

彩色图像去马赛克的非局部稀疏表示方法

黄丽丽^{1,2}, 肖 亮², 韦志辉²

(1. 广西科技大学理学院, 广西柳州 545006; 2. 南京理工大学计算机科学与工程学院, 江苏南京 210094)

摘 要: 目前, 大部分彩色去马赛克(Color DeMosaicking, CDM)算法仅利用了局部的空间和光谱相关性, 容易导致 CDM 复原图像边缘模糊以及细小结构丢失. 当图像中出现周期性细小结构时, 这些局部方法容易产生诸如锯齿、栅格等失真现象. 针对这些问题, 我们将字典学习和稀疏编码统一到一个变分框架中, 提出了非局部自适应稀疏表示模型. 通过非局部相似块聚类自适应地在线学习字典. 利用局部和非局部的冗余信息对稀疏编码进行约束, 强制稀疏编码靠近其非局部均值以减少编码误差. 为了有效抑制服从重尾分布的 CDM 误差, 设计了基于 l_1 范数的数据项. 最后, 联合交替最小化方法和算子分裂技巧对模型进行有效求解. 实验结果验证了本文模型与数值算法的有效性.

关键词: 彩色去马赛克; 正则化; 稀疏表示; 非局部相似性

中图分类号: TP399 **文献标识码:** A **文章编号:** 0372-2112 (2014)02-0272-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.02.010

A Nonlocal Sparse Representation Method for Color Demosaicking

HUANG Li-li¹, XIAO Liang², WEI Zhi-hui²

(1. School of Science, Guangxi University of Science and Technology, Liuzhou, Guangxi 545006, China;

2. School of Computer Science and Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China)

Abstract: Currently, most of the color demosaicking algorithms using only a local spatial and spectral correlation, easily lead restored picture to blur edges and loss of fine structures. When cyclical small structures exist in the image, these local methods are prone to the distortion of the zipper effect, the raster effect, etc. To solve these problems, unifying dictionary learning and sparse coding into a variational framework, a non-local adaptive sparse representation model is proposed through non-local similarity clustering and adaptive dictionary online learning. Using the local and non-local redundancy, sparse coding constraints forced sparse coding close to its non-local means to reduce coding errors. Moreover, the fidelity term is characterized by l_1 -norm to suppress the heavy-tailed visual artifacts. Finally, the joint alternating minimization method and operator splitting techniques are utilized to effectively solve the model. Experimental results demonstrate the effectiveness of the proposed model and the numerical algorithm.

Key words: color demosaicking; regularization; sparse representation; nonlocal similarity

1 引言

出于成本和系统体积的考虑, 大部分数字成像设备(如普及型数码相机/摄像机等)均采用单片传感器采集图像数据. 传感器表面覆盖着一层彩色滤波器阵列(Color Filter Array, CFA), 使采集到的图像阵列在每个像素点只能获得红(R)、绿(G)、蓝(B)三基色中的一种颜色分量强度值. 为了获得丢失的另外两种颜色分量, 需要根据 CFA 模式, 利用空域和光谱域相关性进行插值, 这个过程被称为 CFA 插值. 由于 CFA 的马赛克模式, 通过 CFA 插值获得全彩色图像的过程又被称为彩色去马

赛克(CDM).

颜色复原质量取决于图像内容以及所采用的 CDM 算法. CDM 算法大致可分为两类: 非迭代方法以及迭代方法. 较早的非迭代方法基于简单的双线性插值和三次 B 样条插值. 这类方法易于实现, 执行速度快, 但容易在边界或纹理等高频区域产生明显的锯齿效应以及模糊等失真. 针对这些问题, 一种解决办法是基于色调平滑过渡准则, 根据色比(R/G, B/G)或色差(R-G, B-G)恒定假设进行插值, 但得到的全彩色图像在绿色分量值突变的地方有较大的插值误差^[1]. 另一种解决办法是自适应方向插值. 这类方法通过设计不同的边缘方向检测准

则,沿着图像边缘而不是穿过边缘进行插值.最著名的方向插值算法是由 Hamilton 和 Adams 提出的二阶拉普拉斯校正法(Second Order Laplacian Correction, SOLC)^[2].该方法利用色度信号的二阶导数对亮度信号的插值结果进行校正.基于该思想,Wu 等人提出了基于三基色一致性软判决(Primary-Consistent Soft-Decision, PCSD)准则的 CDM 算法^[3].迭代方法中代表性的工作有:Gunturk 等人利用各通道的高频信息具有强相关性,提出了交替投影(Alternating Projections, AP)的 CDM 方法^[4];Li 提出了连续逼近(Successive Approximation, SA)的 CDM 方法.该方法通过对色差信号进行反复迭代逼近,从而实现三通道的不断更新^[5].

最近,对初始插值估计进行滤波的 CDM 算法取得了很好的重建效果^[6~8].文献[6]指出各颜色通道的初始插值是真实颜色分量强度值和插值误差的叠加.针对插值误差,Zhang 等人首次引入“去马赛克噪声”的概念,并提出了基于方向线性最小均方误差估计(Directional Linear Minimum Mean Square-Error Estimation, DLMMSE)的 CDM 算法^[6].Buades 等人基于非局部均值滤波提出了自相似驱动(Self-Similarity Driven, SSD)的 CDM 算法^[7].Zhang 等人提出了联合局部方向插值以及非局部自适应阈值(Local Directional Interpolation & Non-local Adaptive Thresholding, LDI-NAT)的 CDM 算法^[8].

上述基于滤波的 CDM 方法虽然在一定程度上改善了 CDM 重建效果,但仍存在问题.DLMMSE 由于仅利用了局部的空间和光谱相关性,容易导致 CDM 复原图像边缘模糊以及细小结构的丢失,并且当图像中出现周期性细小结构时,容易产生锯齿、栅格以及虚假色等失真现象.为了避免出现这些问题,SSD 和 LDI-NAT 算法利用非局部冗余信息来增强 CDM 复原效果.SSD 算法利用相似像素的加权平均来更新像素的初始插值.虽然有效抑制了 CDM 噪声,但平均操作仍会引起边缘模糊,并很难去除随着高饱和度边缘的复原而出现的颜色失真.LDI-NAT 算法用高斯分布函数对 CDM 噪声进行建模,从而利用主成分分析法(Principal Component Analysis, PCA)来抑制非局部相似块的 CDM 噪声,但 PCA 对存在异常值(outlier)的插值误差并不鲁棒,因此在边缘处仍存在许多颜色失真现象.

针对上述 CDM 算法所出现的问题,本文通过挖掘 CDM 噪声和图像的稀疏性先验知识,基于非局部鲁棒自适应稀疏表示(NonLocal based Robust Adaptive Sparse Representation, NL-RASR)模型,设计了一个新的抑制 CDM 噪声的滤波方法.本文贡献主要有以下三点:(1)通过实验我们发现 CDM 图像中的失真(如振铃和锯齿效应等)属于小尺度结构,因此 CDM 噪声具有一定的稀疏性.从概率统计的角度来看,CDM 噪声应服从尖峰重

尾的非高斯分布.实验验证了拉普拉斯函数比高斯函数更适合用来对 CDM 噪声进行建模.在极大似然统计推断下,利用 l_1 最小化可鲁棒地去除含有异常值的 CDM 噪声;(2)考虑到图像中存在许多不同的局部结构特征,为了对它们进行有效表示,我们将字典学习和稀疏编码统一到一个变分框架中.受到文献[9]的启发,我们将非局部相似图像块进行聚类,以此作为训练样本自适应地在线学习一组子字典.对于待处理的图像块,选择一个与之最相关的子字典对其进行表示.进一步地,联合局部和非局部的冗余信息对稀疏编码进行约束,强制稀疏编码靠近其非局部均值以减少编码误差;(3)针对所提出的非光滑且非凸的变分模型,利用优化中的变量分裂和二次惩罚技巧,结合交替最小化方法和算子分裂技巧进行有效求解.

2 提出的非局部稀疏表示模型

考虑经过 CFA 采样后得到的颜色分量信号 $z\{c\} = \mathbf{M}\{c\}x\{c\}$, $c \in \{R, G, B\}$, 其中 x 表示理想的全彩色图像, $\mathbf{M}\{c\}$ 表示 c 通道的采样矩阵, $(z\{R\}, z\{G\}, z\{B\})$ 构成了马赛克图像 z . 利用某种局部插值方法(例如 LDI 方法^[8])对马赛克图像 z 进行初值插值得到全彩色复原图像 y . 由于图像边缘存在颜色或亮度的锐变, y 中的边缘处往往会出现锯齿、栅格以及虚假色等失真现象. 受到文献[6~8]的启发,将 CDM 问题转换为去噪问题进行求解,即 $y = x + v$, 其中 v 表示 CDM 误差. 目标是从退化的观测图像 y 中恢复出理想图像 x . 由于用于问题求解的信息量不足,该问题属于数学中的不适定(ill-posed)反问题,因此我们在贝叶斯统计框架下利用噪声及理想图像的先验知识来改善问题性质.

近年来,稀疏表示作为一个强大的统计建模工具,在图像处理领域已经得到了成功的应用^[10,11].有关专家在对人类视觉系统的研究中发现,视觉皮层的接收场特性(空间局部性、朝向性和带通性)使得视觉系统只用很少的视觉神经元就能捕获到自然场景中的关键信息.利用这种生物视觉特性,发展出了图像(或信号)稀疏表示理论.在稀疏表示模型中,将信号 $x \in \mathbb{R}^N$ 表示为一组原子 $\{d_j \in \mathbb{R}^N, j = 1, 2, \dots, L\}$ 的线性组合.将 L 个原子作为列向量形成字典 $D \in \mathbb{R}^{N \times L}$, 从而图像 x 可表示为: $x = D\alpha$, 其中 $\alpha \in \mathbb{R}^L$ 表示信号 x 在字典 D 下的分解系数.稀疏表示理论研究表明,自然图像在合适的字典下总存在稀疏的表示,即系数向量 α 中非零元素的个数很少.

根据贝叶斯-最大后验(Bayesian-MAP)统计推断,可建立下列关于字典 D 和稀疏表示系数 α 的去噪变分模型:

$$\max_{\alpha, D} \{\log P(\alpha, D | y)\}$$

$$= \max_{\alpha, D} \{ -\log P(y|\alpha, D) - \log P(\alpha) \} \quad (1)$$

其中等式右端的第一项为似然函数(数据项),第二项为系数 α 的先验分布(正则项).下面通过CDM噪声和图像的稀疏性先验信息挖掘,分别给出式(1)中的似然函数和先验分布.

2.1 数据模型

目前,大部分文献均假设噪声近似服从高斯分布,从而在极大似然意义下利用 l_2 范数来约束数据项.然而,实际情况出现的噪声多为脉冲噪声(包括椒盐噪声和拉普拉斯噪声),它们服从尖峰重尾的非高斯分布^[12].为了得到更完善的CDM重建效果,需要针对CDM问题建立更为精确的数据模型.这里,我们通过大量实验来研究CDM误差的统计特性.以McMaster数据库中的Image 6和Image 13为例(如图1所示),图1分别绘制了G通道CDM误差 v 的经验分布曲线、高斯函数以及拉普拉斯函数的拟合曲线.由图1可看出, v 的经验分布曲线在0处出现尖峰并且有拖尾现象.重拖尾的出现主要是由于CDM图像中的失真(如振铃和锯齿效应等)属于小尺度结构.与高斯分布相比较,拉普拉斯函数更适合用来对 v 进行建模.根据拉普拉斯分布的定义,观测图像 y 的似然函数为:

$$P(y|D, \alpha) = \frac{1}{\sqrt{2}\sigma_v} \exp\left\{-\frac{\sqrt{2}\|y - D\alpha\|_1}{\sigma_v}\right\} \quad (2)$$

其中 σ_v 表示噪声 v 的标准差.




图1 McMaster数据库中Image 6(a)和Image 13(b)的G通道CDM误差的经验分布

2.2 聚类稀疏表示模型

我们将自然图像分成若干小块,这些块往往具有结构性冗余.对局部图像块在某个字典上的编码施加稀疏性约束,要求系数 α 在零点聚集出现,因此 α 通常

应服从非高斯的重尾分布,例如拉普拉斯分布、广义高斯分布等.这相当于利用字典中的原子对这些图像块进行去相关,从而保留信号的主要特征.除了局部冗余性信息,图像的另一重要先验是非局部冗余性信息,即自然图像中往往包含许多重复性相似的结构模式.我们将图像块根据特征进行分类.对于每一个给定的图像块,要求它在给定字典下的稀疏编码尽可能的接近其所属类的非局部均值,以减小编码误差^[13].

记 $x_i = R_i x$, $y_i = R_i y$ 分别表示由 $\sqrt{n} \times \sqrt{n}$ 大小的图像块堆叠成的 n 维向量, $R_i \in \mathbb{R}^{n \times N}$ 表示从图像中提取图像块的二值矩阵(i 表示位于图像块左上角的像素).考虑到图像块之间相互重叠,遍历 i ,从观测图像 y 中共提取了 $(\sqrt{N} - \sqrt{n} + 1)^2$ 个图像块.通过 K -均值聚类,我们将提取的图像块分成 K 类 $\{C_1, C_2, \dots, C_K\}$, $\{y_i\}_{i=1}^m$ 表示属于 C_k ($k=1, 2, \dots, K$)的非局部相似块. $D_k \in \mathbb{R}^{n \times r}$ 表示由样本 $\{y_i\}_{i=1}^m$ 训练得到的子字典, α_i 表示 y_i 在字典 D_k 下的分解系数.综上所述,采用下列先验分布:

$$P(\alpha_i) = \frac{1}{\sqrt{2}\sigma_{\alpha_i}} \exp\left\{-\frac{\sqrt{2}\|\alpha_i - \mu_i\|_1}{\sigma_{\alpha_i}}\right\} \quad (3)$$

其中非局部均值 μ_i 定义为^[13]:

$$\mu_i = \sum_j w_j^i \alpha_j^i \quad (4)$$

这里 α_j^i 表示图像块 x_j^i 的稀疏编码, x_j^i 表示与 x_i 相似的非局部图像块. x_j^i 在一个以 x_i 为中心的 $L \times L$ 大小的窗口内进行搜索,可按照下列标准匹配图像块: $\text{dist}(x_i, x_j^i) = \|x_i - x_j^i\|_2 \leq T$,其中 T 为事先设置好的阈值.事实上,我们根据欧式距离选择与 x_i 最近的 L 个图像块作为与之相似的非局部块;权重 $w_j^i = \frac{\exp\{-\|x_i - x_j^i\|_2^2/h\}}{W_i}$,其中 h 为事先设置好的尺度因子, W_i 为归一化常数.

将式(2)和(3)代入式(1)就得到下列基于NL-RASR的CDM模型:

$$\min_{d_i, \{\alpha_i\}} \sum_{i=1}^m \left\{ \|y_i - D_k \alpha_i\|_1 + \frac{\sigma_v}{\sigma_{\alpha_i}} \cdot \|\alpha_i - \mu_i\|_1 \right\}, \quad \text{s.t. } \|d_i\|_2 = 1 \quad (5)$$

一旦由模型(5)求解出 D_k 和 α_i ,便可得到图像块 x_i 的估计: $\hat{x}_i = D_k \alpha_i$.由于 \hat{x} 在迭代过程中不断更新,因此噪声水平 σ_v 在迭代过程中也会发生变化.这里,采用文献[14]中的策略自适应地估计噪声水平 σ_v ,即 $\sigma_v = c(\sigma^2 - E(y - \hat{x})^2)^{1/2}$,其中 $0 < c < 1$ 为常数, σ 表示污染 y 的噪声水平,可利用文献[15]提出的方法对它进行估计.

3 模型的求解算法

交替最小化方法是求解联合优化问题的常用方

法.然而,不可微的目标函数使得优化问题(5)的数值求解变得困难.我们利用优化中经典的变量分裂和二次惩罚技巧,并结合交替最小化方法以及凸分析中的算子分裂法,将原始的复杂问题转化为若干个具有闭形式解的简单问题进行求解.

首先,引入辅助变量 $u_i \in \mathbb{R}^n$,用它来近似式(5)中不可微数据项中的变量 $y_i - \mathbf{D}_k \alpha_i$.其次,通过增加一个二次函数对这两个变量之间的差异进行惩罚,从而得到问题(5)的一个逼近式:

$$\min_{\{u_i\}, \{\alpha_i\}} \sum_{i=1}^m \left\{ \left\| u_i \right\|_1 + \frac{\eta}{2} \left\| u_i - (y_i - \mathbf{D}_k \alpha_i) \right\|_2^2 + \lambda_i \left\| \alpha_i - \mu_i \right\|_1 \right\}, \quad \text{s.t. } \left\| d_i \right\|_2 = 1 \quad (6)$$

其中 $\eta \gg 0$ 为惩罚参数;为了数值计算的稳定性,正则化参数 λ_i 按照下列式子计算:

$$\lambda_i = \sigma_v / (\sigma_{\alpha_i} + \epsilon) \quad (7)$$

其中 $\epsilon > 0$ 表示一个小常数.优化问题(6)的求解可分为稀疏编码和字典学习两个阶段.

3.1 稀疏编码阶段

字典 \mathbf{D}_k 给定时,首先固定 u_i ,关于变量 α_i 求解下列最小化优化问题:

$$\min_{\{\alpha_i\}} \sum_{i=1}^m \left\{ \frac{\eta}{2} \left\| u_i - (y_i - \mathbf{D}_k \alpha_i) \right\|_2^2 + \lambda_i \left\| \alpha_i - \mu_i \right\|_1 \right\} \quad (8)$$

我们采用凸分析中经典的向前-向后算子分裂法(Forward-Backward Splitting, FBS)将变量 α_i 和约束矩阵 \mathbf{D}_k 进行解耦.具体地,由任意的起始点 $\alpha_i^{(0)}$ 出发,我们有下面的 FBS 迭代格式^[16]:

$$\alpha_i^{(k+1/2)} = \alpha_i^{(k)} - \gamma \eta \mathbf{D}_k^T (\mathbf{D}_k \alpha_i^{(k)} - (y_i - u_i)) \quad (9)$$

$$\alpha_i^{(k+1)} = \arg \min_{\{\alpha_i\}} \sum_{i=1}^m \left\{ \frac{1}{2\gamma} \left\| \alpha_i - \alpha_i^{(k+1/2)} \right\|_2^2 + \lambda_i \left\| \alpha_i - \mu_i \right\|_1 \right\} \quad (10)$$

其中式(10)具有闭形式的最小解:

$$\alpha_i^{(k+1)} = \text{Shrink}(\alpha_i^{(k+1/2)} - \mu_i, \gamma \lambda_i) + \mu_i \quad (11)$$

上标(k)表示迭代次数, γ 表 FBS 迭代格式的步长,收缩算子定义为:

$$\text{Shrink}(a, b) = a / |a| \cdot \max(|a| - b, 0)$$

当 $0 < \gamma < 2 / \left\| \mathbf{D}_k^T \mathbf{D}_k \right\|_2$ 时,序列 $\{\alpha_i^{(k)}\}$ 收敛于原始问题的最小解^[16].

其次,当 α_i 固定,关于变量 u_i 求解下列最小化优化问题:

$$\min_{\{u_i\}} \sum_{i=1}^m \left\{ \left\| u_i \right\|_1 + \frac{\eta}{2} \left\| u_i - (y_i - \mathbf{D}_k \alpha_i) \right\|_2^2 \right\} \quad (12)$$

该问题的最小解可由下列逐块的阈值收缩公式得到:

$$u_i = \text{Shrink}\left(y_i - \mathbf{D}_k \alpha_i, \frac{1}{\eta}\right) \quad (13)$$

3.2 字典学习阶段

本节旨在学习一组子字典,从而对不同的局部图

像结构进行编码.为此,建立一个由局部图像块构成的训练样本库.由于人类视觉感知系统对边缘较为敏感,边缘传达了图像大部分的语义信息,因此训练样本的选择标准是要求这些图像块具有一定的边缘结构.考虑从观测图像 y 中提取的图像块 y_i ,若其方差 $\text{var}(y_i)$ 大于某个给定的阈值 ζ ,则将 y_i 放入训练样本库.

设 $\mathbf{Y} = [y_1, y_2, \dots, y_M]$ 表示建立好的训练样本库,我们的目标是由 \mathbf{Y} 训练出一组子字典 $\{\mathbf{D}_k\}_{k=1}^K$.为此,需要将数据集 \mathbf{Y} 分成 K 个类,使得每类样本能够表示 \mathbf{Y} 中的特定结构,进而由每个类学习出一个子字典.为了生成感知上有意义的类,我们在 \mathbf{Y} 的特征空间中进行聚类.在低层统计学习中,通常利用高通滤波来增强特征^[17].因此,我们将 \mathbf{Y} 经过高通滤波后的 $\mathbf{Y}^h = [y_1^h, y_2^h, \dots, y_M^h]$ 作为特征空间,并采用 K-均值算法将 \mathbf{Y}^h 分成 K 类.一旦 \mathbf{Y}^h 聚类完成后,相应地样本库 \mathbf{Y} 也被分成了 K 类 $\{C_1, C_2, \dots, C_K\}$,每个类 $C_k = [y_1, y_2, \dots, y_{m_k}]$ 是一个维数为 $n \times m_k$ 的矩阵,其中 m_k 表示 C_k 中的样本数.

下面由每一个聚类 C_k 学习出子字典 \mathbf{D}_k ,使得 \mathbf{D}_k 可以准确地表示 C_k 中的每个样本.为了叙述上的方便,我们将下标 k 省略.固定 u_i 和 α_i ,字典 \mathbf{D} 的学习可归结为下列最小化优化问题的求解:

$$\min_{\mathbf{D} \in \mathbb{R}^{n \times r}} \sum_{i=1}^m \left\{ \left\| u_i - (y_i - \mathbf{D} \alpha_i) \right\|_2^2 \right\}, \quad \text{s.t. } \left\| d_i \right\|_2 = 1 \quad (14)$$

字典 \mathbf{D} 可利用基于块的坐标下降法(block coordinate descent algorithm)进行更新^[18],即每次迭代只更新 \mathbf{D} 中的一个原子 d_j ,而其他原子保持不变.由于 $\{y_i\}_{i=1}^m$ 是聚类后的相似块,因此由这些样本训练出字典的各原子之间存在很大的相关性.为了有效抑制噪声,同时减少计算量,这里我们取 $r < n$,即字典是非冗余的.记 $\mathbf{C} = (y_i) \in \mathbb{R}^{n \times m}$, $\mathbf{U} = (u_i) \in \mathbb{R}^{n \times m}$, $\mathbf{V} = \mathbf{C} - \mathbf{U} - \sum_{l \neq j} d_l \alpha_l^T$,利用 Lagrange 乘子法,将约束优化问题(14)转化为与之等价的无约束优化问题,并根据一阶优化条件以及约束条件 $d_j^T d_j = 1$,得到

$$d_j = \frac{\mathbf{V} \alpha_j}{\left\| \mathbf{V} \alpha_j \right\|_2}, j = 1, 2, \dots, r \quad (15)$$

3.3 算法描述

算法对子问题(8)、(12)以及(14)交替迭代求解,从而得到增强的图像块 $\hat{x}_i = \mathbf{D} \hat{\alpha}_i, i = 1, 2, \dots, (\sqrt{N} - \sqrt{n} + 1)^2$,将它们进行整合即可得到一幅全彩色图像 \hat{x} ,即^[19]

$$\hat{x} = \left(\sum_i R_i^T R_i \right)^{-1} \left(\sum_i R_i^T \hat{x}_i \right) \quad (16)$$

最后将 $z \{c\}, c \in \{R, G, B\}$ 中非零的颜色强度值按照对应位置赋给 $\hat{x} \{c\}, c \in \{R, G, B\}$,即可得到理想全彩色

图像的一个估计.

总结上述算法内容,可得到 NL-RASR 模型(5)求解算法的实现流程:

算法 NL-RASR

输入: $n, \zeta, K, r, h, c, \eta, \gamma, k_{\max}, m_{\max}, \delta$

初始化: $x^{(0)} = y, u^{(0)} = 0, k = 0, m = 0$, 根据 K-均值聚类 and PCA 技巧

初始化字典 $D^{(0)}$, 根据式(4)初始化 $\mu_i^{(0)}$, 根据式(7)初始化 $\lambda_i^{(0)}$

Do

(1) 保存迭代值: $x^* = x^{(m)}$;

Do

(i) 根据式(9)计算得到 $\alpha_i^{(k+1)/2}$;

(ii) 根据式(11)计算得到 $\alpha_i^{(k+1)}$;

(iii) $k = k + 1$;

While $k < k_{\max}$

(2) 根据式(13)计算 $u_i^{(m+1)}$;

(3) 根据式(15)更新字典 $D^{(m+1)}$;

(4) 根据式(4)更新 $\mu_i^{(m+1)}$, 根据式(7)更新 $\lambda_i^{(m+1)}$;

(5) 根据式(16)得到 $x^{(m+1)}$;

(6) $m = m + 1$;

While $\frac{\|x^{(m+1)} - x^*\|_2}{\|x^{(m+1)}\|_2} > \delta$ 或 $m < m_{\max}$

输出: x^* .

4 实验结果与分析

本节通过仿真实验来验证本文模型和算法的有效性. 实验用的测试图像是 McMaster 数据库 (<http://r0k.us/graphics/kodak>) 中的 18 幅 500×500 大小的彩色图像, 如图 2 所示. 在仿真实验中, 这些图像首先根据 Bayer 模式的 CFA 进行采样, 然后通过 CDM 算法进行颜色复原. 将本文算法与近几年具有代表性的一些 CDM 算法进行比较, 包括 SOLC^[2]、PCSD^[3]、AP^[4]、SA^[5]、DLMMSE^[6]、SSD^[7] 以及 LDI-NAT^[8]. 这些算法的 Matlab 代码均可在作者主页上进行下载, 算法所涉及到的参数均按照文献进行默认设置.

本文的 CDM 算法实现基于如下考虑: 由于人眼对绿色更为敏感, 同时绿色占据了可见光谱中最重要和最宽的位置, 因此大部分的 CFA 模板 (如 Bay 模式) 对 G 通道的采样频率要高于 R、B 两通道的采样频率. 这样, G 通道比另外两个颜色通道保留了更多的图像结构信息. 通常, G 通道的重建效果将影响 R、B 两通道的重建效果^[6-8]. 因此, 本文的 CDM 方法按照以下几个步骤进行: (1) 采用 LDI 方法^[8] 对 G 通道进行初始插值; (2) 利用 NL-RASR 方法增强插值后的 G 通道; (3) 基于颜色复原后的 G 通道, 采用 LDI 方法对 R/B 通道进行初始插值; (4) 利用 NL-RASR 方法增强 R/B 通道.

本文算法所涉及到的参数设置如下: 图像块大小为 6

$\times 6$, 即 $n = 36$; 图像块的方差阈值 $\zeta = 116$; 训练样本聚类后的类别数 $K = 70$; 子字典中的原子数 $r = 22$; 高斯核中的尺度因子 $h = 75$; 噪声增益因子 $c = 0.05$; 惩罚参数 $\eta = 60$; FBS 中的迭代步长 $\gamma = 5 \times 10^{-4}$, 最大迭代次数 $k_{\max} = 1$; 外循环最大迭代次数 $m_{\max} = 3$; 迭代终止条件中的阈值 $\delta = 10^{-3}$.



图2 McMaster数据库中的图像, 由上到下, 由左到右分别记为 Image 1-Image 18

我们从定量指标和视觉效果两个方面对 CDM 算法的重建效果进行比较. 采用的定量指标为峰值信噪比 (Peak Signal to Noise Ratio, PSNR) 和锯齿效应比 (Zipper Effect Ratio, ZER). 当色度信号出现不同于亮度信号的高频成分时, 会产生锯齿效应^[7]. 因此, 锯齿效应往往集中在分离彩色区域的边缘处. ZER 表示彩色图像中出现锯齿效应像素点的百分比, 是衡量 CDM 算法边缘保持能力的一项重要指标.

由于受篇幅的限制, 这里只给出了 Image 5、Image

9、Image 13 以及 Image 17 的 CDM 复原结果图. 为了便于从视觉上比较各 CDM 算法的复原效果, 图 3 ~ 图 6 分别给出了这 4 幅图像的局部放大图. 由这些图可看出, SOLC、PCSD、AP、SA 以及 DLMMSE 的复原图像在边缘处出现了明显的锯齿现象. 由于都利用了非局部相似性信息, SSD、LDI-NAT 以及本文算法的复原图像在视觉效果上要优于上述的五种方法, 不过 SSD 和 LDI-NAT 的复原图像在物体边缘处仍出现可察觉的振荡和锯齿现象. 由于本文方法通过自适应的字典学习, 很好地利用了图像的局部和非局部相似性信息, 故在有效抑制锯齿效应的同时, 仍保持图像的边缘和细节信息.




图3 Image 5 的重建结果局部放大图




图4 Image 9 的重建结果局部放大图




图5 Image 13 的重建结果局部放大图




图6 Image 17 的重建结果局部放大图

表 1 和表 2 分别给出了各 CDM 算法对 18 幅测试图像进行重建得到的 PSNR 和 ZER 值. 由表 1 可看出, 本文算法的大部分 PSNR 值比其它方法的 PSNR 值要高. 本文算法的平均 PSNR 值比 LDI-NAT 的高 0.27dB. 这两种算法的 PSNR 值非常接近, 是由于 LDI-NAT 同样使用 LDI 方法进行初始插值, 然后利用非局部冗余信息对局部插值结果进行增强. 不同的是, 该方法利用 PCA 方法, 由非局部相似图像块训练出字典, 然后利用软阈值公式对初始插值图像进行增强. 根据 2.1 节的讨论, 该方法对服从重尾分布的 CDM 噪声并不鲁棒. 因此, 由表 2 可看到, 本文算法的 ZER 值要比 LDI-NAT 的 ZER

值要小很多.同时,跟另外 6 种方法的 ZER 值相比,本文算法的 ZER 值也最小.

表 1 CDM 算法的 PSNR(dB)比较

算法	[2]	[3]	[4]	[5]	[6]	[7]	[8]	本文算法	
Image 1	R	27.69	25.30	27.55	23.53	26.94	27.48	29.29	29.54
	G	31.27	27.16	31.24	25.17	30.63	30.83	32.68	32.83
	B	25.47	23.65	25.43	22.05	24.82	25.39	26.71	27.14
Image 2	R	33.72	31.82	33.76	31.63	33.30	33.85	35.02	35.00
	G	37.77	34.92	37.83	34.00	37.66	37.96	39.06	39.30
	B	32.06	30.82	32.22	30.74	31.86	32.24	32.92	33.16
Image 3	R	31.92	31.50	32.61	31.47	32.60	32.89	33.05	33.35
	G	33.74	33.25	34.57	32.75	35.28	35.05	35.51	35.51
	B	30.03	30.17	30.54	29.80	30.70	30.96	30.31	30.47
Image 4	R	35.08	33.98	35.20	34.59	34.70	36.56	36.25	37.90
	G	37.17	34.54	36.73	34.05	36.99	39.07	40.33	40.24
	B	32.67	31.79	32.53	32.19	32.07	33.80	33.30	34.25
Image 5	R	31.76	28.96	31.30	28.60	30.38	31.61	35.05	35.76
	G	36.25	31.73	35.75	30.97	35.11	35.69	38.14	38.24
	B	30.36	28.19	30.11	28.08	29.41	30.05	31.16	31.57
Image 6	R	36.43	32.40	35.95	32.23	34.98	36.89	39.40	39.70
	G	40.38	33.81	39.64	32.50	38.61	39.47	43.42	43.02
	B	32.59	29.65	32.22	29.14	31.15	32.72	34.97	35.68
Image 7	R	35.32	37.19	37.01	37.03	38.30	36.24	36.09	34.79
	G	36.47	40.02	38.65	40.39	40.70	37.57	37.41	36.60
	B	34.25	36.67	35.76	36.22	37.29	35.65	34.49	33.15
Image 8	R	35.89	34.44	36.75	35.31	35.45	35.93	36.31	36.80
	G	39.19	39.33	40.55	38.49	41.43	40.47	40.29	40.34
	B	36.27	36.19	37.00	35.82	36.99	36.89	36.67	36.80
Image 9	R	33.75	31.35	33.63	30.37	32.39	34.45	35.49	36.26
	G	39.72	35.51	38.93	33.83	38.73	39.91	41.73	42.23
	B	35.45	33.48	35.16	32.54	34.66	35.92	36.30	37.26
Image 10	R	35.67	33.39	35.60	34.03	34.70	36.82	38.26	38.09
	G	40.83	36.44	40.46	36.15	40.00	40.63	42.64	42.50
	B	36.11	34.39	36.07	34.78	35.55	36.50	36.83	36.78
Image 11	R	37.62	35.39	37.56	36.16	36.91	38.46	39.82	39.33
	G	40.81	37.12	40.80	37.11	40.44	40.50	42.57	41.71
	B	36.28	34.94	36.23	34.33	35.75	37.27	37.66	38.18
Image 12	R	35.37	33.84	35.45	34.49	34.74	35.85	38.36	38.67
	G	40.38	37.29	39.96	37.66	39.59	40.23	41.49	41.73
	B	36.93	35.58	36.79	36.24	36.47	37.45	37.59	38.05
Image 13	R	39.76	36.88	39.12	38.11	38.66	40.50	41.77	42.58
	G	43.63	39.38	42.88	39.90	42.57	44.25	44.89	45.93
	B	37.45	35.69	37.16	36.51	36.75	37.68	38.13	38.64
Image 14	R	38.32	36.32	37.99	36.82	37.74	38.88	39.39	39.46
	G	41.45	38.86	41.20	38.79	41.13	42.14	42.84	42.89
	B	35.33	34.01	35.26	34.45	34.78	35.44	36.12	36.49
Image 15	R	35.93	34.52	35.81	34.87	35.32	36.50	36.95	37.60
	G	41.24	38.29	40.91	38.13	40.71	41.17	42.68	42.80
	B	37.90	36.29	37.71	36.52	37.30	38.32	38.99	39.23
Image 16	R	32.66	29.74	32.80	28.75	31.95	32.58	34.96	35.41
	G	34.25	30.14	34.11	28.60	33.22	33.23	35.59	35.45
	B	28.96	27.04	29.07	24.87	28.06	28.87	31.53	33.52

续表 1

算法	[2]	[3]	[4]	[5]	[6]	[7]	[8]	本文算法	
Image 17	R	29.83	26.97	29.63	25.35	28.32	29.90	32.14	32.76
	G	35.32	29.32	34.29	26.68	33.31	34.08	37.62	38.43
	B	29.08	26.74	28.90	25.06	27.77	29.06	30.91	32.07
Image 18	R	33.50	31.91	33.72	31.61	33.32	33.44	34.58	34.52
	G	36.27	34.44	36.89	33.84	37.02	36.04	37.27	36.98
	B	33.29	31.55	33.43	31.11	32.93	33.73	34.30	36.12
Average	R	34.46	32.55	34.52	32.68	34.06	34.94	36.23	36.47
	G	38.12	35.09	38.08	34.63	38.10	38.24	39.79	39.82
	B	33.36	32.05	33.42	31.87	33.15	33.77	34.38	34.92

表 2 CDM 算法的 ZER 比较

算法	[2]	[3]	[4]	[5]	[6]	[7]	[8]	本文算法
Image 1	0.1893	0.4243	0.1368	0.4348	0.2021	0.1063	0.1082	0.0968
Image 2	0.1082	0.1750	0.1092	0.1673	0.1249	0.0667	0.0682	0.0520
Image 3	0.1716	0.4467	0.2284	0.4357	0.2179	0.1015	0.1044	0.0934
Image 4	0.3633	0.9296	0.4724	0.7680	0.5287	0.0839	0.1468	0.1297
Image 5	0.0992	0.1726	0.1092	0.1831	0.1144	0.0572	0.0591	0.0462
Image 6	0.0958	0.1974	0.1225	0.2121	0.1306	0.0553	0.0477	0.0434
Image 7	0.1673	0.1630	0.1726	0.1459	0.1368	0.1244	0.1397	0.1387
Image 8	0.1235	0.2460	0.1797	0.1988	0.1344	0.0567	0.0686	0.0582
Image 9	0.1640	0.3547	0.2055	0.3585	0.2174	0.0834	0.0896	0.0496
Image 10	0.1211	0.2784	0.1511	0.2212	0.1526	0.0725	0.0577	0.0443
Image 11	0.1673	0.3895	0.2355	0.3280	0.2260	0.1035	0.0801	0.0505
Image 12	0.1158	0.2660	0.1788	0.2102	0.1588	0.0472	0.0572	0.0176
Image 13	0.1335	0.2746	0.1926	0.2098	0.1821	0.0510	0.0830	0.0277
Image 14	0.1158	0.2455	0.1711	0.2102	0.1649	0.0629	0.0682	0.0353
Image 15	0.1578	0.3370	0.2417	0.2975	0.2417	0.0891	0.1120	0.0558
Image 16	0.1812	0.3356	0.2093	0.3852	0.2350	0.1492	0.1096	0.0868
Image 17	0.2017	0.3633	0.2293	0.3933	0.2584	0.1378	0.1254	0.1049
Image 18	0.1173	0.5749	0.1473	0.4329	0.1759	0.0706	0.0791	0.0501

5 结论

本文通过挖掘 CDM 插值误差和图像的稀疏性先验知识,提出了 NL-RASR 的 CDM 方法.该方法将字典学习和稀疏编码统一到一个变分框架中:通过非局部相似块聚类自适应地在线学习字典;利用局部和非局部的冗余信息对稀疏编码进行约束,强制稀疏编码靠近其非局部均值以减少编码误差.另外,为了有效抑制服从重尾分布的 CDM 误差,设计了基于 l_1 范数的数据项.最后,联合交替最小化方法和算子分裂技巧对模型进行有效求解.实验结果表明本文提出的方法不仅提高了峰值信噪比,降低了锯齿效应比,而且锐化了图像边缘和纹理,改善了重建图像的视觉质量.

参考文献

- [1] C Y Tsai, K T Song. Heterogeneity-projection hard-decision color interpolation using spectral-spatial correlation[J]. IEEE Transactions on Image Processing, 2007, 16(1): 78-91.

- [2] J F Hamilton, J Adams. Adaptive color plane interpolation in single sensor color electronic camera[P]. U S:5629734, 1997.
- [3] X Wu, N Zhung. Primary-consistent soft-decision color demosaicking for digital cameras[J]. IEEE Transactions on Image Processing, 2004, 13(9): 1263 – 1274.
- [4] B Gunturk, Y Altunbasak, R Mersereau. Color plane interpolation using alternating projections[J]. IEEE Transactions on Image Processing, 2002, 11(9): 997 – 1013.
- [5] Xin Li. Demosaicing by successive approximation[J]. IEEE Transactions on Image Processing, 2005, 14(3): 370 – 379.
- [6] L Zhang, X Wu. Color demosaicking via directional linear minimum mean square-error estimation[J]. IEEE Transactions on Image Processing, 2005, 14(12): 2167 – 2178.
- [7] A Buades, et al. Self-similarity driven color demosaicking[J]. IEEE Transactions on Image Processing, 2009, 18(6): 1192 – 1202.
- [8] L Zhang, X Wu, et al. Color demosaicking by local directional interpolation and non-local adaptive thresholding[J]. Journal of Electronic Imaging, 2011, 20(2): 023016 – 16.
- [9] W Dong, et al. Image deblurring and super-resolution by adaptive sparse domain selection and adaptive regularization[J]. IEEE Transactions on Image Processing, 2011, 20(7): 1838 – 1857.
- [10] 孙玉宝, 肖亮, 等. 图像稀疏表示的结构自适应子空间匹配追踪算法[J]. 计算机学报, 2012, 35(8): 1751 – 1758.
Sun Yu-bao, Xiao Liang, et al. A structure adaptive matching pursuit subspace search algorithm for effective image sparse representation[J]. Journal of Computer, 2012, 35(8): 1751 – 1758. (in Chinese)
- [11] 孙玉宝, 韦志辉, 等. 多形态稀疏性正则化的图像超分辨率算法[J]. 电子学报, 2010, 38(12): 2898 – 2903.
Sun Yu-bao, Wei Zhi-hui, et al. Multimorphology sparsity regularized image super-resolution[J]. Acta Electronica Sinica, 2010, 38(12): 2898 – 2903. (in Chinese)
- [12] Duc-Son Pham, S Venkatesh. Improved image recovery from compressed data contaminated with impulsive noise[J]. IEEE Transactions on Image Processing, 2012, 12(1): 397 – 405.
- [13] W Dong, et al. Centralized sparse representation for image restoration[A]. Proceedings of IEEE International Conference on Computer Vision[C]. USA: IEEE, 2011. 1259 – 1266.
- [14] L Zhang, et al. Two-stage image denoising by principal component analysis with local pixel grouping[J]. Pattern Recognition, 2010, 43(4): 1531 – 1549.
- [15] C Liu, R Szeliski, et al. Automatic estimation and removal of noise from a single image[J]. IEEE Transactions on PAMI, 2008, 30(2): 299 – 314.
- [16] S Setzer. Operator splittings, Bregman methods and frame shrinkage in image processing[J]. International Journal of Computer Vision, 2011, 92(3): 265 – 280.
- [17] W T Freeman, et al. Example-based super-resolution[J]. IEEE Computer Graphics and Applications, 2002, 22(2): 56 – 65.
- [18] Meng Yang, et al. Metaface learning for sparse representation based face recognition[A]. Proceedings of IEEE International Conference on Image Processing[C]. USA: IEEE, 2011. 1601 – 1604.
- [19] M Elad, M Aharon. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736 – 3745.

作者简介



黄丽丽 女, 1977 年出生, 广西德保人, 博士, 讲师, 主要研究领域为图像建模与算法。

E-mail: huang-lili@163.com



肖亮(通信作者) 男, 1976 年出生, 湖南长沙人, 教授, 博士生导师, 主要研究领域为图像处理反问题。

E-mail: xiaoliang@mail.njst.edu.cn



韦志辉 男, 1963 年出生, 江苏淮安人, 教授, 博士生导师, 主要研究领域为稀疏编码理论及应用。

E-mail: gswei@mail.njst.edu.cn