初始高分辨率图像 H_0 可以由 ω 重叠像素重建。

步骤 4 采用全局约束和非局部相似性约束进一步提高重建准确性:

$$H^* = \arg \min_H \| H - H_0 \|_2^2 \text{ s. t. } \downarrow BH = L, \\ \| h_i - \sum_{m=1}^M b^m h_{i(0)}^m \|_2^2 \leq \varepsilon \quad (22)$$

这里, h_i 和 $h_{i(0)}$ 是分别从 H 和 H_0 中提取的图像块, $h_{i(0)}^m$ 是跟 $h_{i(0)}$ 最相似的第 m 个图像块, b^m 是文献[19,20]中定义的非局部权重。

3 实验结果与分析

实验所用的计算机技术参数为 4 核 2.8 GHz Intel Core i7 处理器、32 GB 运行内存,迭代 10 000 次的学习时间为 71.614 h,训练字典达到稀疏度为 0.95%,学习均方根误差为 0.061,字典尺寸由 1 024 缩小为 829。训练好的高低分辨率字典如图 1 所示。

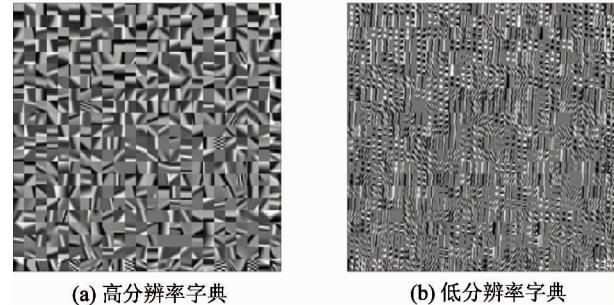


图 1 高、低分辨率字典

超分辨实验对比结果如图 2~图 5 所示。对实验结果采用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity, SSIM)作为超分辨率重建的评价指标,其定义为

$$PSNR = 10 \log_{10} \frac{255^2 M \times N}{\sum_{x=1}^M \sum_{y=1}^N (H(x, y) - H^*(x, y))^2} \quad (23)$$

其中, H 和 H^* 分别表示参考 HRI 和超分辨重建结果图像, M, N 分别表示图像的行数和列数。一般地, $PSNR$ 值越大, 图像质量越好。



图 2 小汽车图像实验结果对比



图3 人物图像实验结果对比



图4 房屋图像实验结果对比

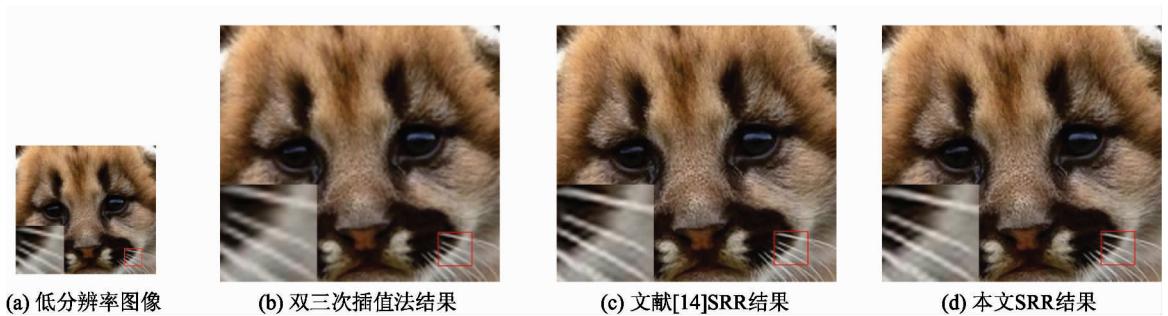


图5 动物图像实验结果对比

假设有图像 x 和 y , 其结构相似性的定义为

$$SSIM = \frac{4\mu_x\mu_y\sigma_{xy}}{(\mu_x^2 + \mu_y^2)(\sigma_x^2 + \sigma_y^2)} \quad (24)$$

其中, μ_x 和 μ_y 是均值, σ_x 和 σ_y 代表方差, 代表

x 和 y 之间的协方差。 $SSIM$ 值越接近 1, 代表图像重建效果越好。对 $PSRN$ 和 $SSIM$ 进行统计, 结果如表 1 所示。

表1 超分辨结果图像的 $PSNR$ 和 $SSIM$ 统计对比

| Image | Bicubic 结果 | | 文献[14] SSR 结果 | | | 本文 SSR 结果 | | |
|--------|------------|-------|---------------|-------|----------|-----------|-------|----------|
| | PSNR (dB) | SSIM | PSNR (dB) | SSIM | SRRT (s) | PSNR (dB) | SSIM | SRRT (s) |
| car | 30.54 | 0.913 | 32.66 | 0.940 | 150 | 33.98 | 0.961 | 99 |
| Lena | 32.80 | 0.887 | 34.44 | 0.913 | 120 | 35.96 | 0.934 | 81 |
| house | 26.36 | 0.804 | 27.65 | 0.850 | 130 | 27.60 | 0.858 | 82 |
| animal | 30.93 | 0.843 | 32.02 | 0.868 | 200 | 33.53 | 0.895 | 130 |

此外,由于人眼视觉对亮度空间更为敏感,因此,本文对待超分辨复原的彩色图像进行了色彩空间变换的预处理,即从 RGB 空间转换至 YCbCr 空间,在超分辨率重建时只对人眼较为敏感的亮度空间进行联合字典的超分辨重建,而对其色度空间仅采用双三次插值处理,这样既可保障超分辨率重建效果,又可大大减少运算量。不同算法超分辨率耗时(SRR time, SRRT)对比结果如表 1 所示。

对比图 2 至图 5 中不同算法的超分辨率结果图像,主观视觉上,相比于三次立方插值算法,本文提出的 BPJDL 超分辨率结果恢复出更多的高频细节和纹理信息;相比于当前先进的稀疏表示超分辨率(文献[14])方法,边缘纹理信息更为丰富。由表 1 中客观参数的对比可见,本文方法较文献[14]的超分辨率结果 PSNR 高出 1.5 dB, SSIM 高出约 0.02,与主观效果更为吻合。同时,本文算法的超分辨率重建速度有明显提高,相比于文献[14]中的 SSR 算法,本文的超分辨率重建时间减少约 50 s,速度提高约 34.6%。其原因为本文提出的 BPJDL 算法利用人眼视觉特性,仅在彩色图像的亮度空间处理,针对耦合特征空间中的字典学习,在两个特征空间中添加了更一致和更准确的映射,这是源自于贝塔过程模型自身的独特特性,即稀疏系数可以被分解为权值和字典原子元素的乘积,相对应的字典原子拥有相同的稀疏度和不同的权值,从而在耦合特征空间之间实现一致且精确的映射。

4 结 论

本文提出一种基于贝塔过程联合字典学习的图像超分辨率重建方法。重点解决了耦合特征空间中的字典学习问题,与当前最先进的稀疏字典学习 SRR 方法(文献[14])相比较,本文方法的超分辨率结果图像的主观效果更好,恢复出更多的纹理细节;客观参数 PSNR 提高约 1.5 dB, SSIM 高出约 0.02,超分辨率重建时间降低约 50 s,速度提高约 34.6%。同时,本文算法可自适应地训练成更小尺寸的字典,使得字典维数更低,因此,本文方法可以更好地拟合耦合特征空间。下一步考虑可以使用变化的贝叶斯推断来

处理 BPJDL 算法,进一步加快吉布斯采样的收敛速度。

参 考 文 献

- [1] Glasner D, Bagon S, Irani M. Super-resolution from a single image [C]. In: IEEE International Conference on Computer Vision, Kyoto, Japan, 2009. 349-356
- [2] 朱福珍,王晓飞,丁群,等.三级训练 BP 神经网络遥感图像超分辨率重建[J].光学精密工程,2015,23(10): 208-215
- [3] 吴强,王国林,许荣庆.两种超分辨 ISAR 成像算法[J].高技术通讯,1999,9(10): 25-29
- [4] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution[J]. *IEEE Computer Graphics and Applications*, 2002, 22(5): 56-65
- [5] Ling F, Zhang Y, Foody G M, et al. Learning-based super-resolution land cover mapping[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(7): 3794-3810
- [6] Yuan Y, Zheng X, Lu X. Hyperspectral image super-resolution by transfer learning[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 10(5): 1963-1974
- [7] Chang H, Yeung D Y, Xiong Y. Super-resolution through neighbor embedding [C]. In: Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Washington, USA, 2004. 275-282
- [8] Sun J, Zheng N N, Tao H, et al. Image hallucination with primal sketch priors[C]. In: IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Madison, USA, 2003. 29-36
- [9] Xie Q L, Chen H, Cao H M. Improved example-based single-based single-image super-resolution [C]. In: The 3rd International Congress on Image and Signal Processing, Yantai, China, 2010. 1204-1207
- [10] Zhao L, Sun Q, Zhang Z. Single image super-resolution based on deep learning features and dictionary model[J]. *IEEE Access*, 2017, 5(99): 17126-17135
- [11] Turkan M, Guillemot C. Online dictionaries for image prediction[C]. In: IEEE International Conference on Image Processing, Brussels, Belgium, 2011. 293-296
- [12] Scholhopf B, Platt J, Hofmann T. Efficient sparse coding

- algorithms [C]. In: Conference on Neural Information Processing Systems, Vancouver, Canada, 2006. 801-808
- [13] Zeyde R, Michael E, Matan P. On single image scale-up using sparse-representations [C]. In: International Conference on Curves and Surfaces, Paris, France, 2010. 711-730
- [14] Yang J, Wright J, Huang T S, et al. Image super-resolution via sparse representation [J]. *IEEE Transactions on Image Processing*, 2010, 19(11) : 2861-2873
- [15] Yang J C, Wang Z W, Lin Z. Bilevel sparse coding for coupled feature spaces [C]. In: IEEE Conference on Computer Vision and Pattern Recognition, Providence, USA, 2012. 2360-2367
- [16] Yang J, Wright J, Huang T, et al. Image super-resolution as sparse representation of raw image patches [C]. In: IEEE Conference on Computer Vision and Pattern Recognition, Anchorage, USA, 2008. 1-8
- [17] He L, Qi H, Zaretaki R. Beta process joint dictionary learning for coupled feature spaces with application to single image super-resolution [C]. In: IEEE Computer Vision and Pattern Recognition, Portland, USA, 2013. 345-352
- [18] Zhou M, Chen H, Paisley J, et al. Nonparametric Bayesian dictionary learning for analysis of noisy and incomplete images [J]. *IEEE Transactions on Image Processing*, 2012, 21(1) : 130-144
- [19] 李绍滨,赵淑清,辛海华. 利用自适应阵对空间信号测向[J]. 高技术通讯,2001, 11(8) : 69-72
- [20] Song P F, Joshua D T, Armando M, et al. Improved super-resolution ultrasound microvessel imaging with spatio-temporal nonlocal means filtering and bipartite graph-based microbubble tracking [J]. *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, 2018, 65(2) : 149-167

Image super-resolution reconstruction based on the Beta process joint dictionary learning

Zhu Fuzhen^{*} , Zou Danni^{**} , Wu Hong^{*} , Bai Hongyi^{*}

(* College of Electrical Engineering, Heilongjiang University, Harbin 150080)

(** College of Computer Science and Engineering, Northeastern University, Shenyang 110819)

Abstract

Aiming to solve the problem that the learning dictionary can only apply to single feature space, an image super-resolution reconstruction (SRR) method is proposed to improve the image SRR effect, which is based on the Beta process joint dictionary learning (BPJDL). Firstly, training sample images are generated according to image degradation model, and high-low resolution images are respectively divided into image patches size of 7×7 . Gibbs sampling is used to generate the dictionary training samples. Then, according to the prior model of BP, a double-parameter joint training dictionary is established to connect the high-low resolution image space. The dictionary sparse coefficients are expressed as a multiplication of coefficient weights and dictionary atoms. After training and updating, a learning dictionary is obtained applying to coupled feature spaces. Finally, image SRR is performed. Experiment results show that the method proposed here can reconstruct the higher quality image with smaller sparse dictionary. At the same time, compared with the most advanced sparse representation SRR algorithm, the result images contain more texture details subjectively, and its objective parameters are better. Its PSNR is increased by about 1.5 dB, SSIM is increased by about 0.02, SRR time is reduced by 50 s.

Key words: image super-resolution reconstruction (SRR), sparse representation, dictionary learning, Beta process, Gibbs sampling