

# 基于最小特征值非线性修正的快速噪声水平估计算法

徐少平 曾小霞 姜尹楠 林官喜 唐祎玲

(南昌大学信息工程学院 南昌 330031)

**摘 要** 鉴于从噪声图像上提取的原始图块协方差矩阵的最小特征值与噪声水平值之间具有显著的相关性,提出一种基于多项式回归技术训练非线性映射模型,直接将原始图块最小特征值修正为最终的噪声水平预测值的快速噪声水平估计算法。首先,选择具有代表性且无失真的自然图像作为训练图像集合;然后,对这些图像施以不同程度的高斯噪声构成样本训练图像库。在此基础上,提取各个噪声样本图像的原始图块,并使用 PCA 变化得到原始图块协方差矩阵的最小特征值;最后,利用多项式回归技术构建最小特征值与噪声水平值之间的非线性修正模型。实验表明,与现有算法相比,改进算法对高、中、低各级别的噪声都能鲁棒地进行预测,尤其在低水平噪声方面表现出色,在预测准确度和执行效率两方面具有显著的综合优势。

**关键词** 图像降噪,噪声水平估计,主成分分析,最小特征值,修正函数,低水平噪声

**中图分类号** TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.07.038

## Fast Noise Level Estimation Algorithm Based on Nonlinear Rectification of Smallest Eigenvalue

XU Shao-ping ZENG Xiao-xia JIANG Yin-nan LIN Guan-xi TANG Yi-ling

(School of Information Engineering, Nanchang University, Nanchang 330031, China)

**Abstract** Considering the fact that the smallest eigenvalue of covariance matrix of the raw patches extracted from noise images is significantly correlated with noise level, this paper proposed a fast algorithm that directly uses a pretrained nonlinear mapping model based on the polynomial regression to map (rectify) the smallest eigenvalue to the final estimate. Firstly, some representative natural images without distortion are selected as training set. Then, the training sample library is formed, and the training set images are corrupted with the different noise levels. Based on this, raw patches are extracted for each noisy image, and the smallest eigenvalue of covariance matrix of the raw patches is gotten by PCA transformation. Finally, a nonlinear mapping model between the smallest eigenvalue and the noise level are obtained based on polynomial regression technique. Extensive experiments show that the proposed algorithm works well for a wide range of noise levels and has outstanding performance at low levels in particular compared with the existing algorithms, showing a good compromise between speed and accuracy in general.

**Keywords** Image denoising, Noise level estimation, Principal component analysis, Smallest eigenvalue, Rectification function, Low level noise

## 1 引言

数字图像在获取、量化存储和传输过程中常常受到噪声的干扰,从而导致图像质量下降,严重影响了诸如特征提取、图像分析、模式识别等后继处理模块的性能<sup>[1-4]</sup>。为获得高质量的图像,需要利用降噪算法对失真图像进行处理,从而为后续处理任务奠定良好的基础。在众多的降噪算法<sup>[5-12]</sup>中,许多降噪效果较好的算法实质上属于非盲降噪算法(Non-blind Denoising Algorithm)。非盲降噪算法在使用过程中需要依靠人工估计图像的噪声水平并设置相应的参数值,但人工通

常很难获得准确的噪声水平值估计并且会使自动执行的降噪算法变为半自动降噪算法,从而严重限制了这些算法的实际应用效果。因此,研究自动化的图像噪声水平评估(Noise Level Estimation, NLE)算法十分有必要。

近年来,学者们已经提出了许多图像噪声水平估计算法<sup>[13-19]</sup>,这些算法的执行过程主要包括两个关键步骤:分离图像与噪声信号,从噪声信号中估算出噪声水平。例如:Immerkar 针对加性零均值高斯噪声提出了一种快速简单的估计方法<sup>[16]</sup>。该方法用一个  $3 \times 3$  的矩阵掩模在图像局部邻域内求和,再根据方差估算出噪声。虽然该算法的计算效率高,

到稿日期:2017-06-04 返修日期:2017-09-09 本文受国家自然科学基金(61662044,61163023,51765042,81501560),江西省自然科学基金(20171BAB202017)资助。

徐少平(1976—),男,博士,教授,博士生导师,主要研究方向为图形图像处理技术、机器视觉、虚拟手术仿真等,E-mail: xushaoping@ncu.edu.cn (通信作者);曾小霞(1993—),女,硕士生,主要研究方向为图形图像处理、机器视觉;姜尹楠(1992—),男,硕士生,主要研究方向为图形图像处理、机器视觉;林官喜(1992—),女,硕士生,主要研究方向为图形图像处理、机器视觉;唐祎玲(1977—),女,博士生,主要研究方向为图形图像处理、机器视觉。

但它的噪声水平估计结果并不太准确。Zoran 等人认为,无噪声图像的边缘带通滤波器响应分布的峰度值与噪声密切相关,通过构建目标函数模型并使用迭代的方法搜索目标函数的最佳值来进行噪声方差的评估<sup>[17]</sup>。该算法在中、低水平噪声以及复杂的自然图像中有着较好的性能,但是在高水平噪声条件下的预测效果不理想。它面临的最大问题是执行时间较长,且在目标函数的寻优过程中可能失败。Liu 等人提出了一种在奇异值分解(Singular Value Decomposition, SVD)域对高斯噪声进行估计的算法<sup>[18]</sup>。该算法需要对图像运用两次 SVD 分解才能获得噪声水平的估计值,计算复杂度较高。Yang 等人提出了一种融合了基于滤波和图块估计两类噪声水平估计算法各自优势的混合型算法,其能够有效避免图像结构或细节对噪声估计的影响<sup>[19]</sup>。相对而言,该算法能够提供比较高效且可靠的噪声估计,计算代价也较低。

近年来,有研究者基于从噪声图像中提取的原生图块(Raw Patches)实现了一类预测准确性较好的 NLE 算法。原生图块是指按照重叠或者不重叠的方式直接从噪声图像中提取出的具有一定大小的子图(常用的子图块大小为  $8 \times 8$ ,  $16 \times 16$  或  $32 \times 32$ ),对其协方差矩阵进行主成分分析(Principal Component Analysis, PCA)变换后,可以利用协方差矩阵的一个或者若干个特征值获得一类基于 PCA 变换的噪声水平估计算法。代表性的工作有:1)Pyatykh 等人提出了一种基于主成分分析的噪声水平估计算法<sup>[14]</sup>。该算法需要根据约束条件在原生图块中确定同质图块(Homogenous Patches)(同质图块是指图像中图像亮度值变化不大甚至为零的光滑区域),然后计算同质图块协方差矩阵的最小特征值,并将其作为噪声水平的估计值。2)Liu 等人<sup>[20-21]</sup>则基于 PCA 变换提出了另一种选择条件,即从原生图块中筛选出同质图块(本文称其为低秩图块),然后提取低秩图块协方差矩阵的最小特征值作为噪声水平的估计值。Liu 算法的预测准确性比较高;Pyatykh 算法和 Liu 算法的共同特点是按照特定约束条件从噪声图像的原生图块中筛选出同质图块,然后将这些同质图块协方差矩阵的最小特征值作为噪声水平值的估计。然而,这两种算法定义的约束条件却以待评估的噪声水平值作为参数,这是一个典型的“鸡与蛋”的问题。为此,这两种算法都只能采用迭代逼近的方式来实现噪声水平的评估,计算效率比较低。3)为解决这个问题,Chen 等人<sup>[15]</sup>在对噪声图像的原生图块协方差矩阵进行 PCA 变化后,直接使用原生图块协方差矩阵的若干个特征值计算出噪声水平值。Chen 算法由于没有筛选同质图块的过程,计算效率相对较高,但其在计算效率和低水平噪声条件下的预测准确性等方面仍有改进的空间(详见第 2 节对相关工作的分析)。

为进一步提高 Chen 算法的执行效率,同时改善该算法在低噪声水平条件下的预测准确度,提出了一种最小特征值非线性修正的快速噪声水平估计算法。该算法充分利用原生图块协方差矩阵最小特征值与噪声水平之间的强相关性,通过多项式回归技术预先训练的映射函数将最小特征值直接映射(修正)为噪声水平估值大小。大量实验表明,改进算法在执行效率方面较 Chen 算法有显著提高,在低、中、高各级别噪声水平条件下均表现出良好的鲁棒性,尤其是在低水平噪声方面,其预测准确性有显著提高。改进算法本质上属于基

于训练的多图像噪声评估算法,可以充分利用图像所蕴含的规律性的特征作为先验知识来实现准确的噪声水平预测,且执行速度较快;它在执行效率和预测准确性之间达到了很好的平衡,尤其适合作为众多非盲降噪算法的前置预处理模块使用。

## 2 相关工作

### 2.1 Chen 算法<sup>[15]</sup>简介

基于 PCA 的噪声水平估计算法通常都需要先将噪声图像分解成一系列的图块,然后对这些图块的协方差矩阵进行进一步的处理。给定一张大小为  $M \times N$  的灰度图像,Chen 算法首先将图像分解为图块集  $X_s = \{x_i\}_{i=1}^s \in \mathbb{R}^{r \times s}$ ,此时集合  $X_s$  中有  $(M-d+1)(N-d+1)$  个大小为  $d \times d$  的图块。为方便问题描述,将图块  $x_i$  写成具有  $r = d^2$  维的矢量形式。集合  $X_s$  中的任意向量  $x_i$  都可以被分解成:

$$\hat{x}_i = x_i + e_i \quad (1)$$

其中,  $\hat{x}_i \in \mathbb{R}^{r \times 1}$  是位于低维子空间的无噪声的图块,  $e_i \in \mathbb{R}^{r \times 1}$  代表噪声。当无失真图像被服从标准正态分布  $N(0, \sigma^2)$  的高斯噪声破坏时,噪声  $e_i$  会服从均值为 0、协方差矩阵为  $\sigma^2 I$  的多元高斯分布  $N_r(0, \sigma^2 I)$ 。因此,图块集  $X_s$  上的噪声估计水平可以作为图像噪声水平估计。经过理论分析后认为,无失真图像的图块分布在  $m$  维的线性子空间中,其中  $m$  是一个预定义的整数且  $m \ll r$ ,其形式化表示如下:

$$x_i = Ay_i + e_i \quad (2)$$

其中,  $A \in \mathbb{R}^{r \times m}$  表示在约束条件  $A^T A = 1$  下的  $m$  维子空间的矩阵,  $y_i$  是  $x_i$  在  $A$  中旋转得到的子空间的投影点,主成分分析 PCA 可以用于推导出式(2)所描述的线性模型,  $A$  由原生图块的协方差矩阵的  $m$  个最大特征矢量构成。原生图块协方差矩阵的计算方法如下:

$$\mu = \frac{1}{s} \sum_{i=1}^s x_i \quad (3)$$

$$\Sigma_x = \frac{1}{s} \sum_{i=1}^s (x_i - \mu)(x_i - \mu)^T \quad (4)$$

其中,  $s$  代表原生图块的个数。

在 Chen 算法中,原生图块协方差矩阵经过 PCA 变换后可以确定  $r$  个特征值  $\{\lambda_i\}_{i=1}^r$ ,  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ 。这些特征值  $S = \{\lambda_i\}_{i=1}^r$  可以划分为  $S_1 \cup S_2$  两部分,其中  $S_1 = \{\lambda_i\}_{i=1}^m$  反映的是图像信号的方差信息,  $S_2 = \{\lambda_i\}_{i=m+1}^r$  反映的是噪声信号的方差信息。Chen 算法根据以下条件来确定  $m$  值的大小:

$$\sum_{p=m+1}^k \lambda_p = \sum_{q=k+1}^r \lambda_q \quad (5)$$

其中,  $\lambda_p$  值是在特征值集合  $S_2$  中大于  $\tau$  值的特征值,  $\lambda_q$  是在特征值集合  $S_2$  中小于  $\tau$  的特征值。  $\tau$  值是 Chen 算法中为推演噪声水平值所定义的一个选择条件(详细的理论证明参见文献<sup>[15]</sup>):

$$\tau = \frac{1}{r-k} \sum_{q=k+1}^r \lambda_q \quad (6)$$

在 Chen 算法中,集合  $S_1$  一开始被设置为空集,  $m$  值被设置为 0;然后,采用循环迭代穷举的方法依次将  $m$  值增加 1,从最大的特征值开始,不断尝试将  $\lambda_m$  值加入到集合  $S_1$  中(同时减小集合  $S_2$  中的特征值个数)。重复上述过程,直至式(5)中描述的条件得到满足。在条件满足的情况下,图像噪声水

平值被估计为: $\sigma=\sqrt{\tau}$ 。从 Chen 算法的实现方式来看,确定  $\tau$  值的过程需要耗费一定的时间。

### 2.2 存在的问题

与 Pyatykh 和 Liu 算法相比,Chen 算法直接使用噪声图像的原生图块并计算这些图块协方差矩阵的特征值,然后选择若干特征值来导出噪声水平的估计,因此 Chen 算法并没有筛选同质图块的过程,计算效率得到了提高。但 Chen 算法仍存在以下两方面不足:1)执行效率有待进一步提高,在确定  $m$  值的过程中,Chen 算法需要采用循环穷举的方式来确定  $\tau$  值,执行时间较长;2) Chen 算法依赖若干特征值估计的噪声水平值,在低水平噪声条件下对噪声水平值的估计严重偏高。如图 1 所示,Chen 算法在估计低水平噪声时存在严重的过估计问题(特别是水平值小于 10 时)。经典的 BM3D 基准测试算法<sup>[12]</sup>使用了不准确的预测值,这会影响降噪算法的效果。如图 2 所示,Lena 图像加入了噪声水平值为 2 的噪声,然后分别利用真实值噪声和 Chen 算法估计的噪声值(估计值在 4 左右)作为 BM3D 算法的入口参数对该图像降噪。图 2(a)是原始图像;图 2(b)是加入噪声水平值为 2 的高斯噪声的图像;图 2(c)是 BM3D 对真实噪声降噪后的图像,PSNR=44.66;图 2(d)给出了 BM3D 对 Chen 算法估计的噪声值进行降噪后的图像,PSNR=42.77;图 2(e)~图 2(h)是图 2(a)~图 2(d)的局部放大图。所获得的降噪图像在 PSNR 指标上大约相差 2,差别比较明显。在视觉上,从图 2(e)~图 2(h)的放大子图中可以看出,使用 Chen 算法估计的噪声参数所获得的图像存在过模糊的现象,图像细节被过度光滑了。




图 1 Chen 算法在 1150 张噪声图像上预测的噪声值与真实值的对比

Fig. 1 Comparison between estimated results obtained by Chen's algorithm and ground truths on 1150 noise images




图 2 在低水平噪声水平下 BM3D 算法使用噪声水平真值和 Chen 算法估计值的对比

Fig. 2 Comparison of BM3D denoising effect using ground truth and estimated values obtained by Chen's algorithm at low noise level

## 3 改进算法

### 3.1 基本思想

本文的创新思想主要来源于以下观察:图 3 给出了从 1150 张噪声图像上根据 Chen 算法提取的原生图块协方差矩阵中最小特征值和真实噪声水平值的对比情况,使用了文献[22]中的 50 张具有代表性的自然图像,每张图像上施加了 1,3,5,7,10,15,20,25,30,35,40,45,50,55,60,65,70,75,80,85,90,95 和 100 共 23 级的噪声(故有 1150 张失真图像,且每一噪声水平下有 50 张噪声图像)。由图 3 可以看出,1150 张噪声图像由于受到了预知噪声水平值的干扰,真实噪声水平值的分布呈现阶梯状上升的特点,而从各张噪声图像原生图块中提取的最小特征值也具有阶梯状上升的特点,尽管在每一段阶梯上存在小范围的波动。另外,在低噪声水平条件下,最小特征值比真实噪声水平高(这也是 Chen 算法在低水平噪声条件下存在过估计问题的原因。此时,最小特征值均大于噪声水平真值,根据式(6)计算的噪声水平值必定大于噪声水平真值)。当噪声水平值高于 20 后,最小特征值逐渐低于真实值。显然,不能直接将最小特征值作为真实噪声水平估计值。尽管如此,最小特征值的分布在总体上与真实噪声水平值存在相同的变化趋势,也存在对应关系。




图 3 原生图块协方差矩阵最小特征值与真实噪声的对比

Fig. 3 Comparison between the smallest eigenvalue of covariance matrix of raw patches and ground truth

基于上述大量数据上观察到的现象,改进算法的主要技术路线为:在大量有代表性的图像集合上,通过训练构造出一个非线性映射(修正)函数,将从原生图块中获得的最小特征值直接映射为噪声水平估计值,这种直接映射的方法将显著提高 Chen 算法的效率,并且这种训练方法可以充分利用自然图像中的统计规律,将有效改善很多算法不能很好解决低噪声水平条件下的预测问题。

### 3.2 最小特征值与噪声水平值的相关性

为了定量地分析最小特征值与噪声水平值之间的相关性,从文献[22]中选出 10 张无失真的图像,如图 4 所示,并为这些图像分别加上 1,5,10,20,40,60,80 和 100 的高斯噪声(限于篇幅,只给出这些噪声水平的实验数据);然后提取原生图块的最小特征值,并将其列于表 1 中。从表 1 中的数据可以看出:1)每一张图像在不同噪声水平条件下的协方差矩阵的最小特征值构成的矢量数据(即表 1 中各行数据)与噪声水平真实值数据(即 1,5,10,20,40,60,80,100)之间的 PLCC 相关系数均在 0.99 以上,这充分表明了最小特征值与噪声水平值之间存在高度的相关性;2)在表 1 中,各个不同图像在同一列(相同的噪声水平值条件下)的数据值变化并不大,其值受图像内容的影响不大,只要图像受到相同噪声水平值的作用,

所提取的最小特征值就近似,这也从另一方面说明了最小特征值与噪声水平值之间具有强相关性;3)对于低于10的噪声,最小特征值普遍高于真实值,而高于20的噪声,则普遍低于真实值。显然,从图像原生图块中提取的最小特征值并不能直接作为噪声水平的评估值,但可以通过它们之间高度的相关性对最小特征值进行适当处理来获得噪声水平的合理估计。

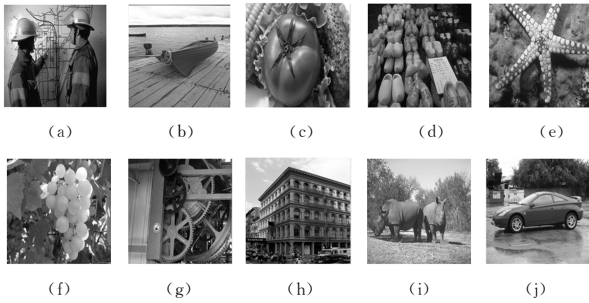


图4 文献[22]中10张有代表性的图像  
Fig. 4 Ten representative images in reference [22]

表1 不同噪声水平条件下原生图块协方差矩阵的最小特征值与噪声水平值的相关性

Table 1 Correlation between the smallest eigenvalue of covariance matrix of raw patches and noise level at different noise levels values

图像	噪声水平								相关系数
	1	5	10	20	40	60	80	100	
图4(a)	2.38	5.33	9.77	18.21	35.54	52.87	68.56	86.27	0.9999
图4(b)	3.09	5.51	10.30	18.73	35.50	52.66	70.36	86.65	0.9999
图4(c)	3.98	6.07	10.21	18.57	35.58	52.30	68.85	84.49	0.9999
图4(d)	2.24	5.21	9.54	18.18	35.04	50.97	69.05	83.91	0.9998
图4(e)	2.68	5.46	9.56	18.30	34.78	52.07	69.06	83.66	0.9998
图4(f)	2.09	5.13	9.37	17.82	34.13	51.56	68.53	86.43	0.9999
图4(g)	2.24	5.22	9.50	18.36	34.96	52.95	68.16	85.64	0.9999
图4(h)	2.62	5.18	9.31	18.05	34.45	51.82	68.06	84.71	0.9999
图4(i)	4.00	6.27	10.45	19.23	36.04	52.98	69.79	86.46	0.9999
图4(j)	1.94	5.14	9.44	17.93	34.62	51.98	68.64	85.86	1.0000

### 3.3 修正函数

由上文可知,最小特征值与噪声水平真值具有对应关系,因此可以利用多项式线性回归模型将最小特征值直接映射(修正)为噪声水平值。给定一组失真图像对象(已知噪声水平),从这些失真图像上提取其原生图块的最小特征值,在这些特征值及其对应的噪声水平真值之间建立如下多项式回归模型:

$$\sigma_i = a_0 + a_1 \lambda_r^i + a_2 \lambda_r^{2i} + \dots + a_m \lambda_r^{mi} + \epsilon_i, i = 1, 2, \dots, n \quad (7)$$

其中,  $\sigma_i$  是第  $i$  张噪声图像的方差,  $\lambda_r^i$  是最小特征值,  $a = (a_0, a_1, \dots, a_m)$  是多项式拟合函数的系数,  $\epsilon_i$  是第  $i$  张图像上的拟合误差。具体可以在训练集合上构建以下线性方程组来求解这个模型中的模型系数:

$$\begin{bmatrix} \sigma_1 \\ \sigma_2 \\ \sigma_3 \\ \vdots \\ \sigma_n \end{bmatrix} = \begin{bmatrix} 1 & \lambda_r^1 & \lambda_r^{2^1} & \dots & \lambda_r^{m^1} \\ 1 & \lambda_r^2 & \lambda_r^{2^2} & \dots & \lambda_r^{m^2} \\ 1 & \lambda_r^3 & \lambda_r^{2^3} & \dots & \lambda_r^{m^3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & \lambda_r^n & \lambda_r^{2^n} & \dots & \lambda_r^{m^n} \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ a_m \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \\ \vdots \\ \epsilon_n \end{bmatrix} \quad (8)$$

用矩阵形式表示为:

$$\vec{\sigma} = X \vec{a} + \vec{\epsilon} \quad (9)$$

其中,  $X$  是由最小特征值构成的系数矩阵,  $\vec{\sigma}$  是由噪声水平真值构成的目标矢量,  $\vec{a}$  是模型系数构成的向量,  $\vec{\epsilon}$  是误差矢量。利用最小二乘估计多项式回归系数的矢量为:

$$\hat{\vec{a}} = (X^T X)^{-1} X^T \vec{\sigma} \quad (10)$$

有很多技术(如支持向量回归 SVR 和神经网络技术)可以实现将最小特征值修正为最终的噪声水平值,本文则使用多项式回归技术来实现,因为其有效且实现较简单。

### 3.4 训练修正函数

利用式(10)即可在训练数据集上完成训练,而合适的多项式次数的选择尚有待确定。次数较多,将导致计算量增加;而过少的次数则有可能导致映射函数的描述能力有限,精度达不到要求。为了解决这个问题,在50张图像集合上采用穷举的方法来检查预测误差的大小,从而确定合适的多项式参数。具体地,对文献[22]中的50张图像分别加入23级高斯噪声(限于篇幅,只给出1,5,10,20,40,60,80,100级噪声条件下的实验数据),根据不同次数得出的噪声预测值计算对应的均方根误差(Root Mean Square Error, RMSE)。采用不同次数的多项式模型进行训练学习,在各个噪声水平下,修正后的噪声水平值与真值之间的均方根误差如表2所列。从表2可以看出,采用不同次数的多项式对预测误差的影响并不大。相对而言,多项式的阶数为3时可以获得较好的预测精度,且计算复杂度也不高。利用训练学习模型修正图3所示的数据,考虑到视觉效果,只给出部分图像的结果,如图5所示。从图5中可以看出,原始的最小特征值经过多项式修改函数的映射后,与真实噪声水平值的重合度非常高。下文的所有噪声估计实验都将采用训练学习好的3次多项式映射函数完成。

表2 不同噪声水平下采用不同多项式次数修正函数预测的结果与真值之间的均方根误差

Table 2 RMSE between estimated results with different degrees of polynomials and ground truths at different noise levels

次数	噪声水平						
	5	10	20	40	60	80	100
5	0.59	0.46	0.34	0.61	0.99	0.79	1.27
4	0.59	0.45	0.34	0.61	0.98	0.79	1.27
3	0.58	0.48	0.34	0.61	0.96	0.79	1.26
2	0.58	0.47	0.34	0.61	0.97	0.79	1.25




图5 利用训练的修正函数对1150张噪声图像中部分图像的最小特征值进行修正后的效果

Fig. 5 Results of final estimation with pretrained nonlinear rectification function on partial images in 1150 noise images

## 4 实验与分析

### 4.1 测试环境

为了评估改进算法的性能,随机选取在各类文献中常用的图像作为测试图像集合,如图 6 所示。同时将提出的改进算法与经典的 Chen<sup>[15]</sup>, Immerkar<sup>[16]</sup>, Yang<sup>[19]</sup>, Zoran<sup>[17]</sup> 和 Liu<sup>[20-21]</sup> 共 5 个噪声水平估计算法进行实验对比。通过对不同算法在不同噪声水平下的预测准确性、BM3D 算法的实际应用效果以及平均执行时间进行对比实验,来验证改进算法的实际性能。实验均在 Matlab R2014a(运行在 Intel(R) Core (TM) i5-3210 CPU @ 2.50GHz RAM 6GB 主机上)统一环境下完成。

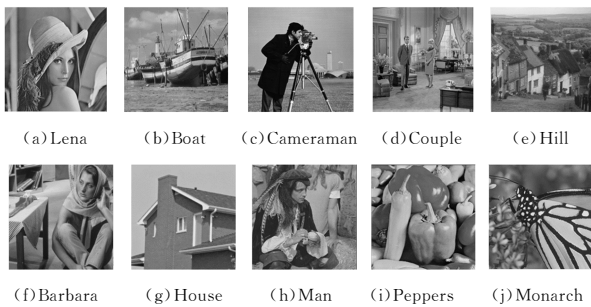


图 6 各类文献中常用的图像集合

Fig. 6 Commonly used images in literatures

### 4.2 预测准确性

表 3 给出了各算法在噪声级别为 5, 10, 20, 40, 60, 80 和 100 时的预测结果(限于篇幅,本文只列出了在 Barbara 图像上的预测数据,预测准确性排名前 3 的算法用下划线标出)。从表 3 中可以看出, Immerkar 算法在高、中、低各个噪声级别上的整体预测准确性都不能令人满意,相比于 Immerkar 算法, Zoran 算法和 Yang 算法的预测准确性有所改进,但其排名靠后。相对而言, Chen 算法、Liu 算法和本文提出的改进算法在各个噪声级别下的预测准确性都较好,尤其是改进算法在各个噪声级别下排进前 3 的次数最多,表现出了非常好的稳定性。对于小于 10 的低级别噪声而言, Chen 算法所预测的噪声水平值存在较严重的过估计问题,而改进算法则准确得多, Liu 算法最好。虽然在低水平噪声条件下的 Liu 算法预测性能最好,但是由下文中各算法在执行时间方面的对比实验可知, Liu 算法所获得的较高预测准确性是以极大的计算时间为代价的。综合而言,改进算法在执行效率和预测准确性两方面的总体优势更加明显。

表 3 不同噪声水平下各算法在 Barbara 图像上的评估结果

Table 3 Estimation results obtained by different algorithms on Barbara image at different noise levels

算法	噪声水平						
	5	10	20	40	60	80	100
Chen 算法	8.03	11.69	21.08	40.49	<u>60.40</u>	<u>79.68</u>	<u>99.71</u>
Immerkar 算法	7.92	12.34	21.29	<u>39.45</u>	56.36	68.97	79.57
Yang 算法	6.88	<u>11.42</u>	<u>20.47</u>	38.82	<u>60.34</u>	77.84	<u>98.96</u>
Zoran 算法	<u>3.82</u>	7.45	16.80	37.04	57.44	76.53	95.64
Liu 算法	<u>5.11</u>	<u>9.94</u>	<u>19.73</u>	<u>39.55</u>	59.44	<u>78.79</u>	97.06
Proposed	<u>3.99</u>	<u>9.24</u>	<u>19.17</u>	<u>39.54</u>	<u>59.70</u>	<u>79.18</u>	<u>98.96</u>

为了更加全面地评估各个算法的预测性能,将各个算法在 10 张常用测试图像的不同噪声级别下的预测结果与真实值的均方根误差进行比较,结果如表 4 所列(各级别噪声的条件下,评价准确性最优的 3 个算法用下划线标出)。由表 4 可知,各个算法的预测效果基本与表 3 中的结果类似。总之,只有改进算法在高、中、低各个级别上都保持了比较稳定的预测准确性,其原因在于自然图像具有内在的统计规律,而改进算法正是利用了这种极强的规律性,通过在大量自然图像上训练学习映射函数实现了准确的预测。

表 4 不同噪声水平下各算法在 10 张经典图像上的预测结果的均方根误差

Table 4 RMSE between estimated results and ground truths on 10 representative images at different noise levels

算法	噪声水平						
	5	10	20	40	60	80	100
Chen 算法	1.94	1.13	0.77	<u>0.50</u>	<u>0.68</u>	<u>0.72</u>	<u>0.70</u>
Immerkar 算法	1.60	1.19	0.75	0.69	3.80	10.20	19.94
Yang 算法	<u>0.64</u>	<u>0.47</u>	<u>0.31</u>	0.98	1.47	1.73	<u>2.49</u>
Zoran 算法	<u>0.55</u>	1.08	1.61	1.93	2.30	2.59	2.38
Liu 算法	<u>0.12</u>	<u>0.18</u>	<u>0.30</u>	<u>0.63</u>	<u>1.23</u>	<u>1.78</u>	2.50
Proposed	<u>0.91</u>	<u>0.64</u>	<u>0.60</u>	<u>0.52</u>	<u>0.76</u>	<u>1.01</u>	<u>0.80</u>

为更广泛地验证算法对测试图像的内容是否敏感,将 LIVE 数据库中的部分图像作为测试图像。表 5 列出在 LIVE 数据库中随机选取 20 张图像作为测试集获得的预测结果;同样,分别给图像加入噪声级别为 5, 10, 20, 40, 60, 80 和 100 的高斯噪声,预测结果通过均方根误差值给出(评价准确性最优的 3 个算法用下划线标出)。从表 5 中的数据可以看出, Immerkar 算法的整体效果较差;总体上, Zoran 算法在低、中、高噪声水平条件下比改进算法差; Chen 算法在中、低水平噪声条件下比改进算法的预测效果差; Liu 算法和 Yang 算法在大部分噪声级别下的均方根误差值比改进算法更好,但是由表 7 中执行时间的对比实验数据可知,它们的执行时间均比改进算法的执行时间长。简而言之,改进算法在获得较稳定的预测准确度的同时保持了较高的执行效率。

表 5 不同噪声水平下各算法在 LIVE 数据库(20 张)中的预测结果的均方根误差

Table 5 RMSE between estimated results and ground truths on twenty images from LIVE database at different noise levels

算法	噪声水平						
	5	10	20	40	60	80	100
Chen 算法	3.59	2.35	1.29	0.77	0.71	<u>0.70</u>	<u>0.80</u>
Immerkar 算法	2.16	1.42	<u>0.66</u>	2.38	6.74	13.54	22.96
Yang 算法	<u>0.67</u>	<u>0.46</u>	<u>0.30</u>	<u>0.36</u>	<u>0.51</u>	<u>0.58</u>	1.40
Zoran 算法	1.07	1.01	1.21	1.73	1.86	1.85	1.76
Liu 算法	<u>0.11</u>	<u>0.08</u>	<u>0.12</u>	<u>0.21</u>	<u>0.40</u>	<u>0.65</u>	<u>0.83</u>
Proposed	<u>0.85</u>	<u>0.74</u>	0.71	<u>0.69</u>	<u>0.67</u>	1.11	<u>1.06</u>

### 4.3 BM3D 算法降噪

为了进一步验证改进算法的实际应用效果,使用经典 BM3D 降噪算法对加入噪声级别为 5, 10, 20, 40, 60, 80 和 100 的高斯噪声的 Lena 图像进行降噪, BM3D 算法的入口参数分别使用真值噪声和改进算法预测的噪声值, 降噪后的图像的 PSNR 值如表 6 所列。从表 6 中可以看出,使用改进算法预测的噪声水平值作为参数与使用真实噪声水平值作为参数的

效果相差不大,充分说明了改进算法的有效性。需要说明的是,在表 6 中,低噪声水平下 PSNR 差值 1.12 稍大,这是由于此时图像质量高,肉眼很难区分 PSNR 值为 40.00 与 38.88 两张图像的质量好坏;另外,参与对比的数据采用真值作为 BM3D 算法的入口参数,依赖人工方式设置参数的实际效果,比表 6 中给出的效果更差。改进算法在实际应用中的效果更优。

表 6 不同噪声水平下经 BM3D 使用真实噪声值和预测噪声值降噪后的 PSNR 指标比较

Table 6 PSNR comparison of BM3D algorithm using ground truths and estimated results at different noise levels

数值类型	噪声水平						
	5	10	20	40	60	80	100
真值	40.00	36.58	33.36	30.02	28.29	26.87	25.86
预测值	38.88	36.31	33.30	29.99	28.28	26.85	25.83
差值	1.12	0.27	0.06	0.03	0.01	0.02	0.03

#### 4.4 执行时间的对比

为了比较各算法的执行效率,选取一张大小为  $512 \times 512$  的 Lena 图像,各算法重复执行 20 次,将平均执行时间作为最终结果参与比较,各算法在不同噪声级别下的平均执行时间如表 7 所列。从表 7 可以看出,虽然 Immerkar 算法的执行时间非常快,但由表 4 和表 5 可知其评价准确性较差,实际应用效果不佳。改进算法的执行时间比其余 4 个算法都少,它的执行效率比 Zoran 算法、Liu 算法和 Chen 算法分别提升了 120 倍、35 倍和 10 倍左右,比 Yang 算法快 50% 左右。改进算法之所以可以获得比较高的执行效率,主要原因在于它直接从原生图块中提取图块协方差矩阵的最小特征值,没有反复迭代选择同质图块的过程。一旦计算出最小特征值,就利用事先训练好的映射函数将最小特征值修正为噪声水平预测值,这部分几乎没有计算代价。因此从执行效率和预测准确率两个方面综合考虑,改进算法较其他经典和主流算法具有更加显著的优势。

表 7 各算法在不同噪声级别下的平均执行时间对比

Table 7 Comparison of average execution time of different algorithms at different noise levels

算法	噪声水平						
	5	10	20	40	60	80	100
Chen 算法	270.9	257.9	260.8	258.1	263.0	263.9	253.2
Immerkar 算法	<b>5.3</b>	<b>5.5</b>	<b>5.4</b>	<b>5.7</b>	<b>6.0</b>	<b>6.3</b>	<b>6.3</b>
Yang 算法	<b>44.8</b>	<b>42.2</b>	<b>44.1</b>	<b>43.3</b>	<b>46.6</b>	<b>45.3</b>	<b>46.7</b>
Zoran 算法	3393.7	3340.4	3322.2	3592.2	3231.9	3248.6	3214.8
Liu 算法	920.7	962.6	1003.9	993.4	1017.9	1005.9	1015.1
Proposed	<b>25.9</b>	<b>25.2</b>	<b>25.7</b>	<b>24.0</b>	<b>23.9</b>	<b>24.5</b>	<b>24.7</b>

**结束语** 本文所提改进算法既没有 Pyatykh 算法<sup>[14]</sup>和 Liu 算法<sup>[20-21]</sup>筛选同质图块的过程,也没有 Chen 算法<sup>[15]</sup>确定  $\tau$  值条件的过程,实现了一种预测准确性和执行效率俱佳的 NLE 算法,这使得它在各类降噪算法的应用中具有显著优势。下一步的研究工作中,将积极探索利用深度学习技术(例如卷积神经网络)实现噪声水平评估,直接利用原生图块训练预测模型,以使得获得的 NLE 算法将不需要提取反映噪声水

平值的特征值,执行效率也有望得到进一步提升。

#### 参考文献

- [1] XU S P, YANG R C, LIU X P. Adaptive switching median filter based on noise ratio estimation[J]. Journal of Optoelectronics • Laser, 2014, 25(4): 792-800. (in Chinese)  
徐少平, 杨荣昌, 刘小平. 基于噪声估计的自适应开关型中值滤波器[J]. 光电子 • 激光, 2014, 25(4): 792-800.
- [2] XU S P, HU L Y, YANG X H. Quality-aware features-based noise level estimator for block matching and three-dimensional filtering algorithm[J]. Journal of Electronic Imaging, 2016, 25(1): 013029.
- [3] LUCAT L, SIOHAN P, BARBAC D. Adaptive and global optimization methods for weighted vector median filters[J]. Signal Processing Image Communication, 2002, 17(7): 509-524.
- [4] LIU S T, MA L P, YIN F L. A color image vector median filtering algorithm based on noise estimation and double weighted spatial distance and magnitude value[J]. Journal of Optoelectronics • Laser, 2011, 22(1): 131-135. (in Chinese)  
刘松涛, 马林坡, 殷福亮. 基于噪声估计和双加权的彩色图像矢量中值滤波[J]. 光电子 • 激光, 2011, 22(1): 131-135.
- [5] DAI T, LU W Z, WANG W, et al. Entropy-based bilateral filtering with a new range kernel[J]. Signal Processing, 2017, 137(8): 223-234.
- [6] JAIN P, TYAGI V. LAPB: Locally adaptive patch-based wavelet domain edge-preserving image denoising[J]. Information Sciences, 2015, 294(2): 164-181.
- [7] WANG W, HE C J. A fast and effective algorithm for a Poisson denoising model with total variation[J]. IEEE Signal Processing Letters, 2017, 24(3): 269-273.
- [8] LI X Y, HE H J, WANG R X, et al. Super pixel-guided nonlocal means for image denoising and super-resolution[J]. Signal Processing, 2016, 124(2): 173-183.
- [9] XIN J R, LU L X, BAO X, et al. Noise energy estimator based on sparseness of time-frequency domain for broadband frequency-hopping signal[J]. Acta Electronica Sinica, 2014, 42(10): 1932-1937. (in Chinese)  
辛吉荣, 陆路希, 包昕, 等. 基于时频稀疏性的跳频信号背景噪声估计算法[J]. 电子学报, 2014, 42(10): 1932-1937.
- [10] XU S P, YANG X H, JIANG S L. A fast nonlocally centralized sparse representation algorithm for image denoising[J]. Signal Processing, 2017, 131(2): 99-112.
- [11] WANG D H, GAO J H. An improved noise removed model based on nonlinear fourth-order partial differential equations[J]. International Journal of Computer Mathematics, 2016, 93(6): 942-954.
- [12] DABOV K, FOI A, EGIAZARIAN K, et al. Image denoising with block-matching and 3D filtering[C]// Proceedings of SPIE. United States: SPIE, 2006: 354-365.
- [13] SHIN D H, PARK R H, YANG S, et al. Block-based noise estimation using adaptive Gaussian filtering[J]. IEEE Transactions on Consumer Electronics, 2005, 51(1): 218-226.
- [14] PYATYKH S, HESSER J, ZHENG L. Image noise level estimation by principal component analysis[J]. IEEE Transactions on

Image Processing, 2013, 22(2): 687-699.

- [15] CHEN G Y, ZHU F Y, HENG P A. An efficient statistical method for image noise level estimation[C]// IEEE International Conference on Computer Vision. New York: IEEE Press, 2015: 477-485.
- [16] IMMERKAR J. Fast noise variance estimation[J]. Computer Vision & Image Understanding, 1996, 64(2): 300-302.
- [17] ZORAN D, WEISS Y. Scale invariance and noise in natural images[C]// IEEE International Conference on Computer Vision. New York: IEEE Press, 2009: 2209-2216.
- [18] LIU W, LIN W S. Additive white Gaussian noise level estimation in SVD domain for images[J]. IEEE Transactions on Image Processing, 2013, 22(3): 872-883.
- [19] YANG S M, TAI S C. Fast and reliable image noise estimation using hybrid approach[J]. Journal of Electronic Imaging, 2010, 19(3): 3007.
- [20] LIU X H, TANAKA M, OKUTOMI M. Noise level estimation using weak textured patches of a single noise image[C]// IEEE International Conference on Image Processing. New York: IEEE Press, 2012: 665-668.
- [21] LIU X H, TANAKA M, OKUTOMI M. Single-image noise level estimation for blind denoising[J]. IEEE Transactions on Image Processing, 2013, 22(12): 5226-5237.
- [22] ZHANG L, ZHANG L, BOVIK A C. A feature-enriched completely blind image quality evaluator[J]. IEEE Transactions on Image Processing, 2015, 24(8): 2579-2591.
- (上接第 218 页)
- 性,利用记忆群体的更新在不直接影响当前群体多样性的情况下加速了算法收敛,针对负荷分配应用,提出了以经验法为基准的变邻域算例。使用某钢厂的实际数据,利用改进的算法在 MATLAB 上对负荷分配优化问题进行仿真,通过与经验法及 ATLPSO-ELS 算法结果的对比,表明该算法对于带钢热轧连轧的负荷分配问题的优化是可行有效的,且算法的时效性有利于实时系统的在线自适应。
- ### 参 考 文 献
- [1] 孙一康. 带钢热轧连轧的模型与控制[M]. 北京:冶金工业出版社, 2002.
- [2] LI H J, XU J Z, WANG G D. Improvement on conventional load distribution algorithm in hot tandem mills[J]. Journal of Iron and Steel Research, International, 2007, 14(2): 36-41.
- [3] KENNEDY J, EBERHART R C. Particle Swarm Optimization [C]// IEEE International Conference on Neural Networks. Piscataway, 1995: 1942-1948.
- [4] KHARE A, RANGNEKAR S. A review of particle swarm optimization and its applications in Solar Photovoltaic system[J]. Applied Soft Computing, 2013, 12(5): 2997-3006.
- [5] SUN J, PALADE V, WU X J, et al. Solving the Power Economic Dispatch Problem With Generator Constraints by Random Drift Particle Swarm Optimization[J]. IEEE Transactions on Industrial Informatics, 2014, 10(1): 222-232.
- [6] HO S Y, LIN H S, LIAUH W H, et al. OPSPSO: Orthogonal Particle Swarm Optimization and Its Application to Task Assignment Problems[J]. IEEE Transactions on Systems Man and Cybernetics Part A: Systems and Humans, 2008, 38(2): 288-298.
- [7] FU Y G, DING M Y, ZHOU C P. Phase Angle-Encoded and Quantum-Behaved Particle Swarm Optimization Applied to Three-Dimensional Route Planning for UAV[J]. IEEE Transactions on Systems Man and Cybernetics Part A: Systems and Humans, 2012, 42(2): 511-526.
- [8] GONG Y J, SHEN M, ZHANG J. Optimizing RFID Network Planning by Using a Particle Swarm Optimization Algorithm with Redundant Reader Elimination[J]. IEEE Transactions on Industrial Informatics, 2012, 8(4): 900-912.
- [9] LI C, YANG S, NGUYEN T T. A self-learning particle swarm optimizer for global optimization problems[J]. IEEE Transactions on Systems Man and Cybernetics Part B Cybernetics, 2012, 42(3): 627-646.
- [10] WEI H L, ISA N A M. An adaptive two-layer particle swarm optimization with elitist learning strategy [J]. Information Sciences, 2014, 273(3): 49-72.
- [11] CHEN W N, ZHANG J, LIN Y, et al. Particle Swarm Optimization With an Aging Leader and Challengers[J]. IEEE Transactions on Evolutionary Computation, 2013, 17(2): 241-258.
- [12] HAN J H, LI Z R, WEI Z C. Adaptive Particle Swarm Optimization Algorithm and Simulation[J]. Journal of System Simulation, 2006, 18(10): 2969-2971. (in Chinese)  
韩江洪, 李正荣, 魏振春. 一种自适应粒子群优化算法及其仿真研究[J]. 系统仿真学报, 2006, 18(10): 2969-2971.
- [13] WEI H L, ISA N A M. Two-layer particle swarm optimization with intelligent division of labor[J]. Engineering Applications of Artificial Intelligence, 2013, 26(10): 2327-2348.
- [14] EPITROPAKISA M G, PLAGIANAKOS V P, VRAHATIS M N. Evolving cognitive and social experience in Particle Swarm Optimization through Differential Evolution: A hybrid approach [J]. Information Sciences, 2012, 216(24): 50-92.
- [15] WEI H L, ISA N A M. An adaptive two-layer particle swarm optimization with elitist learning strategy[J]. Information Sciences, 2014, 273(3): 49-72.
- [16] SHI Y, EBERHART R C. A Modified Particle Swarm Optimizer [C]// Proceedings of the IEEE Conference on Evolutionary Computation. Piscataway, 1998: 69-73.
- [17] ZHAN Z, ZHANG J, LI Y. Adaptive particle swarm optimization[J]. IEEE Transactions on Systems, Man, Cybernetics B: Cybernetics, 2009, 39(6): 1362-1381.
- [18] WANG Y, LIU J L, SUN Y K. Immune Genetic Algorithms (IGA) Based Scheduling Optimization[J]. Journal of University of Science and Technology Beijing, 2002, 24(3): 339-341. (in Chinese)  
王焱, 刘景录, 孙一康. 免疫遗传算法对精轧机组负荷分配的优化[J]. 北京科技大学学报, 2002, 24(3): 339-341.