

自适应的图像在线字典学习超分辨率重建算法

程德强*, 于文洁**, 郭昕, 庄焕东, 付新竹

中国矿业大学信息与控制工程学院, 江苏 徐州 221116

摘要 提出一种参数自适应的在线字典学习图像超分辨率重建算法。在经典的稀疏表示算法框架下, 运用在线字典学习方法来提高字典学习的精度。通过参数自适应方法灵活调整稀疏重建阶段的正则化参数, 并依据每个图像块的特点自适应确定正则化参数, 以此克服人为设定参数的单一性和非最佳参数值的缺点。实验结果表明, 与传统算法相比, 所提算法可有效降低测试图像对训练图像集的依赖程度, 同时克服图像在重建过程中存在的局部模糊或失真, 进一步提高重建图像的质量。

关键词 机器视觉; 图像重建; 超分辨率; 在线字典学习; 正则化参数; 自适应

中图分类号 TN911.73

文献标志码 A

doi: 10.3788/LOP57.061505

Super-Resolution Reconstruction Algorithm Based on Adaptive Image Online Dictionary Learning

Cheng Deqiang*, Yu Wenjie**, Guo Xin, Zhuang Huandong, Fu Xinzhu

School of Information and Control Engineering, China University of Mining and Technology,
Xuzhou, Jiangsu 221116, China

Abstract In this paper, an super-resolution imaging reconstruction algorithm based on the parametric adaptive online dictionary learning (ODL) is proposed. Under the framework of the classical sparse representation algorithm, the ODL method is used to improve the accuracy of dictionary learning. Furthermore, the regularization parameters in the sparse reconstruction stage are flexibly adjusted using the parameter adaptive method, so that the regularization parameters can be adaptively determined based on the characteristics of each image block, overcoming the disadvantages of the singularity and incompatibility of the artificially set parameters. Results show that compared with the traditional algorithm, the proposed algorithm can reduce the dependence of test images on the training image set, overcome the local blur or distortion in the reconstruction process, and improve the quality of the reconstructed image.

Key words machine vision; image reconstruction; super-resolution; online dictionary learning; regular parameters; adaptive

OCIS codes 150.1135; 100.3010; 330.1400

1 引言

人类通过眼睛认识世界获取信息, 高分辨率图像具有更高的像素密度、细节信息, 对图像的特征提取、目标识别定位、卫星遥感成像、医学影像等领域都有着重要的意义。但在实际中, 图像会受到成像硬件、外界环境等的影响, 出现信息损失的现象, 导致图像质量降低, 空间分辨率无法满足实际应用的

需要, 不利于后期的图像处理^[1-2]。

图像超分辨率重建是一种数字处理技术, 通过对单幅或者多幅低分辨率图像进行重建, 生成一幅分辨率高的图像。该方法能够在不改变图像传感硬件设备的情况下, 较为有效地恢复出高分辨率图像^[3-5]。

图像超分辨率重建算法主要分为三类: 基于插值、基于重建和基于学习的重建算法。基于插值^[6]的方法通过插值函数在附近像素的基础上弥补丢失

收稿日期: 2019-08-03; 修回日期: 2019-08-18; 录用日期: 2019-09-02

基金项目: 国家重点研发项目(2018YFC0808302)、国家自然科学基金(51774281)

* E-mail: chengdq@cumt.edu.cn; ** E-mail: wjyu@cumt.edu.cn

的像素,算法复杂度不高,但是效果模糊且含有明显的锯齿效果。基于重建^[7]的方法如凸集投影方法、迭代反向投影法等,通常会受到先验信息的限制,存在收敛速度慢、求解不唯一等缺陷。基于学习^[8-9]的方法是近年来的研究热点,该方法的核心思想是从外部图像库中学习低分辨率和高分辨率图像的对应关系,以此估计并恢复出当前低分辨率样本的高分辨率图像,如基于马尔科夫网络和邻域嵌入^[10]的方法,但是前者计算成本大,后者利用低分辨率图像与样本库中 k 个邻近的高分辨率像素点构造所需的高分辨率图像,虽然降低了计算成本,但在近邻像素点数量的选取上存在争议。另一种基于学习的代表性算法是基于稀疏表示的图像超分辨率重建算法,它以同一幅图像中高、低分辨率向量块具有相同的稀疏表示为前提,通过共同训练高、低分辨率图像块组成的两个样本字典,在设定好的前提下进行高、低分辨率向量块的匹配,最终恢复出高分辨率图像^[11]。此法虽可以取得较好的效果,但其字典库的训练模型复杂度高,单一字典库无法有效地表现出明显的图像边缘信息,在细节信息的处理上存在弊端^[12-13]。

目前,随着压缩感知和机器学习技术的不断发展,稀疏表示以及字典训练在超分辨率重建中的应用不断深入。Yang 等^[14]提出的 sparse coding super-resolution(SCSR)是一种有明显提升效果的稀疏编码图像超分方法。在后续的研究中,Yang 等^[15]进一步研究了提升重建速度、缩短重建时间的方法;He 等^[16]采用联合字典训练的方式进行字典学习;Mairal 等^[17]提出在线字典学习(ODL)算法来弥补传统离线字典的缺点,使字典学习不再受小规模固定训练样本的约束,以此获得较好的重建图像。然

而,目前传统的超分辨率重建方法对边缘、纹理等细节信息的恢复能力有限,易产生视觉伪影等,针对此类问题,本文提出一种自适应的在线字典学习图像超分辨率重建算法,以提高重建图像的质量。

2 基于稀疏表示的图像超分辨率重建模型

大多数现实场景较为复杂,但自然图像可以分割成许多简单的像素块。原子是信号表示模板的元素,图像的局部像素结构可以采用不同的原子组合表示,不同的组合用来表示不同的图像信号。这种表示结构可以保持甚至突出图像的原始细节信息。基于稀疏编码的图像超分辨率重建就是通过低分辨率图像的局部低频信息来寻找对应的原子组以获得高分辨率目标图像高频细节信号的过程。基于稀疏表示和字典学习的图像超分辨率重建算法的数学模型可以描述为

$$\begin{cases} \mathbf{Y} = \mathbf{S}\mathbf{H}\mathbf{X} + \mathbf{n}, \text{ reconstruction constraint} \\ \min \|\boldsymbol{\alpha}\|_0, \text{ s.t. } \mathbf{x} = \mathbf{D}_h\boldsymbol{\alpha} \text{ for some } \boldsymbol{\alpha}, (1) \\ \boldsymbol{\alpha} \in \mathbf{R}^i, \text{ sparse prior} \end{cases}$$

式中: \mathbf{Y} 为输入的低分辨率图像; $\mathbf{X} \in \mathbf{R}^{N \times M}$ 为高分辨率图像,其像素块向量 \mathbf{x} 的长度为 M ; \mathbf{S} 和 \mathbf{H} 分别为将高分辨率图像经过下采样和模糊作用产生低分辨率图像过程中对应的下采样和模糊算子; \mathbf{n} 为噪声因子; \mathbf{D}_h 为高分辨率图像对应的过完备字典; $\boldsymbol{\alpha}$ 为稀疏系数。

基于稀疏编码的超分辨率重建算法通过训练样本集 \mathbf{N} 和低分辨率图像估计与原始高分辨率图像 \mathbf{X} 之间存在最小误差的高分辨率图像 \mathbf{X} 。完成重构任务,如图 1 所示。

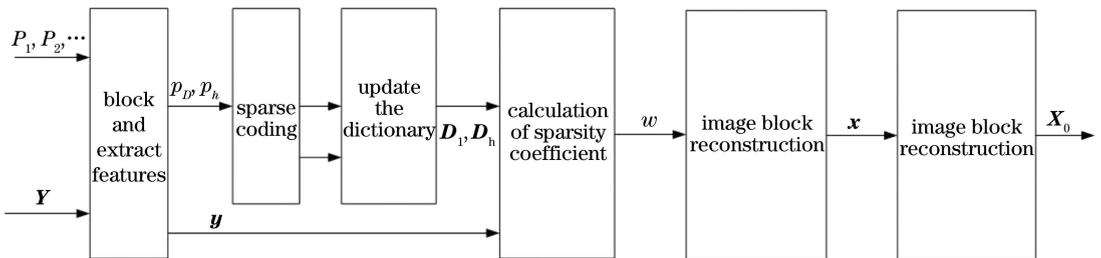


图 1 基于稀疏编码的超分辨率重建

Fig. 1 Super-resolution reconstruction based on sparse encoding

基于稀疏编码的超分辨率重建算法中有两个需要解决的关键问题:1)在训练阶段寻找低分辨率图像与高分辨率图像之间普遍对应关系的过程中,通过何种学习方法找到最佳的过完备字典 \mathbf{D} ;2)如何通过已有字典 \mathbf{D} 重建出与原始图像误差尽量小的

高分辨率图像。

3 本文算法模型

本文提出一种图像自适应的 ODL 超分辨率重建方法,该算法有效结合了图像稀疏表示的相关理

论,主要分为三个阶段:图像块预处理、字典训练以及图像稀疏重构。

3.1 图像块预处理

从图像库中输入一系列样本图像作为字典训练的对象,将需要进行超分重建的自然图像作为目标。在样本训练阶段,从样本图像 $L \in \mathbf{R}^{p \times q}$ 中分割出 q 个指定的大小相同的正方形像素块 $l \in \mathbf{R}^k$, 像素大小 $p = k \times k$, 其中 k 可取 2、4 等,将每个像素块向量作为一组输入样本,向量长度为 P 。样本集的大小决定了像素向量的数量,数量越多,训练得到的字典越精确,同时所需时间越长。为了平衡二者, q 通常选取 10000~100000^[18] 较为合适。假如出现实际样本集产生的向量块数量大于此值的情况,将随机选择所需数目。图像稀疏重建过程中,输入的低分辨率图像也要被分割成相对应的高、低频图像块向量进行重建,从而得到高分辨率图像。

图像块预处理阶段还需要提取图像特征。低分辨率图像的高频部分在重建过程中起着至关重要的作用,它能够有效地预测高分辨率目标图像需要恢复的高频信息。通常选择一系列高斯导数滤波器或一个高通滤波器来提取低分辨率图像块的边缘轮廓信息。本文选用与 Chang 等^[19] 相同的方法,使用图像块的一次和二次梯度表示,包含 4 个一维滤波器。该方法过程简单又可以较好地提取图像的细节特征。本文方法可表示为

$$\begin{aligned} f_1 &= [-1, 0, 1], f_2 = f_1^T, \\ f_3 &= [1, 0, -2, 0, 1], f_4 = f_3^T, \end{aligned} \quad (2)$$

式中: T 表示转置。至此,将获得的每个图像块的 4 个描述向量组合起来形成一个特征向量,即低分辨率像素块的最终表示向量 F 。

3.2 字典训练

信号稀疏理论是自然信号能够被精确表示,或无限接近于预设基原的稀疏线性组合,即线性系数大多为零。稀疏编码是一个学习优化稀疏字典的过程,即将样本转化为合适的稀疏表达形式,包括稀疏编码和字典更新两个阶段,从而求解出高分辨率字典 D_h 和低分辨率字典 D_l 。

3.2.1 稀疏编码

图像块是稀疏表示算法中的基本单元,每列串联图像块构成图像块向量。用 x 表示 n 维高分辨率特征图像块向量, y 表示 m 维低分辨率图像块向量。用矩阵 D_h 和 D_l 描述包含 K 个原子的字典 ($K > n, K > m$)。 D_h 和 D_l 分别从高分辨率图像的样本库及其所对应的低分辨率图像中训练所得。 x

可由 D_h 的原子稀疏线性组合表示,即

$$x = D_h \alpha. \quad (3)$$

用 $\|\alpha\|_0$ 表示由 α 组成的系数集中非零元素的数量, $\|\alpha\|_0 \ll K$, $\|\alpha\|_0$ 是 α 的 l_0 范数。对 y 进行解下列 l_0 最小化问题可以估计稀疏系数,即

$$\alpha_{\min} = \underset{\alpha}{\operatorname{argmin}} (\|D_l \alpha - y\|_2^2 + \gamma \|\alpha\|_0), \quad (4)$$

式中: γ 为正正则化参数,是用来对解的稀疏性和结果的保真性进行平衡的参数。

l_0 最小化问题是非确定性多项式(NP)问题,可以在 α 充分稀疏的条件下用 l_1 最小化问题近似:

$$\alpha_{\min} = \underset{\alpha}{\operatorname{argmin}} (\|D_l \alpha - y\|_2^2 + \gamma \|\alpha\|_1), \quad (5)$$

式中: $\|\alpha\|_1$ 是 α 的 l_1 范数, l_1 范数是 l_0 范数的最优凸近似,比 l_0 范数更易于优化求解。同时,联合上述图像块预处理部分的特征提取 F , 根据拉格朗日乘子进行公式变换,可得

$$l(x, D) \stackrel{\text{def}}{=} \min_{D, \alpha} \frac{1}{2} \|Fx - FD\alpha\|_2^2 + \gamma \|\alpha\|_1. \quad (6)$$

对于输入图像的每一个 y , 利用(5)式与 D_l 进行结合得到相对应的稀疏系数 α , 再通过(3)式,利用 α 和 D_h 从 y 中恢复出所对应的高分辨率图像块向量 x , 拼接所有的 x 即可获得最终重建的高分辨率图像。

3.2.2 引入 ODL

在基于学习的图像超分辨率重建过程中,字典训练的结果影响着最终重构的效果。传统的稀疏编码算法为:在已知初始字典的情况下通过(6)式采用正交匹配追踪等算法求解稀疏系数 α , 再采用 K-SVD 算法对稀疏字典逐列更新获取目标超完备字典。Mairal 等^[17] 提出了 ODL 算法,相对于传统稀疏编码的字典学习算法,其优点在于可以根据字典的上一个信息数据迭代更新,适合大规模和不确定训练样本集。ODL 方法中, D 被认为是 X_n 的统计参数值组合,训练得到的 D_n^0 在进行迭代更新时不需要完整的历史图像块数据,即在获取图像块有效信息进行字典的迭代更新时,得到的结果与之前的图像块信息无关,而仅与当前字典和输入的图像块信息有关。因此,传统字典学习方法与 ODL 算法的区别可表示为

$$\begin{cases} D_i^n = f_i(x_n, X_{n-1}) \\ D_0^n = f_0(x_n, D_{n-1}) \end{cases}. \quad (7)$$

ODL 算法过程中无需每次都记录 X_n 并进行处理,它将结合当前 x_n 与上一步迭代更新生成的 D_{n-1} , 统计地表示为 X_{n-1} 。此方法生成的目标超完备字典精度更高,且在大规模应用于视频帧

序列等的动态数据方面,这些都是传统的字典学习算法无法企及的。因此,本文引入 ODL 改进算法,分别对高、低分辨率图像样本进行训练,得到 \mathbf{D}_h 和 \mathbf{D}_l 。

1) 初始化阶段

输入信号为 $\mathbf{X}_n = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, 设置此阶段所需的正则化参数 γ_0 , 以及图像块大小 p , 利用离散余弦变换、稀疏编码、随机矩阵等方法对 \mathbf{D}_0 进行初始化训练。

2) 求解稀疏系数

从 $\mathbf{D} = \mathbf{D}_0$ 开始, 通过最小角回归算法迭代求解 $\alpha_{n-\min} \stackrel{\text{def}}{=} \underset{\alpha_n}{\text{argmin}} \frac{1}{2} \|\mathbf{x}_i - \mathbf{D}_{n-1} \boldsymbol{\alpha}_i\|_2^2 + \gamma \|\boldsymbol{\alpha}_i\|_1$,

$$(8)$$

式中: $n = \{1, 2, \dots, N\}$, 表示迭代次数; \mathbf{x}_i 为当前输入图像块向量; $\alpha_{n-\min}$ 为更新的稀疏系数。为将训练效果与所用时间相平衡, 本研究选择确定大小的样本集进行字典学习。

3) 字典更新

将 \mathbf{D}_{n-1} 作为热启动, 与每次迭代更新得到的稀疏系数 $\{\boldsymbol{\alpha}_{n-i+1}, \dots, \boldsymbol{\alpha}_n\}$ 相结合, 根据(9)式不断在线更新 $\mathbf{D}_{n-\min}$:

$$\mathbf{D}_{n-\min} \stackrel{\text{def}}{=} \underset{\mathbf{D}_n \in \mathbf{c}}{\text{argmin}} \frac{1}{n} \cdot \left\{ \sum_{i=1}^n \|\mathbf{x}_i - \mathbf{D} \boldsymbol{\alpha}_i\|_2^2 + \gamma \|\boldsymbol{\alpha}_i\|_1 \right\}. \quad (9)$$

字典列过大时, 无法满足约束条件 $\mathbf{D} \in \mathbf{c}$, 因此, 引入约束最优化来克服这一问题, 与牛顿迭代法相结合进行归一化处理后可得:

$$\mathbf{D}(:, i) \leftarrow \frac{\mathbf{D}(:, i)}{\max \|\mathbf{D}(:, i)\|_2, 1}. \quad (10)$$

4) 字典生成

N 次迭代更新结束后, 得到目标所需的超完备字典 \mathbf{D}_N 。按照上述步骤, 对已知的高分辨率图像样本进行学习训练得到高分辨率字典 \mathbf{D}_h ; 对插值缩小后的低分辨率图像样本训练生成低分辨率字典 \mathbf{D}_l 。

3.3 改进的稀疏重建

3.3.1 优化稀疏系数——参数自适应方法

在字典训练阶段引入 ODL, 对字典按照上述步骤进行更进一步的精准学习训练, 取得最优的超完备高低分辨率字典对 $(\mathbf{D}_h, \mathbf{D}_l)$ 。依据(3)式, 要想使待重建的高分辨率图像块尽可能精确, 除了需要确保字典 \mathbf{D}_h 的精准性外, 在重建阶段稀疏系数 α_i 的

取值也尤为关键, 它可由(5)式求解。因此, 为了使得该值的求解更加贴合图像块的性质, 通过自适应调整重建阶段的正则化参数 γ 来找到最适合的重建稀疏系数, 以提升最终的图像重建效果。

传统重建算法中, 稀疏正则项参数 γ 通常是由实验人员依据经验设定, 且对于每个补丁 \mathbf{x}_i 的训练, γ 取固定值, 而这影响着每个补丁的稀疏编码。因此, 本文提出一种通过优化稀疏正则项的参数自适应方法, 依据图像块的条件, 自适应地计算各图像块的 γ 值。

Kang 等^[20]基于图像复原的相关理论和原始图像 \mathbf{x} 及其在模糊退化过程中的特点, 提出一种正则化参数的求解方法。本文将该方法与稀疏编码的重建模型有效结合, 提出一种稀疏正则参数的自适应算法。

从上一步迭代结果得出的目标图像 \mathbf{x}_i 中可以确定正则化参数 $\gamma^{[20]}$, 因此, 可将(5)式表示为

$$\alpha_{i-\min}^* = \underset{\alpha_n}{\text{argmin}} \|\mathbf{D}_l \boldsymbol{\alpha}_i - \mathbf{y}_i\|_2^2 + \gamma(\mathbf{x}_i^t) \|\boldsymbol{\alpha}_i\|_1, \quad i = 1, 2, \dots, m. \quad (11)$$

(11)式为 Lasso 问题, 求解方式多样, 本文选择特征符号搜索算法对(11)式进行求解^[21]。

由(3)式可知, \mathbf{x}_i 由 \mathbf{D}_h 和 $\boldsymbol{\alpha}_i$ 确定, 为了简化运算, 将(11)式改写为

$$J(\gamma(\boldsymbol{\alpha}_i), \boldsymbol{\alpha}_i) = \|\mathbf{D}_l \boldsymbol{\alpha}_i - \mathbf{y}_i\|_2^2 + \gamma(\boldsymbol{\alpha}_i) \|\boldsymbol{\alpha}_i\|_1, \quad i = 1, 2, \dots, m. \quad (12)$$

设定 $\gamma(\boldsymbol{\alpha}_i)$ 是关于 $J(\gamma(\boldsymbol{\alpha}_i), \boldsymbol{\alpha}_i)$ 的线性函数^[20], 即

$$\gamma(\boldsymbol{\alpha}_i) = \lambda J(\gamma(\boldsymbol{\alpha}_i), \boldsymbol{\alpha}_i). \quad (13)$$

为了满足 $J(\gamma(\boldsymbol{\alpha}_i), \boldsymbol{\alpha}_i)$ 的凸性, 对于 λ 的选择应满足约束条件 $\lambda \leq \frac{1}{\|\boldsymbol{\alpha}\|_1}$, 且

$$\lambda = \|\mathbf{x}_i\|^2, \quad (14)$$

因此可得

$$\gamma(\boldsymbol{\alpha}_i) = \frac{\|\mathbf{D}_l \boldsymbol{\alpha}_i - \mathbf{y}_i\|_2^2}{\frac{1}{\lambda} - \|\boldsymbol{\alpha}_i\|_1} \times \frac{1}{2}. \quad (15)$$

3.3.2 参数自适应的 ODL 图像超分重建

本文引入 ODL 方法, 将参数自适应算法纳入稀疏重建中, 以此改进稀疏编码的经典算法框架, 求得稀疏系数, 实现参数自适应的 ODL 图像超分重建。

1) 输入 ODL 阶段训练好的高分辨率字典 \mathbf{D}_h 和低分辨率字典 \mathbf{D}_l , 输入低分辨率图像 \mathbf{Y} , 将它分割成 q 个图像块向量;

2) 设定初始稀疏系数 γ_0 , 且对于每个小块, 求解(11)式得到初始化系数 α_0 ;

3) 通过(16)式求解自适应系数 γ^* :

$$\gamma^*(\alpha_i) = \frac{\|D_i \alpha_i - y_i\|_2^2}{\frac{1}{\lambda} - \|\alpha_i\|_1} \times \frac{1}{2}, \lambda = \|y_i\|_2^2; \quad (16)$$

4) 求解(17)式得到重建稀疏系数 α' :

$$\alpha'_{i-\min} = \operatorname{argmin} \|D_i \alpha_i - y_i\|_2^2 + \gamma(\alpha_i) \|\alpha_i\|_1, \quad i = 1, 2, \dots, m; \quad (17)$$

5) 依据(1)式中的稀疏先验, 通过高分辨率字典 D_h 和稀疏系数 α' 获得高分辨率图像块向量;

6) 由低分辨率图像 Y 结合(1)式中的重建约束, 获取与原始高分辨率图像误差最小的图像 X_0 ;

7) 用(18)式进行全局优化, 且得到高分辨率图像 X^* :

$$X^* = \operatorname{argmin}_X \|SHX - Y\|_2^2 + c \|X - X_0\|. \quad (18)$$

4 实验结果与分析

为了检验本文算法的优越性, 从超分辨率重建研究领域中选择部分常用图像, 在不同噪声环境和扩大因子下进行测试实验, 取参数 γ_0 分别为 0.7、0.8、0.9 时的本文算法结果与 Bicubic、NE、ScSr-ODL 算法进行对比。

4.1 实验环境

实验所使用的软件为 MATLAB 2016b, 实验环境为 Windows 10 系统(64 位), 计算机配置为: Intel (R)Core(TM)i5-8400, 2.8 GHz 主频, 16 GB 内存。将低分辨率图像块向量化后减去均值, 再用上述预处理方式提取梯度特征, 重建后与均值相加, 这样可以突出图像的边缘及细节信息。实验中选取大小均为 $128 \text{ pixel} \times 128 \text{ pixel}$ 的彩色图像作为低分辨率图像, 补丁块的大小 $5 \text{ pixel} \times 5 \text{ pixel}$, 且将图像从 RGB 空间转换到 YCbCr 空间进行重建测试。

使用方均根误差(RMSE)、峰值信噪比(PSNR)和结构相似度(SSIM)3个常用指标来评估实验效果。使用 w 和 h 分别表示图像纵、横方向的像素数量, $P_{\max\text{-pixel}}$ 表示最大的像素取值, 本实验中取 $P_{\max\text{-pixel}} = 255$, u_x 和 u_y 表示窗口的亮值估计, σ_x 和 σ_y 则为对比预估值。这3项评估指标的计算方法如下:

1) 方均根误差, 此值越小, 重建图像的质量越高,

$$R_{\text{MSE}}(x, y) = \sqrt{\frac{1}{hw} \|x - y\|_F^2}; \quad (19)$$

2) 峰值信噪比, 此值越大, 表示重建图像效果越好,

$$P_{\text{SNR}}(x, y) = 20 \lg(P_{\max\text{-pixel}}/R_{\text{MSE}}); \quad (20)$$

3) 结构相似度, 此值越大, 表示重建图像与原始图像误差越小,

$$S_{\text{SIM}} = \frac{(2u_x u_y + k_1^2 P_{\max\text{-pixel}}^2)(2\sigma_x \sigma_y + k_2^2 P_{\max\text{-pixel}}^2)}{(u_x^2 + u_y^2 + k_1^2 P_{\max\text{-pixel}}^2)(\sigma_x^2 + \sigma_y^2 + k_2^2 P_{\max\text{-pixel}}^2)}, \quad k_1 < 1, k_2 < 1. \quad (21)$$

4.2 实验结果

图2所示为图像 Lenna 分别在人工选定和自适应的情况下数值之间的对比(扩大因子为 2, γ 为 0.9)。由此可见, 人工设定的参数会导致所有图像块使用单一且非最优参数值, 而引入自适应的 ODL 恰好可以解决这一问题, 根据自身特点有效地确定每个图像块的最优值。

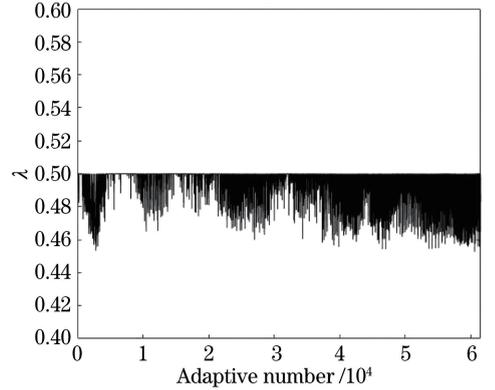


图2 图像 Lenna 的自适应值可视化

Fig. 2 Visualization of adaptive value for the image of Lenna

由文献[15]的稀疏表示超分重建算法的实验结果可知, 当正则化参数 γ 由人为设定为固定值时, γ 取 0.48 时可获得最优的重建效果。ODL 算法则可以提高字典训练的精度, 进一步提升图像的重建质量。而本文算法既引入 ODL 来提高字典训练的精度, 又克服了经典稀疏重建阶段正则项参数固定单一且非最优值的缺点, 并且由实验结果可知, 当 $\gamma_0 \geq 0.48$ 时, 本文算法的图像重建质量均得到明显的提升, 特别是对细节特征的处理结果更显著, 因此本研究仅以 γ_0 取 0.7、0.8、0.9 为例展示实验对比结果。

首先, 对 8 组图片在扩大因子为 2 的条件下进行测试, 其中, ScSr1^[14]、ScSr2^[14]、ScSr3^[14]、ODL1^[17]、ODL2^[17]、ODL3^[17] 分别表示正则化参数为固定值, 人为取得 $\gamma = 0.7、0.8、0.9$; ours1、ours2、

ours3 分别表示参数 γ_0 的初始取值 0.7、0.8、0.9 时的正则化参数自适应的图像 ODL 超分重建算法。

图 3 所示为图像 baby、Lenna 以及 butterfly 在各超分辨率重建算法下的结果。

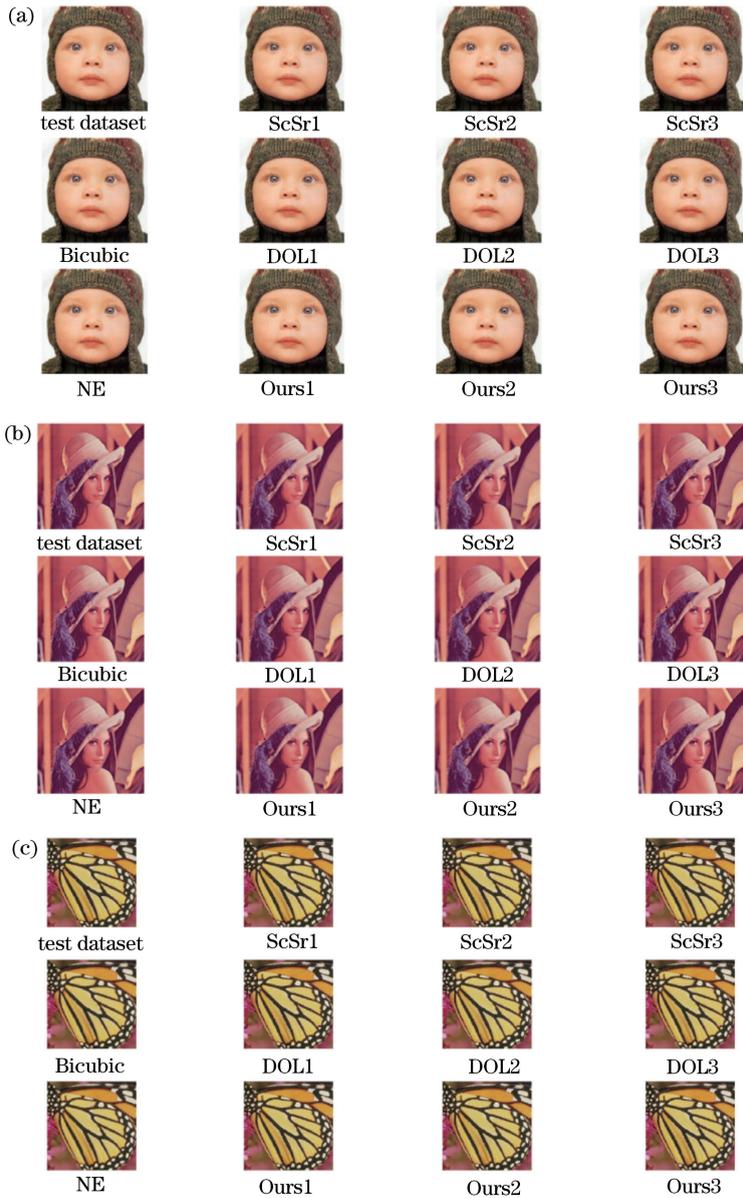


图 3 扩大因子为 2 时不同图像的重建效果对比。(a) Baby;(b) Lenna;(c) butterfly

Fig. 3 Comparison of reconstruction for different images when the magnification factor is 2.

(a) Baby; (b) Lenna; (c) butterfly

表 1 为利用传统超分重建算法 (Bicubic)、NE 算法与本文算法对 8 张图像进行重建得到的数据。由于 Bicubic 与 NE 这两种传统的超分重建算法没有用到稀疏编码,因此无正则项,与 γ 无关,本文算法的优越性是显而易见的。表 2 为稀疏表示算法 ScSr^[14]、ODL^[17] 与本文算法的实验数据对比。可以看到,本文算法的 3 项评价指标均得到较好的提升,由此证明本文算法具有一定的优越性。

基于稀疏表示的超分重建算法 ScSr 以及 ODL 算法均采用人为设定的正则项参数, γ 在字典训练以及稀

疏重建阶段固定不变,而本文算法在取相同的 γ_0 作为自适应的初始正则化参数后取得明显的改进效果。

为进一步验证本文算法对于成像质量差的低分辨率图像在重建过程中出现的模糊失真问题的有效性,将图像扩大因子设为 3,继续进行对比实验。图 4 所示为采用不同算法对图像 baby 进行重建的对比结果,表 3 则为 baby、man、butterfly 以及 baboon 4 组图像在每个算法下的重建结果对比,由此可见,本文算法的 3 项评估指标均有明显提升,证实了本文算法的优越性。

表 1 扩大因子为 2 时不同图像的重建数值对比

Table 1 Numerical comparison of reconstruction for different images when the magnification factor is 2

Method	Evaluation index	Baby	Lenna	Butterfly	Subway	Man	Bike	Baboon	Monarch
Bicubic	RMSE	4.157	5.455	12.572	10.009	10.213	15.479	17.337	6.673
	PSNR	37.059	34.713	27.462	29.440	29.261	25.657	24.674	32.958
	SSIM	0.951	0.911	0.915	0.871	0.845	0.850	0.696	0.959
NE	RMSE	4.622	12.108	15.991	11.624	10.926	21.070	19.442	7.543
	PSNR	36.889	28.669	26.559	27.416	28.291	21.657	22.589	31.211
	SSIM	0.893	0.788	0.737	0.753	0.786	0.591	0.505	0.882
Ours1	RMSE	3.601	4.561	7.836	8.623	8.863	11.357	16.157	4.701
	PSNR	38.384	36.299	31.572	30.802	30.500	28.401	25.286	36.031
	SSIM	0.963	0.927	0.958	0.908	0.880	0.914	0.759	0.970
Ours2	RMSE	3.603	4.574	7.845	8.520	8.881	11.486	16.141	4.718
	PSNR	38.351	36.276	31.562	30.846	30.483	28.322	25.295	35.996
	SSIM	0.963	0.926	0.958	0.909	0.880	0.9127	0.759	0.971
Ours3	RMSE	3.605	4.571	7.843	8.564	8.854	11.414	16.148	4.675
	PSNR	38.360	36.280	31.563	30.850	30.508	28.353	25.291	36.079
	SSIM	0.963	0.926	0.958	0.910	0.880	0.914	0.760	0.971

表 2 扩大因子为 2 时不同图像的重建数值对比

Table 2 Numerical comparison of reconstruction for different images when the magnification factor is 2

Method	Evaluation index	Baby	Lenna	Butterfly	Subway	Man	Bike	Baboon	Monarch
ScSr1 ^[14]	RMSE	3.656	4.631	7.911	8.696	8.885	11.619	16.218	5.145
	PSNR	38.262	36.215	31.502	30.707	30.484	28.207	25.269	35.300
	SSIM	0.961	0.925	0.956	0.906	0.878	0.910	0.757	0.967
ODL1 ^[17]	RMSE	3.633	4.593	7.884	8.672	8.866	11.594	16.185	5.104
	PSNR	38.270	36.239	31.518	30.738	30.497	28.226	25.272	35.309
	SSIM	0.962	0.926	0.957	0.907	0.879	0.911	0.758	0.968
Ours1	RMSE	3.601	4.561	7.836	8.623	8.863	11.357	16.157	4.701
	PSNR	38.384	36.299	31.572	30.802	30.500	28.401	25.286	36.031
	SSIM	0.963	0.927	0.958	0.908	0.880	0.914	0.759	0.97
ScSr2 ^[14]	RMSE	3.693	4.692	8.268	8.802	8.995	12.295	16.173	4.881
	PSNR	38.205	36.083	31.158	30.571	30.377	27.796	25.277	35.762
	SSIM	0.961	0.921	0.955	0.903	0.876	0.903	0.757	0.969
ODL2 ^[17]	RMSE	3.651	4.652	8.108	8.776	8.986	12.282	16.167	4.834
	PSNR	38.231	36.127	31.274	30.592	30.385	27.801	25.281	35.785
	SSIM	0.962	0.925	0.956	0.905	0.877	0.904	0.758	0.970
Ours2	RMSE	3.603	4.574	7.845	8.520	8.881	11.486	16.141	4.718
	PSNR	38.351	36.296	31.562	30.846	30.483	28.322	25.295	35.996
	SSIM	0.963	0.926	0.958	0.909	0.880	0.9127	0.759	0.971
ScSr3 ^[14]	RMSE	3.751	4.801	9.309	8.982	9.385	12.963	16.179	5.479
	PSNR	38.080	35.887	30.043	30.415	30.134	27.206	25.283	34.791
	SSIM	0.960	0.923	0.942	0.901	0.874	0.895	0.758	0.966
ODL3 ^[17]	RMSE	3.707	4.768	9.235	8.966	9.220	12.944	16.154	5.406
	PSNR	38.106	35.912	30.145	30.440	30.157	27.214	25.288	34.810
	SSIM	0.961	0.924	0.948	0.902	0.875	0.896	0.759	0.967
Ours3	RMSE	3.605	4.571	7.843	8.564	8.854	11.414	16.148	4.675
	PSNR	38.360	36.290	31.563	30.850	30.508	28.353	25.291	36.079
	SSIM	0.963	0.926	0.958	0.910	0.880	0.914	0.760	0.971

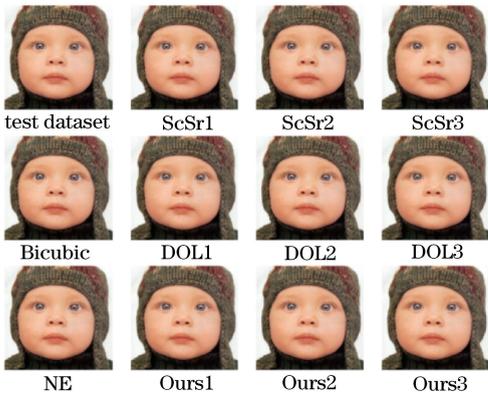


图4 扩大因子为3时 baby 图像的重建效果对比

Fig. 4 Comparison of reconstruction for image of baby when the magnification factor is 3

同样,将图像扩大因子设为4 继续进行对比实验,得到结果如图5和表4所示。图5所示为采用

不同算法对图像 baby 进行重构的效果对比,表4 则为 baby、man、butterfly 以及 baboon 4 组图像在不同算法下的重建数值对比。可以看出本文算法的3项评估指标仍均有明显提升,可证实本文算法在不同扩大因子下均可取得较好的重建效果。

本研究还在不同噪声环境下采用不同的算法进行对比实验。图6所示为图像 Lenna 在0.0005的高斯噪声环境中的实验重建效果对比,表5为图像 Lenna 在扩大因子为2,方差分别设为0、0.0002以及0.0005的高斯噪声环境中的实验结果。图7所示为图像 Lenna 在0.001的椒盐噪声下的重建效果对比,表6为图像 Lenna 在扩大因子为2,密度分别设为0、0.0005以及0.001的椒盐噪声环境中的实验结果。可以看出,本文算法适用于不同水平的噪声环境,且其重建效果均能得到提升。

表3 扩大因子为3时的不同图像的重建结果对比

Table 3 Numerical comparison of reconstruction for different images when the magnification factor is 3

Method	Evaluation index	Baby	Man	Butterfly	Baboon
Bicubic	RMSE	5.956	13.206	18.611	20.992
	PSNR	33.941	27.032	24.056	23.013
	SSIM	0.904	0.749	0.819	0.543
NE	RMSE	6.774	14.115	19.013	22.873
	PSNR	30.857	23.902	21.667	21.584
	SSIM	0.881	0.706	0.798	0.610
ScSr1 ^[14]	RMSE	5.541	12.345	15.549	20.601
	PSNR	34.607	27.627	25.619	23.136
	SSIM	0.914	0.781	0.858	0.590
ODL1 ^[17]	RMSE	5.518	12.322	15.523	20.555
	PSNR	34.626	27.639	25.635	23.197
	SSIM	0.915	0.782	0.859	0.591
Ours1	RMSE	5.395	12.174	15.321	20.224
	PSNR	34.823	27.744	25.749	23.338
	SSIM	0.920	0.784	0.865	0.600
ScSr2 ^[14]	RMSE	5.447	12.473	15.649	20.440
	PSNR	34.709	27.711	25.535	23.242
	SSIM	0.917	0.781	0.858	0.593
ODL2 ^[17]	RMSE	5.459	12.190	15.621	20.418
	PSNR	34.720	27.732	25.579	23.255
	SSIM	0.916	0.782	0.859	0.594
Ours2	RMSE	5.395	12.104	15.501	20.224
	PSNR	34.823	27.793	25.648	23.338
	SSIM	0.920	0.784	0.863	0.600
ScS3 ^[14]	RMSE	5.577	12.202	15.700	20.663
	PSNR	34.589	27.729	25.539	23.168
	SSIM	0.912	0.782	0.856	0.588
ODL3 ^[17]	RMSE	5.540	12.186	15.689	20.615
	PSNR	34.592	27.735	25.541	23.171
	SSIM	0.913	0.783	0.857	0.589
Ours3	RMSE	5.513	12.172	15.520	20.576
	PSNR	34.636	27.745	25.636	23.187
	SSIM	0.915	0.784	0.861	0.591

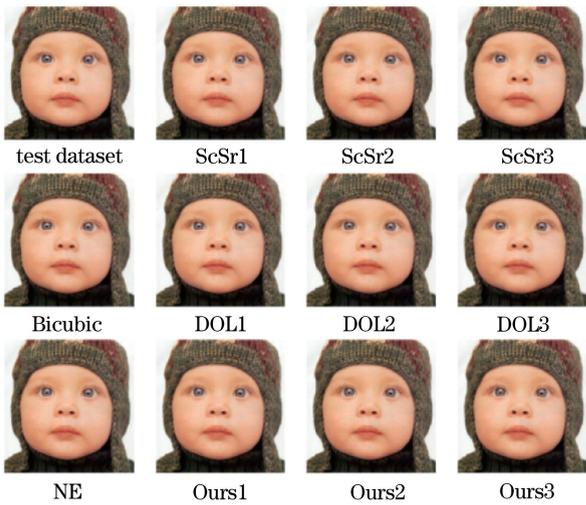


图5 扩大因子为4时 baby 图像的重建效果对比
Fig. 5 Comparison of reconstruction for image of baby when the magnification factor is 4

5 结 论

基于学习的超分辨率重建是目前应用较多且效果较好的一种普遍算法,对边缘锐化图像的处理结果良好,但是同时存在着模糊失真的缺点,导致纹理区域存在不同程度的变形。为了克服这些问题,一方面引入 ODL 算法,这一算法在线迭代更新原有字典,通过外部训练样本分别得到高低分辨率字典,获得更加精确的超完备字典;另一方面,通过参数自适应方法自动有效地调整图像重建阶段的正则化参数,在提高分辨率的同时,保持图像边缘的锐度且有效复原图像的纹理细节,在主观和客观评价上均取得明显的优化效果,而且在处理含噪图像时,其结果的 PSNR 值更加稳定,噪声鲁棒性更好。在后续的研究中,可以从改进 ODL 的字典训练模型入手,进一步完善参数的自适应计算,设计更适合的图像超分辨率算法。

表4 扩大因子为4时不同算法的重建数值对比

Table 4 Comparison of reconstruction for different images when the magnification factor is 4

Method	Evaluation index	Baby	Man	Butterfly	Baboon
Bicubic	RMSE	7.601	15.334	23.192	22.934
	PSNR	31.828	25.734	22.145	22.244
	SSIM	0.857	0.676	0.734	0.451
NE	RMSE	7.083	15.993	24.850	22.663
	PSNR	31.880	25.002	21.785	22.291
	SSIM	0.858	0.605	0.690	0.473
ScSr1 ^[14]	RMSE	6.773	14.258	21.263	22.601
	PSNR	32.864	26.447	22.905	22.378
	SSIM	0.876	0.711	0.754	0.490
ODL1 ^[17]	RMSE	6.751	14.203	21.218	22.512
	PSNR	32.872	26.450	22.919	22.407
	SSIM	0.877	0.712	0.755	0.491
Ours1	RMSE	6.735	14.109	21.040	22.497
	PSNR	32.893	26.462	22.992	22.413
	SSIM	0.878	0.713	0.757	0.492
ScSr2 ^[14]	RMSE	6.747	14.488	21.091	22.552
	PSNR	32.859	26.239	22.970	22.009
	SSIM	0.876	0.705	0.755	0.490
ODL2 ^[17]	RMSE	6.756	14.464	21.084	22.521
	PSNR	32.865	26.247	22.973	22.103
	SSIM	0.877	0.706	0.756	0.491
Ours2	RMSE	6.738	14.184	21.043	22.478
	PSNR	32.888	26.416	22.990	22.420
	SSIM	0.878	0.713	0.763	0.492
ScSr3 ^[14]	RMSE	6.761	14.258	21.147	22.528
	PSNR	32.874	26.380	22.949	22.401
	SSIM	0.876	0.710	0.754	0.490
ODL3 ^[17]	RMSE	6.739	14.217	21.128	22.513
	PSNR	32.886	26.396	22.956	22.407
	SSIM	0.877	0.711	0.755	0.491
Ours3	RMSE	6.681	14.195	20.963	22.371
	PSNR	32.962	26.409	23.025	22.462
	SSIM	0.880	0.713	0.763	0.495

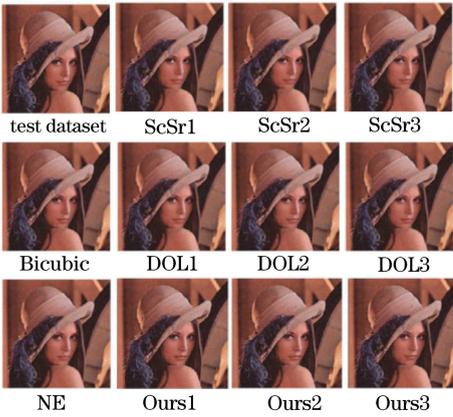


图 6 方差为 0.0005 时高斯噪声下的重建效果对比

图 7 密度为 0.001 时椒盐噪声下的重建效果对比图

Fig. 6 Comparison of reconstruction under Gaussian noise environment with variance of 0.0005

Fig. 7 Comparison of reconstruction under pepper & salt noise environment with density of 0.001

表 5 不同水平高斯噪声环境下重建数值对比

Table 5 Numerical comparison of reconstruction under different Gaussian noise environment

Variance	Evaluation index	Bicubic	NE	ScSr1	ODL1	Ours1	ScSr2	ODL2	Ours2	ScSr3	ODL3	Ours3
0	RMSE	5.455	12.108	4.604	4.593	4.561	4.660	4.652	4.574	4.775	4.768	4.571
	PSNR	34.713	28.669	36.231	36.239	36.299	36.119	36.127	36.276	35.907	35.912	36.280
	SSIM	0.911	0.788	0.925	0.926	0.927	0.924	0.925	0.926	0.923	0.924	0.926
0.0002	RMSE	6.942	7.001	5.903	5.889	5.727	6.386	6.377	6.244	6.597	6.584	6.261
	PSNR	32.622	30.757	34.057	34.068	34.309	33.368	33.372	33.556	33.088	33.092	33.532
	SSIM	0.908	0.874	0.928	0.929	0.932	0.883	0.884	0.885	0.882	0.883	0.886
0.0005	RMSE	7.480	7.992	7.490	7.477	7.465	7.583	7.542	7.487	7.731	7.695	7.463
	PSNR	31.973	20.662	31.971	31.986	31.996	31.906	31.911	31.973	31.724	31.736	32.001
	SSIM	0.869	0.831	0.820	0.821	0.824	0.821	0.822	0.823	0.821	0.822	0.824

表 6 不同水平椒盐噪声环境下的重建数值对比

Table 6 Numerical comparison of reconstruction under different pepper & salt noise environment

Density	Evaluation index	Bicubic	NE	ScSr1	ODL1	Ours1	ScSr2	ODL2	Ours2	ScSr3	ODL3	Ours3
0	RMSE	5.455	12.108	4.697	4.593	4.561	4.673	4.652	4.574	4.787	4.768	4.571
	PSNR	34.713	28.669	36.231	36.239	36.299	36.114	36.127	36.276	35.906	35.912	36.280
	SSIM	0.911	0.788	0.925	0.926	0.927	0.924	0.925	0.926	0.923	0.924	0.926
0.0005	RMSE	6.969	7.145	5.902	5.888	5.821	5.895	5.889	5.727	6.501	6.486	6.084
	PSNR	32.588	32.077	34.057	34.066	34.165	34.059	34.068	34.309	33.219	33.228	33.783
	SSIM	0.906	0.873	0.927	0.928	0.929	0.928	0.929	0.932	0.922	0.923	0.929
0.001	RMSE	7.305	7.661	6.872	6.844	6.799	7.101	7.066	6.964	7.165	7.159	6.862
	PSNR	32.181	31.877	32.757	32.761	32.817	32.473	32.480	32.607	32.359	32.365	32.737
	SSIM	0.900	0.843	0.916	0.917	0.918	0.912	0.913	0.915	0.912	0.913	0.918

参 考 文 献

[1] Qiu K, Yi B S, Xiang M, et al. Collaborative sparse dictionary learning for reconstruction of single image super resolution[J]. Acta Optica Sinica, 2018, 38(9): 0910002.
邱康, 易本顺, 向勉, 等. 协作稀疏字典学习实现单幅图像超分辨率重建[J]. 光学学报, 2018, 38(9):

0910002.

[2] Cheng D Q, Chen L L, Cai Y C, et al. Image super-resolution reconstruction based on multi-dictionary and edge fusion[J]. Journal of China Coal Society, 2018, 43(7): 2084-2090.
程德强, 陈亮亮, 蔡迎春, 等. 边缘融合的多字典超分辨率图像重建算法[J]. 煤炭学报, 2018, 43(7): 2084-2090.

- [3] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [4] Kou Q Q, Cheng D Q, Zhuang H D, et al. Cross-complementary local binary pattern for robust texture classification [J]. *IEEE Signal Processing Letters*, 2019, 26(1): 129-133.
- [5] Xu M E, Xie B L, Xu G M, et al. Hyperspectral image super-resolution method based on spatial spectral joint sparse representation [J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071014.
许蒙恩, 谢宝陵, 徐国明. 空间光谱联合稀疏表示的高光谱图像超分辨率方法 [J]. *激光与光电子学进展*, 2018, 55(7): 071014.
- [6] Li X, Orchard M T. New edge-directed interpolation [J]. *IEEE Transactions on Image Processing*, 2001, 10(10): 1521-1527.
- [7] Borman S, Stevenson R L. Super-resolution from image sequences-a review [C] // 1998 Midwest Symposium on Circuits and Systems (Cat. No. 98CB36268), August 9-12, 1998, Notre Dame, IN, USA. New York: IEEE, 1998: 6233062.
- [8] Chu J H, Hu F S, Zhang J Q, et al. An improved single-frame super-resolution algorithm for magnetic resonance image [J]. *Laser & Optoelectronics Progress*, 2018, 55(5): 051009.
褚晶辉, 胡风硕, 张佳祺, 等. 一种改进的单帧磁共振图像超分辨率算法 [J]. *激光与光电子学进展*, 2018, 55(5): 051009.
- [9] Freeman W T, Jones T R, Pasztor E C. Example-based super-resolution [J]. *IEEE Computer Graphics and Applications*, 2002, 22(2): 56-65.
- [10] Chang H, Yeung D Y, Xiong Y M. Super-resolution through neighbor embedding [C] // Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 27-July 2, 2004, Washington, DC, USA. New York: IEEE, 2004: 8152809.
- [11] Zeyde R, Elad M, Protter M. On single image scale-up using sparse-representations [M] // Boissonnat J D, Chenin P, Cohen A, et al. *Curves and surfaces 2010. Lecture notes in computer science*. Berlin, Heidelberg: Springer, 2012, 6920: 711-730.
- [12] Yang C Y, Ma C, Yang M H. Single-image super-resolution: a benchmark [M] // Fleet D, Pajdla T, Schiele B, et al. *Computer vision-ECCV 2014. Lecture notes in computer science*. Cham: Springer, 2014, 8692: 372-386.
- [13] Tan Z, Xiangli B, Lü Q B, et al. A sequence images super-resolution enhancement approach based on frequency-domain [J]. *Acta Optica Sinica*, 2017, 37(7): 0710001.
谭政, 相里斌, 吕群波, 等. 一种基于频域的序列图像超分辨率增强方法 [J]. *光学学报*, 2017, 37(7): 0710001.
- [14] Yang J C, Wright J, Huang T, et al. Image super-resolution as sparse representation of raw image patches [C] // 2008 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2008, Anchorage, AK, USA. New York: IEEE, 2008: 10139952.
- [15] Yang J C, Lin Z, Cohen S. Fast image super-resolution based on in-place example regression [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE, 2013: 1059-1066.
- [16] He L, Qi H R, Zaretzki R. Beta process joint dictionary learning for coupled feature spaces with application to single image super-resolution [C] // 2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE, 2013: 345-352.
- [17] Mairal J, Bach F, Ponce J, et al. Online learning for matrix factorization and sparse coding [J]. *Journal of Machine Learning Research*, 2010, 11(1): 19-60.
- [18] Zheng X T, Yuan Y, Lu X Q. Singleimage super-resolution restoration algorithm from external example to internal self-similarity [J]. *Acta Optica Sinica*, 2017, 37(3): 0318006.
郑向涛, 袁媛, 卢孝强. 自外而内的单幅图像超分辨率复原算法 [J]. *光学学报*, 2017, 37(3): 0318006.
- [19] Chang H, Yeung D Y, Xiong Y M. Super-resolution through neighbor embedding [C] // Computer Vision and Pattern Recognition, 2004. Proceedings of the 2004 IEEE Computer Society Conference on IEEE, 2004.
- [20] Kang M G, Katsaggelos A K. General choice of the regularization functional in regularized imagerestoration [J]. *IEEE Transactions on Image Processing*, 1995, 4(5): 594-602.
- [21] Lee H, Battle A, Raina R, et al. Efficient sparse coding algorithms [C] // *Advances in Neural Information Processing Systems*, December 3-6, 2007, Vancouver, British Columbia, Canada. Canada: NIPS, 2007: 801-808.