

## 面向单幅图像去雨的非相干字典学习及其稀疏表示研究

汤红忠<sup>1,2,3</sup>, 王翔<sup>1,3</sup>, 张小刚<sup>2</sup>, 李骁<sup>1,3</sup>, 毛丽珍<sup>1,3</sup>

(1. 湘潭大学信息工程学院, 湖南 湘潭 411105; 2. 湖南大学电气与信息工程学院, 湖南 长沙 410082;  
3. 湘潭大学控制工程研究所, 湖南 湘潭 411105)

**摘 要:** 提出一种非相干字典学习及稀疏表示方法, 并将其应用于单幅图像去雨。该方法在字典学习阶段, 为降低有雨原子与无雨原子间的相似性, 引入字典的非相干性, 构建新的目标函数, 不仅可以保证有雨字典与无雨字典的可分性, 而且学习的非相干字典具有类似于紧框架的性质, 可以逼近等角紧框架。通过有雨字典与无雨字典对高频图像的稀疏表示, 能够更好地分离出高频图像中的有雨分量与无雨分量, 将高频无雨分量与低频图像融合实现图像去雨。采用合成雨图与真实雨图对算法进行验证, 实验结果表明, 算法所学习的非相干字典具有较好的稀疏表示性能, 去雨后的图像雨线残留较少, 边缘细节保持较好, 视觉效果更为清晰自然。

**关键词:** 非相干字典; 字典学习; 稀疏表示; 单幅图像去雨

中图分类号: TP391.4

文献标识码: A

## Incoherent dictionary learning and sparse representation for single-image rain removal

TANG Hong-zhong<sup>1,2,3</sup>, WANG Xiang<sup>1,3</sup>, ZHANG Xiao-gang<sup>2</sup>, LI Xiao<sup>1,3</sup>, MAO Li-zhen<sup>1,3</sup>

(1. College of Information Engineering, Xiangtan University, Xiangtan 411105, China;

2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

3. Institute of Control Engineering, Xiangtan University, Xiangtan 411105, China)

**Abstract:** The incoherent dictionary learning and sparse representation algorithm was present and it was applied to single-image rain removal. The incoherence of the dictionary was introduced to design a new objective function in the dictionary learning, which addressed the problem of reducing the similarity between rain atoms and non-rain atoms. The divisibility of rain dictionary and non-rain dictionary could be ensured. Furthermore, the learned dictionary had similar properties to the tight frame and approximates the equiangular tight frame. The high frequency in the rain image could be decomposed into a rain component and a non-rain component by performing sparse coding based learned incoherent dictionary, then the non-rain component in the high frequency and the low frequency were fused to remove rain. Experimental results demonstrate that the learned incoherent dictionary has better performance of sparse representation. The recovered rain-free image has less residual rain, and preserves effectively the edges and details. So the visual effect of recovered image is more sharpness and natural.

**Key words:** incoherent dictionary, dictionary learning, sparse representation, single-image rain removal

### 1 引言

受有雨天气状况的影响, 户外镜头所采集图像

的部分纹理与细节信息容易被雨线遮挡, 造成局部区域过亮、背景图像模糊等问题。雨天图像质量的退化极大制约了视觉监控、视觉导航与目标跟踪等

收稿日期: 2017-01-10; 修回日期: 2017-04-08

通信作者: 张小刚, zhangxiaogang@126.com

基金项目: 国家自然科学基金资助项目 (No.61573299, No.61673162, No.61672216, No.61602397); 湖南省自然科学基金资助项目 (No.2017JJ3315, No.2017JJ2251, No.2016JJ3125)

**Foundation Items:** The National Natural Science Foundation of China (No.61573299, No.61673162, No.61672216, No.61602397), The Natural Science Foundation of Hunan Province (No.2017JJ3315, No.2017JJ2251, No.2016JJ3125)

户外智能视觉系统的功能,且雨滴颗粒状态多变,不同情形下的雨线方向和粗细均不相同。因此,研究如何从各类雨天降质图像中恢复出高质量的图像具有极高的研究与应用价值<sup>[1-3]</sup>。

图像去雨研究主要包括视频图像去雨与单幅图像去雨。与视频图像去雨相比,单幅图像去雨可利用的先验知识较少,其研究更具挑战性,所以迅速受到国内外研究人员的关注<sup>[4-10]</sup>。Wu等<sup>[4]</sup>结合雨滴显著图确定雨滴的候选区域,采用二值支持向量机实现雨滴检测,并利用图像修复技术实现雨滴去除。Kim等<sup>[5]</sup>假设雨滴呈椭圆形且雨线方向为垂直向下,利用椭圆形状与方向实现雨滴检测,并基于非局部均值滤波方法实现单幅图像去雨。Chen等<sup>[6]</sup>基于雨线的时空相关性提出一种低秩模型实现单幅(视频)图像去雨,但这一方法并未考虑降雨时大风、雨雾等因素的影响。Li等<sup>[7]</sup>基于图块的先验知识,提出一种混合高斯模型实现图像有雨层与无雨层的分离,但该模型适合背景较为平滑的图像。

降雨图像物理退化过程复杂,受大风、大雨过程形成雾气等因素的影响,雨线方向与形状均会发生一定程度的变化,故其利用的各类先验条件均存在一定的局限性。因此,Kang等<sup>[8]</sup>提出一种基于字典学习及稀疏表示的单幅图像去雨框架,该框架首先利用双边滤波将有雨图像分为高频图像与低频图像,基于字典学习实现高频图像的稀疏表示,结合方向梯度直方图(HOG, histogram of oriented gradient)特征实现学习字典的原子分类,得到无雨字典与有雨字典,通过稀疏重构获得高频图像的有雨分量与无雨分量,将高频图像的无雨分量与低频图像叠加得到去雨后的图像。该方法去雨后图像易模糊。Huang等<sup>[9]</sup>基于文献[8]采用仿射传播方法实现字典原子的聚类,利用无雨原子类的较大方差获得高频无雨分量,该方法图像去雨后边缘保持程度有所提高,但有一定的雨线残留,而且字典聚类方法导致算法实时性差。Luo等<sup>[10]</sup>利用PS(Photoshop)中的滤色原理提出一种非线性雨图模型,并利用判别性稀疏编码实现图像去雨,该方法通过约束无雨图像与有雨分量的稀疏表示系数间的相关性实现图像去雨,雨线残留现象严重,去雨不彻底。

基于字典学习及稀疏表示实现图像去雨取得了一定的效果,但仍然存在以下问题。1) 有雨图像中雨线与背景图像纹理之间存在重叠现象,现有的字典学习方法得到的字典原子间相似度较

高。因此,难以对字典原子准确分类,容易将背景图像中与雨线相似的结构误判为雨线,去雨后的图像产生过度平滑现象<sup>[8]</sup>,或把雨线判为背景图像,去雨不彻底<sup>[9]</sup>。2) 无雨图像与有雨层图像使用同一个字典进行稀疏表示,仅通过间接约束无雨图像与有雨层图像的稀疏表示系数间的相关性,无法保证有雨层与无雨层的分离,去雨后的图像雨线残留严重<sup>[10]</sup>。

为了解决上述问题,本文提出了一种非相干字典学习方法,其目的是实现单幅图像去雨。与现有单幅图像去雨方法的不同之处在于以下2点。1) 构建了一个非相干字典学习的模型,该模型引入了字典的非相干性,抑制了原子间的相似性,能够降低有雨原子与无雨原子间的相似性,能保证聚类时有雨字典与无雨字典的可分性。2) 学习的非相干字典具有类似于紧框架的性质,可以逼近等角紧框架,因此,基于本文学习的非相干字典对图像具有更好的稀疏表示性能,其稀疏表示系数正好与图像的规则密切关联。实验结果表明,结合非相干字典学习及稀疏表示可以有效提高图像去雨的性能,同时具有较好的实时性。

## 2 非相干性与等角紧框架

近几年来,基于字典学习及稀疏表示的理论研究引起了广大学者的关注<sup>[11-13]</sup>。传统字典学习,如K-SVD(K-singular value decomposition)<sup>[11]</sup>、在线字典学习(online dictionary learning)<sup>[12]</sup>等方法学习的字典虽然可以较好保证样本数据的稀疏性,但若直接应用于图像去雨,会造成学习字典中有雨原子与无雨原子间相似度较高,有雨分量与无雨分量无法分离,去雨后的图像产生雨线残留或过度平滑<sup>[8-10]</sup>。

非相干字典的学习可以提高数据样本的稀疏表示性能,并且能降低特征信息的冗余性,同时加快字典学习的速度<sup>[14,15]</sup>。字典的相干性作为过完备字典 $\mathbf{D}$ 中原子间相似程度的度量,其定义为

$$\mu(\mathbf{D}) = \max \left\{ \left| \langle d_i, d_j \rangle \right|, i \neq j \right\} \quad (1)$$

其中, $d_i$ 、 $d_j$ 表示字典中2个不同原子。 $\mu(\mathbf{D})$ 越大,原子间相似程度越强;反之, $\mu(\mathbf{D})$ 越小,原子间相似程度越弱,则 $\mathbf{D}$ 为非相干字典。正交基相干性等于0,但是正交基无法保证样本表示的稀疏性。

文献[16]指出框架是基的过完备形式，而紧框架是正交基的过完备形式。更进一步，等角紧框架(ETF, equiangular tight frame)能获得过完备字典相干性的最小边界  $\mu(\mathbf{D}) = \sqrt{\frac{m-n}{n(m-1)}}$ ，其定义如下。

**定义 1** 矩阵  $\mathbf{F} \in \mathbb{R}^{n \times m}$ ，其中， $n < m$ ，列向量  $\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_m$ ，判断矩阵  $\mathbf{F}$  为等角紧框架需满足以下 3 个条件。

- 1) 列向量具有单位范数，即  $\|\mathbf{f}_j\|_2 = 1, 1 \leq j \leq m$ 。
- 2)  $|\mathbf{f}_i^T \mathbf{f}_j| = \cos \theta, 0 < \theta < \frac{\pi}{2}, i \neq j$ 。
- 3)  $\mathbf{F}\mathbf{F}^T = \frac{m}{n} \mathbf{I}_n = \lambda \mathbf{I}_n$ ， $\mathbf{I}_n$  是一个  $n$  阶单位阵。

由定义 1 可知，若  $\mathbf{F}$  为 ETF，则  $\mathbf{F}$  为行满秩矩阵，具有  $n$  个非零的奇异值且都等于  $\sqrt{\frac{m}{n}}$ 。

### 3 非相干字典学习及图像去雨

#### 3.1 模型构建

基于字典学习的图像去雨可视为一个二分类问题，通过对高频图像的字典学习及其稀疏表示，将学习的字典分为有雨字典与无雨字典，背景图像具有与雨线结构相似的区域，则字典原子间的相似程度较高，因此，希望构建的模型具有以下性能。

1) 学习的字典原子具有较好的可分性，即原子间的相似性较低，可以较大地提高原子分类性能，从而保证了高频无雨分量与有雨分量的分离。

2) 学习的字典具有一定的单位紧框架性，能获得较好的稀疏重构性能，且表示系数能反映一定图像的规则。

然而，基于定义 1 直接构造  $\mathbf{D}$  的等角紧框架非常困难<sup>[17]</sup>，因此，本文提出一种新的非相干字典学习的模型，同时，联合优化字典的稀疏表示性能这一策略，其目的是保证学习字典尽量逼近 ETF 结构，模型的定义如下

$$\min_{\mathbf{D}, \{\mathbf{x}_i\}_{i=1}^p} \sum_{i=1}^p \frac{1}{2} \|\mathbf{y}_i - \mathbf{D}\mathbf{x}_i\|_F^2 + \alpha \left\| \mathbf{D}\mathbf{D}^T - \frac{2m}{n} \mathbf{I}_n \right\|_F^2 + \beta \|\mathbf{x}_i\|_1$$

$$\text{s.t.} \|\mathbf{d}_j\|_2^2 = 1 \quad (2)$$

其中，训练样本集  $\mathbf{Y} := \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_p\} \in \mathbb{R}^{n \times p}$ ， $\mathbf{y}_i$  是第  $i$  个训练样本，即有雨图像第  $i$  个图像块内像素展开的列向量。 $\mathbf{D} \in \mathbb{R}^{n \times m}$  是过完备字典， $\mathbf{X} := \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p\} \in$

$\mathbb{R}^{m \times p}$ ， $\mathbf{x}_i$  是样本  $\mathbf{y}_i$  对应的稀疏表示系数。目标函数的第 1 项是稀疏重构性，第 2 项是学习字典的紧框架约束项，第 3 项控制稀疏表示系数的稀疏度， $\alpha$  与  $\beta$  平衡了重构误差、字典的相干性与稀疏度三者之间的权重。

式(2)中的第 2 项约束了学习字典的紧框架性，实质上也是降低学习字典的相干性，其证明过程如下。

**证明**

令  $\mathbf{D}\mathbf{D}^T = \mathbf{S}$ ， $\lambda = \frac{1}{n} \sum_{j=1}^m \|\mathbf{d}_j\|_2^2$ ，则式(2)中的第 2

项可写为

$$\left\| \mathbf{D}\mathbf{D}^T - 2\lambda \mathbf{I} \right\|_F^2 = \text{tr}(\mathbf{S} - 2\lambda \mathbf{I})^2 = \text{tr}(\mathbf{S}^2 - 4\lambda \mathbf{S} + 4\lambda^2 \mathbf{I}_n)$$

$$= \text{tr}(\mathbf{S}^2) - 4\lambda \text{tr}(\mathbf{S}) + 4\lambda^2 \text{tr}(\mathbf{I}_n) \quad (3)$$

其中

$$\lambda \text{tr}(\mathbf{S}) = \frac{1}{n} \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 = \frac{1}{n} \left( \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 \right)^2 \quad (4)$$

$$\lambda^2 \text{tr}(\mathbf{I}_n) = \frac{1}{n^2} \left( \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 \right)^2 n = \frac{1}{n} \left( \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 \right)^2 \quad (5)$$

结合式(4)与式(5)，式(3)可重新定义为

$$\left\| \mathbf{D}\mathbf{D}^T - 2\lambda \mathbf{I} \right\|_F^2 = \text{tr}(\mathbf{S}^2) = \text{tr}(\mathbf{D}\mathbf{D}^T)^2 = \text{tr}(\mathbf{D}^T \mathbf{D})^2 \quad (6)$$

由此可见，式(6)实际上优化了字典格拉姆矩阵中的元素。若字典原子为单位范数，即满足  $\|\mathbf{d}_j\|_2^2 = 1$ ，式(6)表示最小化字典格拉姆矩阵中非对角线上的元素  $\mathbf{d}_i^T \mathbf{d}_j (i \neq j)$ ，即字典原子间的相干性(如式(1)所示)。同时， $\lambda = \frac{1}{n} \sum_{j=1}^m \|\mathbf{d}_j\|_2^2 = \frac{m}{n}$ ，目标函

数中第 2 项即为所求。

在本文的模型中，一方面，约束了字典的单位范数紧框架性，可以最大化稀疏编码的支撑集，保证了字典的稀疏表示性能；另一方面，字典原子间相干性得到有效抑制，进一步保证原子间的可分性，从而有利于后一阶段有雨字典与无雨字典的分离。

#### 3.2 目标函数的求解

式(2)中的  $(\mathbf{D}, \mathbf{X})$  是一个组合的非凸优化问题，其求解一般采用交替最小化进行迭代更新，通过反复执行稀疏编码与字典更新直到满足收敛条件或完成迭代。

1) 稀疏编码：固定  $\mathbf{D}$ ，式(2)的稀疏编码直接采用前向后向算子分裂法<sup>[18]</sup>求解得到  $\mathbf{X}$ 。

2) 固定稀疏编码系数矩阵  $X$ , 则字典更新目标函数为

$$\min_D \sum_{i=1}^p \frac{1}{2} \|y_i - Dx_i\|_F^2 + \alpha \left\| DD^T - \frac{2m}{n} I_n \right\|_F^2 \quad (7)$$

将式(7)写成矩阵形式, 其定义为

$$\min_D \frac{1}{2} \|Y - DX\|_F^2 + \alpha \left\| DD^T - \frac{2m}{n} I_n \right\|_F^2 \quad (8)$$

$$\begin{aligned} \|Y - DX\|_F^2 &= \text{tr}((Y - DX)^T (Y - DX)) \\ &= \text{tr}(Y^T Y - 2Y^T DX + X^T D^T DX) \\ &= \text{tr}(Y^T Y) + \text{tr}(X^T D^T DX) - 2\text{tr}(DXY^T) \end{aligned} \quad (9)$$

$$\begin{aligned} \left\| DD^T - \frac{2m}{n} I_n \right\|_F^2 &= \text{tr}((DD^T - 2\lambda I_n)^T (DD^T - 2\lambda I_n)) \\ &= \text{tr}((DD^T - 2\lambda I_n)(DD^T - 2\lambda I_n)) \\ &= \text{tr}(DD^T DD^T - 4\lambda DD^T + 4\lambda^2 I_n) \end{aligned} \quad (10)$$

结合式(9)与式(10), 将式(8)对  $D$  求导, 其梯度可定义为  $2(DXX^T - YX^T) + 4\alpha\lambda(DD^T D - D)$ , 在每次字典的迭代更新中, 采用 LBFSGS (limited-memory BFGS) 方法<sup>[19]</sup>求解式(7)。

### 3.3 图像去雨步骤

本文具体实现步骤如下。

1) 图像分解。将有雨图像 (如图 1(b)所示) 分解为高频图像 (如图 1(c)所示) 与低频图像 (如图 1(d)所示)。高频图像包含了图像的有雨分量与

恢复图像的边缘信息, 而低频图像包含无雨图像的基本信息。

2) 非相干字典的学习。随机取高频图像中  $p$  个图块作为训练样本实现非相干字典学习 (如式(2)所示)。

3) 非相干字典原子的聚类。利用 HOG 特征对字典原子聚类, 将非相干字典分为有雨字典与无雨字典 2 个部分。

4) 基于非相干字典的稀疏重构。利用聚类后的非相干字典对样本进行稀疏表示, 分别可求得有雨字典与无雨字典的稀疏表示系数, 直接将有雨字典对应的稀疏表示系数置 0, 得到高频图像的有雨分量如图 2 所示, 高频图像的无雨分量如图 3 所示。

5) 将高频图像的无雨分量 (如图 3 所示) 与低频图像 (如图 1(d)所示) 相加, 得到图像去雨结果如图 4 所示。

## 4 实验结果比较与分析

为了验证本文算法的有效性与时性, 本文分别对合成雨图与真实雨图进行了仿真实验。硬件平台为 Intel Core i3, 3.70 GHz CPU, 4 GB 内存, 软件平台为 Matlab 2014a。

### 4.1 合成雨图

结合 3.3 节的图像去雨步骤, 对比了本文算法与文献[8]和文献[9]算法, 这 3 种算法都采用双边滤波对有雨图像进行分解, 分解后获得相同的高频图像与低频图像, 分别如图 1(c)、图 1(d)所示。基于以上不同算法学习的字典对高频图像进行稀疏表示, 利用其表示系数可重构出相应的高频图像有雨




图1 图像分解的结果



图2 不同算法恢复的高频图像有雨分量



图 3 不同算法恢复的高频图像无雨分量



图 4 图 1(d)与图 3 相加得到不同算法的图像去雨结果

分量与无雨分量,分别如图 2 和图 3 所示。与图 2(a)和图 2(b)相比,基于本文算法重构的高频有雨分量与背景图像分离更彻底,分离的有雨层图像更完整,如图 2(c)所示。图 3(a)是基于文献[8]算法重构的高频无雨分量,丢失了一部分背景图像的纹理与边缘信息。图 3(b)是基于文献[9]算法重构的高频无雨分量,仍包含残留的雨线。基于本文算法重构的高频无雨分量不仅无明显雨线残留,而且具有更为丰富的背景纹理,如图 3(c)所示。因此,本文提出的非相干性字典学习模型有效降低了原子间的相似性,提高了有雨原子与无雨原子的可分性。与其他字典学习算法相比,本文的算法更能正确区分高频图像中的有雨分量与无雨分量。最后,将重构的高频无雨图像(如图 3 所示)与低频图像(如图 1(d)所示)叠加,得到了不同算法的图像去雨结果,如图 4 所示。由图 4 可知,文献[8]算法虽然去雨较为彻底,但去雨后的图像模糊;文献[9]算法去雨后仍然存在一定的有雨分量;本文算法不仅能有效去除有雨分量,同时能够较好地保持背景图像纹理及其边缘,去雨后的图像较为清晰自然,视觉效果更好。

特别说明的是,与以上 3 种算法不同, Luo 等<sup>[10]</sup>基于判别性稀疏编码建立了图像去雨模型。该模型的无雨图像和有雨分量共享一个字典,仅通过约束这两者稀疏表示系数之间的关联实现图像去雨。图 5 给出了文献[8]、文献[9]、文献[10]与本文算法的去雨效果对比。从细节图对比分析可知,如图 5(g)所示,文献[8]算法去雨后的图像产生了过度平滑现象。如图 5(h)所示,文献[9]算法去雨不彻底。



图 5 不同算法的图像去雨结果

如图 5(i)所示, 文献[10]算法去雨后的图像清晰, 但雨线残留最为严重, 其主要原因在于利用这些方法学习的字典进行稀疏重构时无法保证雨线与背景区域的分离。如图 5(j)所示, 本文算法去雨后的图像基本无雨线残留, 且没有产生过度平滑与人工边缘的现象, 具有一定清晰的图像边缘轮廓。与其他算法相比, 本文提出的非相干字典学习模型保证了有雨分量与无雨分量的可分性, 因此, 具有更好的去雨效果。

为进一步验证本文方法的有效性, 采用 4 种不同的合成雨图 (包括不同粗细及方向的雨线), 对比算法有文献[8]算法、文献[9]算法与文献[10]算法。如图 6 所示, 本文提出的去雨算法可实现对不同方向与粗细的雨线去除。

目前, 单幅图像去雨算法缺乏一个标准性的评价指标。针对合成雨图, 主要通过对比去雨前后图像之间的相似度来定量评估不同算法的去雨性能。本文采用峰值信噪比 (PSNR, peak signal to noise ratio) 与图像结构相似质量指数 (SSIM, structural similarity index metric) [20]对不同算法的去雨性能进行评估。其中, PSNR 值越大, 则代表图像去雨后失真度越小; 而 SSIM 取值范围为[0,1], 指标值越接近于 1, 则代表图像去雨前后图像相似度越高。表 1 和表 2 分别给出文献[8]、文献[9]、文献[10]与本文算法的性能指标

的对比效果。

表 1 给出了 4 种不同字典学习算法对多个测试图像去雨得到的 SSIM 值。由表 1 可知, 本文算法可以获得最高的 SSIM 值, 说明去雨后的图像与标准图像更为相似, 并保持了与视觉一致的效果。表 2 给出了 4 种不同字典学习算法对多个测试图像去雨得到的 PSNR 值, 由表 2 可知, 文献[10]的算法在测试图像 3、4 (如图 6 所示) 上获得了较高的 PSNR 值, 但去雨后的图像有较多有雨分量的残留 (如图 6(e)所示), 但综合来说本文算法具有更高的 PSNR 值。

### 4.2 真实雨图

为进一步验证本文算法的普适性, 采用真实雨图对本文算法的去雨性能进行测试, 并与文献[8]、文献[9]、文献[10]算法进行对比, 图 7 给出了基于真实雨图采用不同算法的图像去雨结果。对比图 7 第 1 行的方框细节图像 (如图 7 中的第 2 行所示), 如图 7(b)所示, 文献[8]算法去雨后的图像边缘细节出现失真现象, 较为模糊; 如图 7(c)和图 7(d)所示, 文献[9]算法与文献[10]算法去雨后的图像包含较多的雨线, 去雨不彻底, 比较适用于雨量较小的图像; 如图 7(e)所示, 本文算法去雨更为彻底, 且没有明显的人工边缘, 纹理信息与边缘细节得到了较好保持。



图 6 不同算法的图像去雨结果

**表 1** 基于合成雨图不同图像去雨方法的 *SSIM*

比较对象	图像 1	图像 2	图像 3	图像 4	图像 5	图像 6	平均值
标准图像	1	1	1	1	1	1	1
合成有雨图像	0.755	0.600	0.525	0.712	0.688	0.708	0.665
文献[8]算法去雨图像	0.726	0.762	0.669	0.748	0.695	0.802	0.734
文献[9]算法去雨图像	0.775	0.765	0.539	0.584	0.675	0.722	0.677
文献[10]算法去雨图像	0.752	0.805	0.635	0.821	0.700	0.741	0.742
本文算法去雨图像	0.811	0.812	0.689	0.821	0.760	0.805	0.783

**表 2** 基于合成雨图不同图像去雨方法的 *PSNR/dB*

比较对象	图像 1	图像 2	图像 3	图像 4	图像 5	图像 6	平均值
标准图像	$\infty$	$\infty$	$\infty$	$\infty$	$\infty$	$\infty$	$\infty$
合成有雨图像	23.86	20.40	19.08	23.31	19.89	22.67	21.54
文献[8]算法去雨图像	24.70	25.63	19.20	25.37	22.30	21.77	23.16
文献[9]算法去雨图像	25.56	25.51	19.55	22.76	25.37	21.06	23.30
文献[10]算法去雨图像	24.55	26.14	26.70	28.71	19.50	23.10	24.78
本文算法去雨图像	26.53	26.21	25.37	26.57	19.82	24.90	24.90




图 7 基于真实图像的不同图像去雨算法的结果

### 4.3 不同算法的去雨速度对比分析

表 3 列出了不同算法进行图像去雨的运行时间。其中,  $M \times N$  为图像尺寸, 每个尺寸的图像取 10 幅, 运行时间取 10 幅图像的去雨时间的平均值。由表 3 可以看出, 随着图像尺寸增大, 文献[10]算法时间开销最大, 这是由于其算法的复杂度远高于

其他 3 种算法, 且该算法的内存占用度极高。不论图像尺寸多大, 本文算法运行时间均明显优于其他 3 种方法, 在保证去雨质量的同时具有较好的实时性。其关键原因在于本文提出的非相干字典学习模型, 避免了原子间的过度冗余, 从而加快了字典学习速度。

表3

不同算法的去雨时间对比

图像尺寸 ( $M \times N$ )	文献[8]算法运行时间/s	文献[9]算法运行时间/s	文献[10]算法运行时间/s	本文算法运行时间/s
558×374	153.16	144.34	382.39	122.75
317×450	128.11	114.97	149.35	77.03
317×317	76.83	78.54	104.75	30.87

## 5 结束语

本文提出一种非相干字典学习及稀疏表示的单幅图像去雨方法。通过引入字典的非相干性,能够降低有雨原子与无雨原子间的相似性,大大提升了聚类时有雨字典与无雨字典的可分性。其次,本文学习的字典具有类似于紧框架的性质,可以逼近等角紧框架。通过有雨字典与无雨字典对高频图像的稀疏表示,能获得更完整的高频有雨图像与高频无雨图像。实验结果表明,基于本文学习的非相干字典对测试图像具有较好的稀疏表示性能,去雨后的图像雨线残留较少,边缘细节保持能力较好,同时具有较好的实时性。在未来的工作中,如何利用颜色特征达到更优的去雨效果,以及建立与视觉效果统一的客观去雨性能评价指标仍待进一步研究。

## 参考文献:

- [1] WANG Y, CHEN C, ZHU S, et al. A framework of single-image deraining method based on analysis of rain characteristics[C]//IEEE International Conference on Image Processing. 2016: 4087-4091.
- [2] MI Z, SHANG J, ZHOU H, et al. Image fusion-based video deraining using sparse representation[J]. Electronics Letters, 2016, 52(18): 1528-1529.
- [3] YANG W, TAN R T, FENG J, et al. Joint rain detection and removal via iterative region dependent multi-task learning[J]. arXiv preprint arXiv:1609.07769, 2016.
- [4] WU Q, ZHANG W, KUMAR B V K V. Raindrop detection and removal using salient visual features[C]//19th IEEE International Conference on Image Processing. 2012: 941-944.
- [5] KIM J H, LEE C, SIM J Y, et al. Single-image deraining using an adaptive nonlocal means filter[C]//2013 IEEE International Conference on Image Processing. 2013: 914-917.
- [6] CHEN Y L, HSU C T. A generalized low-rank appearance model for spatio-temporally correlated rain streaks[C]//The IEEE International Conference on Computer Vision. 2013: 1968-1975.
- [7] LI Y, TAN R T, GUO X, et al. Rain streak removal using layer priors[C]//The IEEE Conference on Computer Vision and Pattern Recognition. 2016: 2736-2744.
- [8] KANG L W, LIN C W, FU Y H. Automatic single-image-based rain streaks removal via image decomposition[J]. IEEE Transactions on Image Processing, 2012, 21(4): 1742-1755.
- [9] HUANG D A, KANG L W, WANG Y C F, et al. Self-learning based image decomposition with applications to single image denoising[J]. IEEE Transactions on Multimedia, 2014, 16(1): 83-93.
- [10] LUO Y, XU Y, JI H. Removing rain from a single image via discriminative sparse coding[C]//The IEEE International Conference on Computer Vision. 2015: 3397-3405.
- [11] ELAD M, AHARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on

Image Processing, 2006, 15(12): 3736-3745.

- [12] MAIRAL J, BACH F, PONCE J, et al. Online dictionary learning for sparse coding[C]//The 26th Annual International Conference on Machine Learning. 2009: 689-696.
- [13] 汤雅妃, 张云勇, 郭志斌. 基于稀疏表达的微弱信号提取及检测方法[J]. 通信学报, 2015, 36(Z1): 215-223.  
TANG Y F, ZHANG Y Y, GUO Z B. Approach to weak signal extraction and detection via sparseness representation[J]. Journal on Communications, 2015, 36(Z1): 215-223.
- [14] 汤红忠, 张小刚, 陈华, 等. 带边界条件约束的非相干字典学习方法及其稀疏表示[J]. 自动化学报, 2015, 41(2): 312-319.  
TANG H Z, ZHANG X G, CHEN H, et al. Incoherent dictionary learning method with border condition constrained for sparse representation[J]. Acta Automatica Sinica, 2015, 41(2): 312-319.
- [15] TANG H Z, ZHANG X, CHEN H, et al. Incoherent dictionary learning method based on unit norm tight frame and manifold optimization for sparse representation[J]. Mathematical Problems in Engineering, 2016.
- [16] GUREVICH S, HADANI R. Incoherent dictionaries and the statistical restricted isometry property[J]. arXiv preprint arXiv:0809.1687, 2008.
- [17] SUSTIK M A, TROPP J A, DHILLON I S, et al. On the existence of equiangular tight frames[J]. Linear Algebra and Its Applications, 2007, 426(2): 619-635.
- [18] RAKOTOMAMONJY A. Direct optimization of the dictionary learning problem[J]. IEEE Transactions on Signal Processing, 2013, 61(22): 5495-5506.
- [19] LIU D C, NOCEDAL J. On the limited memory BFGS method for large scale optimization[J]. Mathematical Programming, 1989, 45(1-3): 503-528.
- [20] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.

## 作者简介:



汤红忠 (1979-), 女, 湖南衡山人, 湖南大学博士生, 湘潭大学副教授, 主要研究方向为图像处理与模式识别、字典学习及稀疏表示。

王翔 (1991-), 男, 湖南衡阳人, 湘潭大学硕士生, 主要研究方向为图像处理与模式识别。

张小刚 (1972-), 男, 河南汝南人, 湖南大学教授、博士生导师, 主要研究方向为工业过程控制与模式识别。

李骁 (1993-), 男, 湖南临湘人, 湘潭大学硕士生, 主要研究方向为图像处理与模式识别。

毛丽珍 (1994-), 女, 湖南岳阳人, 湘潭大学硕士生, 主要研究方向为图像处理与模式识别。